



2022
Lleida

27·1
junio · juny
julio · juliol

Cataluña
Catalunya

8º CONGRESO FORESTAL ESPAÑOL

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

8CFE

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

Organiza



Predicción del hábitat óptimo y la productividad actual y futura de *Pinus pinaster* ssp. atlantica en el noroeste de España

BARRIO-ANTA, M.¹, CASTEDO-DORADO, F.², CÁMARA-OBREGÓN, A.¹ y LÓPEZ-SÁNCHEZ, C.A.¹

¹ Departamento de Biología de Organismos y Sistemas, Escuela Politécnica de Mieres, Universidad de Oviedo, Campus Universitario de Mieres, C/Gonzalo Gutiérrez Quirós S/N, 33600 Mieres.

² Departamento de Ingeniería y Ciencias Agrícolas. Escuela de Ingeniería Agrícola y Forestal. Universidad de León, Campus de Ponferrada, Avda. de Astorga S/N, 24400 Ponferrada.

Resumen

El objetivo de este estudio ha sido desarrollar modelos ráster con resolución de 250 x 250 m para predecir el hábitat óptimo y la productividad de *Pinus pinaster* ssp. atlantica en España. Para ello se usaron datos de presencia de la especie obtenidos del IFN3, datos de productividad procedentes de parcelas de investigación e información ambiental espacialmente continua disponible. Después de probar varios algoritmos, se seleccionó Random Forest como la mejor metodología para modelizar ambas variables. La precisión global del modelo de hábitat óptimo fue del 73% y las variables con mayor poder predictivo fueron variables climáticas (principalmente térmicas) y propiedades físicas del suelo. El modelo de índice de sitio explicó el 60% de la variabilidad y las variables litológicas fueron las más relevante. Las proyecciones futuras revelan un importante incremento de hábitat óptimo para el año 2070 (50-66%) y un ligerísimo incremento del índice de sitio (0,46-0,51%).

Palabras clave

Pinus pinaster Aiton, modelo de distribución de especies, índice de sitio, variables ambientales, random forest, cambio Climático.

1. Introducción

El pino pinaster es una especie forestal con gran versatilidad ecológica que en la Península Ibérica ha sido clasificada tradicionalmente en dos poblaciones, razas o subespecies diferentes (población atlántica y población mediterránea); aunque actualmente no hay consenso definitivo sobre su estatus taxonómico (ALÍA et al., 1996). Ambas poblaciones difieren en su localización y crecimiento. Así, las poblaciones atlánticas se encuentran principalmente en zonas de clima atlántico y son más productivas, mientras que las poblaciones mediterráneas se encuentran en áreas de clima mediterráneo con precipitaciones bajas, irregulares y altas temperaturas y son menos productivas (ALÍA et al. 1997; BRAVO-OVIEDO et al., 2011). Estas poblaciones españolas de pino pinaster atlántico parece que se expandieron por Galicia en el siglo XIX procedentes de Portugal y actualmente están ampliamente distribuidas por todo el noroeste (Galicia, Asturias y la provincia de León). La especie ocupa en estas seis provincias una superficie de 433.754 ha, que representa el 18,2% de su área arbolada total (MAPA, 2019), siendo su conífera más importante en superficie ocupada. Además, también es la conífera más importante en cortas de madera, alcanzando estas en el período 2002-2015 los 2.649.249 m³/año, que suponen un 31,9% del total de madera cortado en la región (MAPA, 2019). Por tanto, debido a esta gran importancia económica, es necesario que propietarios, gestores y planificadores sean capaces de determinar la capacidad productiva de las masas existentes, así como el potencial productivo de los nuevos terrenos disponibles para llevar a cabo repoblaciones futuras.

El conjunto de variables ambientales (geomorfológica, edáficas, y climáticas) que determinan la capacidad inherente de un terreno para la producción de una determinada especie forestal es lo que se denomina calidad de estación (CLUTTER et al., 1983; VANCLAY, 1994) y tradicionalmente ha sido

determinada a través del índice de sitio. Dicho índice se define como altura dominante de la masa a una determinada edad de referencia y ha sido usado universalmente como medida indirecta de la productividad forestal debido a: *i*) su buena correlación con la producción en volumen, *ii*) su relativa independencia de la densidad de la masa y *iii*) debido a problemas que presentan, las deseable a priori, medidas directas (e.g. volumen) (CLUTTER et al., 1983). Una vez determinado el índice de sitio, y siempre que existan modelos de crecimiento y producción desarrollados para la especie en cuestión, es posible obtener el correspondiente crecimiento medio anual máximo en volumen. Este crecimiento medio anual máximo en volumen por hectárea es considerado como una medida de productividad más apropiada por su relación directa con el volumen total que una masa puede proporcionar en una determinada estación al final del turno de corta (SKOVSGAARD & VANCLAY, 2008; LATTA et al., 2009).

Cuando se dispone de ecuaciones de crecimiento en altura dominante para una determinada especie es posible calcular el índice de sitio a escala monte con bastante precisión. Sin embargo, este método de estimación directa requiere que la masa esté presente y su determinación es cara ya que precisa de la medición de la altura dominante de la masa y la determinación de su edad. Estos inconvenientes se resuelven con el empleo de métodos indirectos de estimación del índice de sitio basados en variables ambientales (e.g., FONTES et al. 2003; ROMANYÀ & VALLEJO, 2004; ÁLVAREZ-ÁLVAREZ et al. 2011). Sin embargo, muchos de los modelos construidos hasta la fecha con esta metodología incluyen variables edáficas que sólo se pueden determinar a través de la toma de muestras de suelo y la realización posterior de caros análisis en laboratorio, disminuyendo enormemente su utilidad práctica. La existencia actual de datos masivos procedentes de sensores remotos y de capas ráster de datos interpolados de variables geomorfológicas, edáficas y de clima, permite obtener información ambiental espacialmente continua que posibilita la estimación y el mapeado del índice de sitio a escala paisaje con unas precisiones razonables (BONTEMPES & BOURIAUD, 2014). Además, como ventaja adicional sobre los métodos directos, esta metodología permite estimar el índice de sitio de terrenos en los que la especie no está presente.

Una vez desarrollados estos modelos, una importante cuestión práctica que se plantea es la de establecer el marco territorial más adecuado sobre la que mapear el índice de sitio. En este sentido, un marco adecuado donde sobrescribir esta y, cualquier otra información ecológica relevante sobre una determinada especie, es la superficie de su hábitat más adecuado o hábitat óptimo (CASTAÑO-SANTAMARÍA et al., 2019), y que se define como el área dentro de esa región donde esa especie está presente o potencialmente puede estarlo. Para definir esta superficie, tradicionalmente se han construido modelos matemáticos que se han denominado modelos de distribución de especies, SDMs (GUISAN & ZIMMERMANN, 2000).

El cambio climático ya está afectando de forma significativa al sur de Europa, esperándose cambios más dramáticos en el futuro ya que se predicen incrementos de temperatura media de 4-6°C y descenso de la precipitación media mensual del 15-20% para 2080. Las variables climáticas son factores que condicionan y determinan en mayor o menor grado la distribución y productividad de las especies forestales y; por tanto, cualquier cambio en estas variables es de esperar que afecte a su distribución, abundancia y crecimiento. En este sentido, si se dispone de proyecciones climáticas futuras para distintos escenarios de cambio climático, con ayuda de los SDMs es posible predecir el desplazamiento previsible de las especies o los lugares óptimos donde estas pueden persistir. Igualmente, estas proyecciones climáticas se pueden usar con los modelos de productividad para predecir la influencia que el cambio climático tendrá en ella.

2. Objetivos

El objetivo principal de este trabajo ha sido el desarrollo de modelos espacialmente continuos de distribución y productividad para las poblaciones atlánticas de pino pinaster en el noroeste de

España y predecir la influencia del cambio climático en las mismas. Para conseguirlo ha sido necesario: *i*) analizar las variables ambientales que condicionan la distribución de la especie y su productividad, *ii*) desarrollar modelos de distribución y productividad en función de dichas variables, *iii*) generar mapas espacialmente continuos de las variables ambientales a usar como potenciales predictores, y *iv*) llevar a cabo predicciones futuras de los modelos para diferentes horizontes temporales y escenarios de cambio climático.

3. Metodología

3.1. Área de estudio y datos usados

El área de estudio comprende la región de procedencia de pino pinaster 1 en España (noroeste) (ALIA et al., 2009), que incluye la comunidad autónoma de Galicia y parte de Asturias y de la provincia de León (Figura 1). Se trata de una región caracterizada principalmente por un clima atlántico o de fuerte influencia atlántica y rocas graníticas y sedimentarias del Paleozoico inferior con litofacies dominantes de areniscas, cuarcitas y pizarras. Los suelos dominantes son de textura franca a franco-arenosa, con baja capacidad de retención de agua y fuertemente ácidos (ALIA et al., 2009).

Para conocer la presencia de la especie en el área de estudio, se emplearon los datos del tercer inventario Forestal Nacional (IFN3) (DGCN, 2006), considerando como presencia la existencia de uno o más árboles vivos de pino pinaster en cada una de las parcelas del IFN3. Por otro lado, se usaron datos de índice de sitio (IS) obtenidos de 85 parcelas de investigación instaladas por miembros del equipo de investigación a lo largo del área de estudio durante las últimas dos décadas.

Como posibles predictores de los modelos de distribución y productividad de la especie se utilizaron tres tipos de variables ambientales espacialmente continuas: topográficas, climáticas, y edáficas. Las variables topográficas se obtuvieron del modelo digital de elevación elaborado por el Plan Nacional de Ortofotografía Aérea (PNOA; www.pnoa.ign.es), usando para determinarlas el Automated Geoscientific Analyses Geographical Information System software v.3.0.0 SAGA (CONRAD et al., 2015). Como variables climáticas se emplearon 19 variables climáticas que se obtuvieron de WorldClim (HIJMANS et al., 2005) y como variables edáficas se utilizaron 12 variables edáficas obtenidas de SoilGrids250m (HENGL et al., 2017). Por último, el tipo de suelo se obtuvo de la European Soil Database (ESDB) v2.0., y la clase litostratigráfica, permeabilidad y geología se obtuvieron del Mapa Geológico y Estratigráfico Nacionales (IGME, 2015a; 2015b). Debido a las diferentes resoluciones espaciales de las variables anteriores, todas fueron rasterizadas a una resolución de 250 m.

Finalmente, para predecir los efectos del cambio climático se emplearon los Modelos de Clima Global (GCM) para 2050 y 2070 basados en el modelo CMIP5 del quinto Informe de Evaluación del IPCC (<http://www.worldclim.org/CMIP5>).

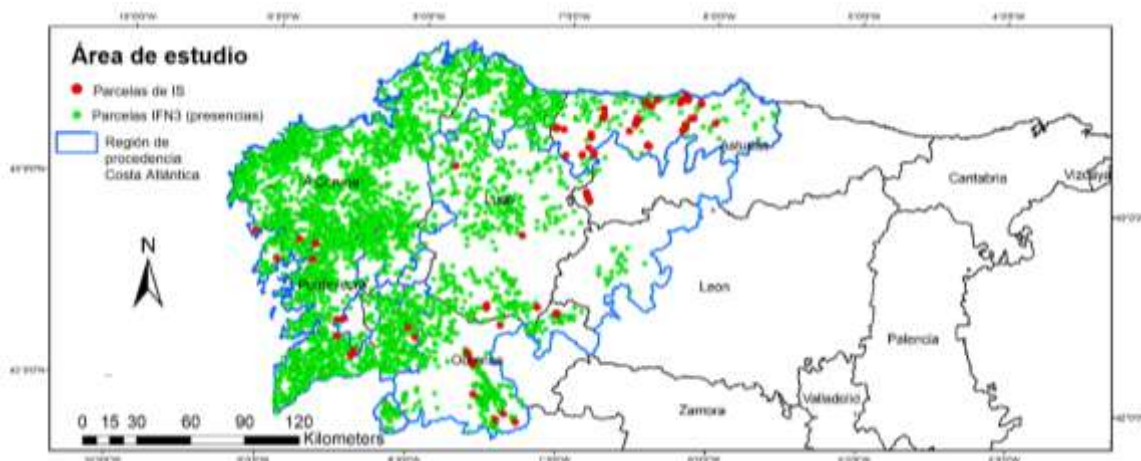


Figura 1. Localización del área de estudio (región de procedencia 1) dentro del área de distribución de pino pinaster. Parcelas usadas en el Tercer Inventario Forestal Nacional (IFN3) donde la presencia de pino pinaster fue confirmada (puntos verdes) y parcelas de índice de sitio (SI) usadas en el estudio (puntos rojos).

3.3. Modelización de la productividad y de la distribución de la especie

Para obtener el mejor modelo de distribución y de productividad y a partir de las variables ambientales, se probaron diferentes algoritmos *machine learning* implementados el software WEKA (HALL et al. 2009) y el paquete BIOMOD2 R (THUILLER et al., 2003), respectivamente: redes neuronales artificiales (ANN), análisis de árboles de clasificación (CTA), análisis discriminante flexible (FDA), modelos aditivos generalizados (GAM), modelos generalizados de regresión potenciada (GBM), modelos lineales generalizados (GLM), modelo de regresión lineal múltiple (MLR), árboles de regresión (RT), modelos de bosques aleatorios (RF), splines de regresión adaptativos multivariantes (MARS), regresión lineal múltiple (MLR), envolventes rectilíneas de superficie (SRE) y k-ésimo vecino más cercano (KNN).

Para la evaluación de los modelos se usó el método de validación cruzada de 10 carpetas o grupos. Este proceso consistió en cuatro pasos: i) en el primer paso el conjunto de datos se dividen en 10 grupos aleatorios de aproximadamente el mismo tamaño, ii) luego el modelo se ajusta 10 veces, omitiendo secuencialmente un grupo cada vez, iii) cada uno de los modelos ajustado se usa para producir predicciones pseudo-independientes en el grupo omitido, proporcionando una buena indicación de como predice el modelo sobre datos no usados en el ajuste y iv) a partir de esas predicciones se obtienen diversas métricas para evaluar los modelos.

Para analizar la precisión de las predicciones del modelo SDM, se utilizó la matriz de confusión (FIELDING & BELL, 1997) de la que se extrajeron varios estadísticos (precisión global (OA), sensibilidad, especificidad, estadístico true skill (TSS), Área bajo la curva ROC (AUC) y estadístico Kappa). Los algoritmos generan probabilidades de presencia y para calcular OA y Kappa es necesario un modelo binario, por lo que fue necesario fijar un umbral de probabilidad para determinar esos valores de presencia/ausencia. Dicho umbral se calculó como el valor medio de dos métodos: la probabilidad de presencia que maximizó sensibilidad y especificidad y la probabilidad de presencia que minimizó la diferencia entre los valores absolutos de sensibilidad y especificidad. Para evaluar los modelos se utilizaron el coeficiente de determinación de regresión no lineal (RYAN, 1997), los valores absoluto y relativo del error medio absoluto (MAE) y el error cuadrático medio (RMSE).

Para seleccionar los predictores del modelo final, se utilizó la medida de importancia variable (VIM) como técnica de clasificación, cuyos valores fueron normalizados para que su suma diese uno y expresados en valores relativos ($VIM_{relativo} = (VIM - VIM_{min}) / (VIM_{max} - VIM_{min})$).

Para transformar los valores de IS a valores de crecimiento medio anual máximo en volumen (CM_{max}) se llevaron a cabo simulaciones con los modelos dinámicos de crecimiento elaborados para pino pinaster atlántico en la zona de estudio (DIÉGUEZ-ARANDA et al., 2009; ARIAS-RODIL, et al., 2016) considerando valores iniciales de plantación de 900 a 1400 pies/ha y suponiendo que la masa evoluciona de forma natural (reducción de densidad sólo por mortalidad natural y por eventos aleatorios). A partir de dichas simulaciones se ajustó un modelo paramétrico para predecir CM_{max} en función del IS y de la densidad de plantación y otro modelo para predecir la edad (TCM_{max}) a la que se alcanza ese CM_{max} .

3.4. Predicciones futuras

Los modelos obtenidos se aplicaron sobre datos climáticos proyectados para dos escenarios de cambio climático (moderado y pesimista) para 2050 y 2070, respectivamente. El escenario moderado (RCP 4.5) asume que las políticas climáticas limitarán las emisiones relacionadas con el efecto invernadero, alcanzándose una concentración de CO_2 de 650 ppm y un aumento de 1,0 a 2,6 °C de temperatura en 2100 (THOMSON et al., 2011). Por su parte, el escenario pesimista (RCP 8.5) supone un aumento continuo en los gases de efecto invernadero (manteniéndose la tendencia actual), alcanzando una concentración de CO_2 de 1.350 ppm y un incremento de 2,6–4,8 °C de temperatura para 2100 (IPCC, 2013; HARRIS et al., 2014).

4. Resultados

4.1. Selección de la mejor técnica de ajuste

Los resultados de los ajustes de los diferentes algoritmos ensayados mostraron que el algoritmo Random Forest (RF) es el que presentó mejores resultados en los valores de los estadísticos de comparación en validación cruzada (Tabla 1), tanto para el modelo de distribución, como para el de productividad. RF es una técnica de clasificación y de regresión no paramétrica ampliamente usada que consiste en la construcción de decenas o centenas de árboles de decisión a partir de submuestras aleatorizadas de variables dependientes e independientes (BREIMAN, 2001).

Tabla 1. Valores de los estadísticos de comparación (tras validación cruzada de 10 grupos) de los diferentes algoritmos probados para ajustar el modelo de distribución de la especie y el de productividad. ANN = redes neuronales artificiales; CTA = análisis de árboles de clasificación; FDA = análisis discriminante flexible; GAM = modelos aditivos generalizados; GBM = modelos generalizados de regresión potenciada; GLM = modelos lineales generalizados; MARS = splines de regresión adaptativos multivariantes; RF = modelos de bosques aleatorios; SRE = envolventes rectilíneas de superficie; MLR = regresión lineal múltiple; KNN = k-ésimo vecino más cercano; RT = árboles de regresión usando el algoritmo M5P. Estadísticos de comparación: Área bajo la curva ROC (AUC) y pseudo-coeficiente de determinación (R^2). Valores entre paréntesis son las desviaciones estándar de 10 predicciones.

Modelo de distribución de especies (software BIOMOD2)									
	ANN	CTA	FDA	GAM	GBM	GLM	MARS	RF	SRE
AUC	0,79 (0,02)	0,76 (0,02)	0,78 (0,02)	0,79 (0,02)	0,79 (0,02)	0,78 (0,02)	0,79 (0,02)	0,81 (0,02)	0,62 (0,02)
Modelo de productividad (software WEKA)									
	MLR	kNN	MARS	RT	RF				
R^2	0,41 (0,23)	0,44 (0,26)	0,52 (0,16)	0,47 (0,20)	0,59 (0,23)				

4.2. Modelo de distribución de especies. Hábitat óptimo actual y futuro

De las 7378 parcelas de inventario del IFN3 en el área de estudio, el pino pinaster estaba presente en 3760 y ausente en 3618. Los estadísticos de evaluación del modelo en validación mostraron una buena capacidad predictiva (AUC=0,81; OA=0,73; TSS= 0,46 y Kappa= 0,46). Como resultado del proceso de selección de variables, el algoritmo RF seleccionó 11 variables ambientales de un total de 50, mostrando que la distribución del pino pinaster atlántico está influenciada por muchas variables interrelacionadas (Tabla 2). Teniendo en cuenta la importancia normalizada, cinco variables climáticas son las que más contribuyen (52,23%) en la explicación del hábitat óptimo (33,39% corresponde a variables térmicas y 18,8% a variables pluviométricas). Cinco variables de suelo contribuyeron globalmente con un 39,82% (32,31% corresponde a variables físicas y 7,51% a variables químicas).

La temperatura media anual (BIO1) fue la variable más importante indicando que la probabilidad de presencia de la especie aumenta cuando esta temperatura pasa de los 10 a los 16 °C. Las dos siguientes variables en importancia (BIO3 y BIO4) se refieren a la variabilidad de las temperaturas e indican que la especie prefiere áreas con temperatura estables. Las siguientes variables son la precipitación de la estación más lluviosa (BIO16) y la estacionalidad de la precipitación (BIO16). Indicando que el pino pinaster atlántico prefiere las zonas con precipitaciones de invierno más altas, que también se corresponden con zonas de alta estacionalidad de las precipitaciones (BIO15). La densidad de la fracción de tierra fina (BD) es la principal variable de suelo que entra en el modelo e indica que la probabilidad de presencia de este pino es más alta cuando esta densidad se incrementa de 1150 a 1500 kg/m³.

El hábitat óptimo actual se extiende por la práctica totalidad de A Coruña y Pontevedra (a excepción de las zonas más elevadas de estas provincias), aproximadamente por la mitad de las provincias de Lugo y Ourense y la franja costera centro-occidental de Asturias (Figura 2, izquierda).

Las proyecciones futuras del SDM para los dos escenarios de cambio climático revelan incrementos importantes de la superficie de hábitat óptimo de pino pinaster atlántico, siendo estos cambios más importantes para el escenario más pesimista. El escenario de cambio (moderado/pesimista) se revela como mucho más importante que el horizonte temporal de proyección (2050/2070). Así, los cambios más importantes ya se producen en 2050, con un incremento de la superficie de hábitat óptimo de entre 0,85 y 1,1 millones de ha (incrementos del 45,86 al 60,75% sobre la superficie actual, para el escenario de cambio climático moderado y pesimista, respectivamente). Para 2070 se obtienen incrementos adicionales del 4,01 y del 5,38% respecto 2050 para cada uno de los dos escenarios. Los resultados sugieren que, en esta fecha, prácticamente todo Galicia (salvo áreas montañosas del sureste de Ourense) y gran parte del oeste de Asturias presentarían condiciones óptimas para el establecimiento de la especie (Figura 2).

Tabla 2. Variables incluidas en el modelo de distribución, incluyendo su categoría y su importancia. Para asegurar que los valores de importancia de la variable están expresados en una escala comparable para cada variable respuesta, los valores de todos los predictores seleccionados se normalizaron para que su suma fuese la unidad (importancia normalizada) o expresados como valores relativos. $Importancia\ relativa = (VIM - VIM_{min}) / (VIM_{max} - VIM_{min})$.

Categoría	Variable	Importancia normalizada	Importancia relativa	Valores resumen en el hábitat óptimo			
				media	max,	min.	d.s.
Clima	BIO1	11,57	100,00	12,96	15,10	8,00	1,00
Clima	BIO3	11,22	93,49	3,94	4,40	3,60	0,14
Clima	BIO4	10,60	81,81	413,34	565,40	307,00	60,44
Clima	BIO16	9,44	59,84	447,94	662,00	241,00	77,91

Clima	BIO15	9,40	59,09	42,26	53,00	27,00	4,77
Suelo	BD	9,28	56,85	1274,66	1506,00	1042,00	59,12
Suelo	SILT	8,63	44,69	32,42	44,00	20,00	3,85
Suelo	R	8,14	35,36	16,02	43,00	1,00	5,48
Terreno	TSI	7,96	31,95	0,00	0,32	-0,26	0,03
Suelo	WRB-LEV ¹	7,51	23,52	-	-	-	-
Suelo	DB200	6,26	0,00	199,82	200,00	161,00	1,37

BIO1= temperatura media anual; BIO2=rango medio diurno de temperatura (media mensual de temperatura máxima diaria- temperatura mínima); BIO3= Isotermicidad (BIO2/BIO7)*100; BIO4= estacionalidad de la temperatura (desviación estándar*100); BIO15= estacionalidad de la precipitación (coeficiente de variación); BIO16= precipitación de la estación más lluviosa; BIO7= rango de temperatura anual (temperatura máxima del mes más cálido - temperatura mínima del mes más frío); BD= densidad de la fracción de tierra fina (<2mm); TSI= índice de forma del terreno; WRB_LEV = Grupo de referencia del suelo de las unidades tipológicas del suelo de la Base Mundial de Referencia (WRB) para los Recursos del Suelo; DB200= Profundidad hasta roca (horizonte R) hasta 200 cm. ¹ variable cualitativa.

4.3. Modelo de productividad. Productividad actual y futura

Los estadísticos de evaluación del modelo RF en validación cruzada ($R^2=0,6$: MAE=1,24 m y RMSE=1,54 m) y la no detección de sesgo, tras la inspección de los gráficos de valores observados frente a predichos, indican una buena capacidad de ajuste para su uso como modelo predictivo. Como resultado del proceso de selección de variables, el algoritmo RF seleccionó 7 variables ambientales de un total de 50. De estas, únicamente 2 variables contribuyeron ya con un 75,37% (correspondiendo un 51,24% litostratigrafía y un 24,13% a la geocronología). Globalmente las variables relacionadas con el suelo representaron el 90,28% de la importancia normalizada y las variables relacionadas con el clima únicamente el 9,71% (Tabla 3).

Tabla 3. Variables incluidas en el modelo de productividad, incluyendo su categoría y su importancia. Para asegurar que los valores de importancia de la variable están expresados en una escala comparable para cada variable respuesta, los valores de todos los predictores seleccionados se normalizaron para que su suma fuese la unidad (importancia normalizada) o expresados como valores relativos. $Importancia\ relativa = (VIM - VIM_{min}) / (VIM_{max} - VIM_{min})$.

Categoría	Variable	Importancia normalizada	Importancia relativa	Valores resumen en el hábitat óptimo			
				media	max	min	d.s.
Suelo	LIT_dlo ¹	51,24	100,00	-	-	-	-
Suelo	Geo_es ¹	24,13	43,16	-	-	-	-
Suelo	R	6,31	5,80	16,02	43,00	1,00	5,48
Clima	BIO3	6,17	5,52	3,94	4,40	3,60	0,14
Suelo	CEC	4,71	2,45	25,04	66,00	15,00	2,82
Suelo	WRB-LEV ¹	3,89	0,72	-	-	-	-
Clima	BIO08	3,54	0,00	8,59	12,50	2,60	1,64

¹ Variables cualitativas

Los grupos litostratigráficos que mostraron mayor productividad fueron las rocas plutónicas ácidas (granitos, granodioritas y quartzodioritas), seguidos por esquistos, filitas, ampelitas y liditas. Los suelos formados por esquistos, esquistos micáceos, esquistos cuarcíticos, ortogneis, migmatitas y gravas y depósitos aluviales de grava, arena y limo mostraron una productividad intermedia. La menor productividad se produce sobre terrenos formado por pizarras, areniscas y cuarcitas.

Teniendo en cuenta la edad del material geológico, los valores de índice de sitio más elevados se han alcanzado sobre materiales de paleozoico más antiguo (Pérmico-Carbonífero-Devónico). En cambio, los valores de índice de sitio más bajos se alcanzan sobre terrenos procedentes de materiales sedimentarios del paleozoico más moderno (período Ordovícico y Cámbrico).

Para transformar el valor de índice de sitio a crecimiento medio máximo en volumen (CM_{max}) y obtener el turno de máxima renta en volumen asociado (TCM_{max}), se obtuvieron las siguientes relaciones matemáticas, que al proceder de simulaciones presentan un R^2 muy elevado (0,99):

$$CM_{max} = 5,3243 + 1,0940 \cdot IS + 0,0058 \cdot IS^2 - 2897,1760 \cdot (1/N) \quad (\text{Eq. 1})$$

$$TCM_{max} = 110,5400 - 5,3243 \cdot CM_{max} + 0,0931 \cdot CM_{max}^2 \quad (\text{Eq. 2})$$

Donde, CM_{max} es el crecimiento medio máximo anual en volumen ($m^3/ha/año$), IS es el índice de sitio (altura dominante de la masa en m a la edad de referencia de 20 años), N es la densidad de plantación (pies/ha) y TCM_{max} (años), es el turno de máxima renta en volumen (edad a la que se alcanza el CM_{max}).

Puesto que las parcelas que se han usado para el desarrollo de los modelos de crecimiento y producción son “ideales” con ausencia de huecos por derribos o marras de plantación, los ejercicios de simulación puros (simulación completa en ausencia de datos de estado iniciales de una masa) requieren introducir un factor corrector que puede ser equivalente al grado de densidad real de las masas (MADRIGAL et al. 1999). Considerando que pino pinaster atlántica es bastante frugal, resistente a derribos por viento y presenta baja mortalidad natural (ARIAS-RODIL et al., 2016), este valor reductor del CM_{max} lo hemos estimado en 0,75. Así para obtener los valores reales de CM_{max} , los resultados de Eq.1 deben multiplicarse por dicho factor reductor. En cambio, el valor de CM_{max} a introducir en la expresión para determinar el turno de máxima renta en volumen (Eq. 2) no deben multiplicarse por dicho factor reductor. Atendiendo a dichos resultados y a los valores máximos de IS observados en la región ($IS=19$), el crecimiento medio máximo en volumen esperable para las densidades de plantación habituales (900-1400 pies/ha) se sitúa entre 18,4-18,7 $m^3/ha/año$ con unos turnos asociados de máxima renta en volumen de 35-36 años, respectivamente.

Tabla 4. Superficie ocupada (ha) por las distintas clases de valores del IS (altura dominante de la masa a la edad de referencia de 20 años) dentro de su hábitat óptimo en las condiciones climáticas actuales y porcentaje de variación para dos horizontes de temporales de proyección (2050 y 2070) bajo los escenarios de cambio climático RCP4.5 y RCP8.5.

Horizonte temporal	Actual	2050		2070	
Escenario de cambio climático	-	RCP4.5	RCP8.5	RCP4.5	RCP8.5
Clase de IS (m)					
8	206,25	127,3%	-100,0%	51,5%	-100,0%
9	8.800,00	136,4%	254,6%	200,6%	228,7%
10	12.668,75	147,4%	472,8%	240,7%	538,8%
11	45.481,25	87,4%	222,8%	123,4%	273,5%
12	119.362,50	100,3%	149,7%	111,0%	177,7%
13	446.375,00	64,0%	63,8%	62,7%	67,6%
14	392.662,50	31,4%	47,1%	33,7%	51,8%
15	483.443,75	28,8%	38,4%	32,6%	38,7%
16	225.843,75	26,2%	32,3%	29,2%	31,9%

17	63.362,50	44,5%	6,0%	34,1%	4,7%
18	59.087,50	41,3%	66,7%	56,4%	70,4%
19	4.237,50	76,7%	-57,1%	18,1%	-49,7%

Como se puede ver en la tabla anterior y espacialmente en la figura 2, la superficie de terrenos con índice de sitio para pino pinaster inferior a 16 m aumenta sustancialmente. Sin embargo, esto se debe al aumento futuro de la superficie de hábitat óptimo. La comparación hecha sobre la misma superficie de hábitat óptimo (actual) arroja solamente un escasísimo incremento del índice de sitio de 0,45-0,51% respecto al valor medio actual ponderado por las superficies ocupadas (14,5 m).

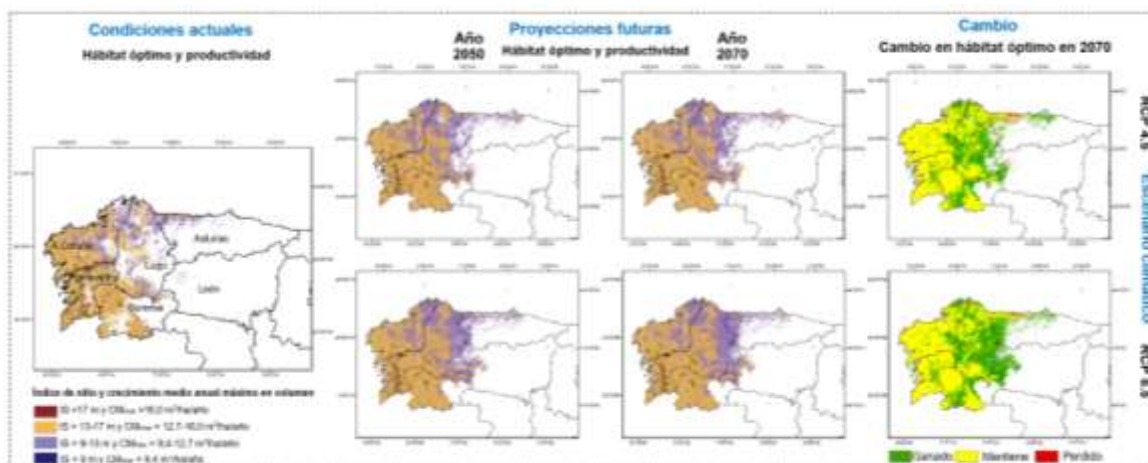


Figura 2. Predicciones del hábitat óptimo y productividad actuales y futuras bajo dos escenarios de cambio climático. Nota: los crecimientos medios anuales en volumen máximos se corresponden con una densidad de plantación de 1100 pies/ha (una de las más frecuentes).

5. Discusión

5.1. Modelo de distribución de especies y efecto del cambio climático

El pino pinaster es una especie termófila que en España crece en áreas caracterizadas por temperaturas medias anuales mayores de 10 °C y rangos anuales de precipitación de entre 500 y 1300 mm (ALÍA et al., 2009). Los resultados de este estudio mostraron que las variables climáticas relacionadas con la temperatura son las que tienen una influencia más fuerte a la hora de explicar su distribución. Así la probabilidad de presencia de la especie es más alta cuando la temperatura media anual es más alta y la variabilidad de las temperaturas (BIO3 y BIO4) menor, lo cual está en correspondencia con la información autoecológica publicada para la especie (ABAD VIÑAS et al. 2016; NICOLÁS & GANDULLO 1967; GANDULLO & SÁNCHEZ PALOMARES, 1994). El menor efecto de las variables de precipitación se debe al hecho de que en noroeste de España la precipitación anual que se alcanza está en el rango de 1000-1300 mm (incluso más), que es muy superior al mínimo que requiere la especie (400-500 mm) (ABAD VIÑAS et al. 2016). Los resultados también mostraron que el pino pinaster atlántico prefiere las zonas con precipitaciones de invierno más altas (BIO16), que espacialmente se traduce en zonas de baja altitud próximas a la costa, debido a que en el noroeste de España la precipitación disminuye al separarse de la costa, consecuencia del patrón general de circulación atmosférico con frentes llegando desde el oeste (DE UÑA ÁLVAREZ, 2001).

Respecto al suelo, la densidad de la fracción de tierra fina (BD) fue variable edáfica más importante, indicando mayor probabilidad de presencia de la especie con valores más altos de BD.

Esta propiedad física del suelo suele mostrar correlaciones negativas con el contenido en materia orgánica del suelo (e.g. ALEXANDER, 1989; GRIGAL & VANCE 2000; PÉRIÉ & OUIOMET, 2008; SAKIN, 2012) y positivas con el contenido en arena (CHAUDHARI et al., 2013). Por tanto, esta variable está indicando la preferencia de la especie por suelos con bajo contenido en materia orgánica y de texturas arenosas. Estos resultados son consistentes con la evidencia de que las altas temperaturas promueven mayores tasas de mineralización de la materia orgánica de los suelos (ÁLVAREZ-ÁLVAREZ et al. 2011) y con la ampliamente reconocida preferencia de la especie por suelos de textura arenosa (NICOLÁS & GANDULLO, 1967; BARÁ & TOVAL, 1983; GANDULLO & SÁNCHEZ PALOMARES, 1994; ABAD VIÑAS et al. 2016).

La proyección temporal del modelo indica incrementos de la superficie de hábitat óptimo para la especie en 2050 de entre el 46 y el 61% de la superficie actual. Estos resultados están en la línea de los obtenidos en estudios llevados a cabo sobre la especie a una escala más amplia, como las proyecciones de la base de datos europea Forest Focus ([Suitability maps of Pinus pinaster \(ForestFocus\) - Datasets \(europa.eu\)](http://ForestFocus.eu)) o los llevados a cabo por BEDE-FAZEKAS & LEVENTE HORVÁTH (2014). Puesto que la expansión de esta especie se debe principalmente al manejo por parte del hombre, este incremento de superficie de hábitat óptimo debe interpretarse como un incremento de superficies adecuadas para realizar nuevas plantaciones con pino pinaster.

5.2. Modelo de productividad y efecto del cambio climático

Las variables relacionadas con el material geológico (litoestratigrafía y la edad de las formaciones geológicas) fueron claramente las variables más importantes a la hora de explicar la variabilidad del índice de sitio. Sin embargo, este resultado no sorprende, ya que diversos autores en estudios previos sobre la especie, llegaron a resultados similares (e.g., BRAVO-OVIEDO et al. 2011; EIMIL-FRAGA et al. 2014). La razón parece estar en que estas variables geológicas están fuertemente correlacionadas con variables físicas y químicas de los suelos como su profundidad, su tipo de textural, la densidad aparente de su fracción fina, la disponibilidad de algunos nutrientes, etc. Los mayores valores del índice de sitio se producen sobre masas establecidas sobre suelos procedentes de la disgregación de rocas plutónicas (granitos, granodioritas y cuarzodioritas) y la razón se puede deber a que se trata de zonas a baja altitud y con alta profundidad de suelos debida al alto grado de tectonización por la presencia de numerosas fallas y fracturas (EIMIL-FRAGA et al. 2014). Por el contrario, los menores índices de sitio se producen sobre suelos procedentes de cuarcitas, pizarras y areniscas del Cámbrico-Ordovicio que originan suelos poco profundos y pobres en nutrientes debido a la alta resistencia a la meteorización que presentan estas rocas. La siguiente variable más importancia es la probabilidad de ocurrencia de un horizonte de roca dentro de los primeros dos metros de suelo. La profundidad de suelo ya ha sido apuntada previamente como variable muy influyente en la productividad de las masas de pino pinaster (BARÁ y TOVAL, 1983; OLIVEIRA et al., 2000; ÁLVAREZ-ÁLVAREZ et al., 2011; EIMIL-FRAGA et al., 2014). La única variable relacionada directamente con el contenido en nutrientes de los suelos que considera el modelo de productividad es la capacidad de intercambio catiónico, aunque presenta muy poca importancia. Esta escasa relación del contenido en nutrientes del suelo con la productividad del pino pinaster atlántico ha sido puesta de manifiesto en numerosos estudios (e.g., BARÁ y TOVAL, 1983; ÁLVAREZ-ÁLVAREZ et al., 2011; EIMIL-FRAGA et al., 2014) e indica que la mayor productividad de la especie se relaciona con mayores “volúmenes de suelo” y con la presencia de ciertos tipos texturales (suelos arenosos o franco-arenosos) y no con altos valores nutricionales del suelo. Estos resultados vuelven a poner de relieve la marcada frugalidad que siempre se le ha atribuido a la especie.

Las simulaciones con los datos climáticos futuros bajo dos escenarios de cambio climático (RCP4.5 y RCP8.5) sólo predicen un ligerísimo incremento en la productividad (>1%). La razón es que sólo dos variables de temperatura fueron seleccionadas en el modelo (isotermicidad y temperatura

media del trimestre más lluvioso (invierno) y a que su contribución global a la explicación de la variabilidad del índice de sitio fue muy baja (9,71% de la importancia normalizada)

6. Conclusiones

El estudio ha permitido elaborar dos mapas raster con una resolución espacial de 250 m/píxel para predecir el hábita óptimo y la productividad del pino pinaster atlántico en el noroeste de España bajo escenarios de cambio climático. Las variables climáticas (principalmente térmicas) son las más afectan a la distribución de la especie, mientras que la productividad es explicada principalmente por variables litológicas y muy poca influencia de las variables nutricionales del suelo. El cambio climático se espera que aumente sustancialmente la superficie óptima disponible para la especie ya en 2050, mientras que apenas se observan cambios en la productividad. Estos resultados pueden animar a darle un mayor protagonismo a esta especie en los programas de reforestación frente a otras coníferas que también se usan en la zona como el pino radiata.

7. Agradecimientos

Los autores están muy agradecidos a Elena Robla y Vicente Sandoval, del Área de Inventarios y Estadísticas Forestales (Ministerio para la Transición Ecológica y Reto Demográfico), por proporcionar los datos de la actualización del Cuarto Inventario Forestal Nacional para el norte de España (IFN4.5).

8. Bibliografía

ABAD VIÑAS, R.; CAUDULLO, G.; OLIVEIRA, S.; DE RIGO, D.; 2016. *Pinus pinaster* in Europe: distribution, habitat, usage and threats. En: SAN-MIGUEL-AYANZ, J.; DE RIGO, D.; CAUDULLO, G.; HOUSTON DURRANT, T.; MAURI, A. (eds.): European Atlas of Forest Tree Species. pp. e012d59+. Publ. Off. EU, Luxembourg,

ALEXANDER, E.B.; 1989. Bulk density equations for southern Alaska soils. *Can J Soil Sci* 69 177–180.

ALÍA, R.; GARCÍA DEL BARRIO, J.M.; IGLESIAS, S.; MANCHA, J.A.; DE MIGUEL, J.; NICOLÁS, J.L.; PÉREZ, F.; SÁNCHEZ DE RON, D.; 2009. Regiones de Procedencia de especies forestales en España. Ministerio de Medio Ambiente y Medio Rural y marino. Organismo Autónomo Parques nacionales. Madrid.

ALÍA, R.; MARTÍN, S.; DE MIGUEL, J.; GALERA, R.; AGÚNDEZ, D.; GORDO, J. SALVADOR, L.; CATALÁN, G.; GIL, A.; 1996. Regiones de procedencia *Pinus pinaster* Aiton. Dirección General de Conservación de la Naturaleza, Madrid.

ALÍA, R.; MORO, J.; DENIS, J.B.; 1997. Performance of *Pinus pinaster* provenances in Spain: interpretation of the genotype by environment interaction. *Can J For Res* 27:1548–1559.

ÁLVAREZ-ÁLVAREZ, P.; AFIF, E.; CÁMARA-OBREGÓN, A.; CASTEDO-DORADO, F.; BARRIO-ANTA, M.; 2011. Effects of foliar nutrients and environmental factors on site productivity in *Pinus pinaster* Ait. Stands in Asturias (NW Spain). *Ann For Sci* 68:497–509.

ARIAS-RODIL, M.; BARRIO-ANTA, m.; DIÉGUEZ-ARANDA, U.; 2016. Developing a dynamic growth model for maritime pine in Asturias (NW Spain): comparison with nearby regions. *Ann For Sci* 73(2): 297–320.

BARÁ, S.; TOVAL, G.; 1983. Calidad de estación del *Pinus pinaster* Ait. en Galicia. INIA. Serie: Recursos Naturales, 24. Madrid.

BEDE-FAZEKAS, A.; LEVENTE HORVÁTH, K.M.; 2014. Impact of climate change on the potential distribution of Mediterranean pines. Quarterly J. Hungarian Meteorol Serv 118:41–52.

BRAVO-OVIEDO, A.; ROIG, S.; BRAVO, F.; MONTERO, G.; DEL RÍO, M.; 2011. Environmental variability and its relationship to site index in Mediterranean maritime pine. Forest Syst 20(1):50–64.

BREIMAN, L.; 2001. Random forests. Mach Learn 45 (1):5–32.

CASTAÑO-SANTAMARÍA, J.; LÓPEZ-SÁNCHEZ, C.A.; OBESO, J.R.; BARRIO-ANTA, M.; 2019. Modelling and mapping beech forest distribution and site productivity under different climate change scenarios in the Cantabrian Range (North-western Spain). For Ecol Manage 450: 117488.

CHAUDHARI, P.R.; AHIRE, D.V.; AHIRE, V.D.; CHKRAVARTY, M.; MAITY, S.; 2013. Soil bulk density as related to soil texture, organic matter content and available total nutrients of Coimbatore soil. Int J Sci Res 3 (2): 1–8.

CLUTTER, J.; FORTSON, J.; PIENAAR, L.; BRISTER, H.; BAYLEY, R.; 1983. Timber management: a quantitative approach. John Wiley & Sons. New York.

CONRAD, O.; BECHTEL, B.; BOCK, M.; DIETRICH, H.; FISCHER, E.; GERLITZ, L.; WEHBERG, J.; WHICHMANN, V.; BÖHNER, J.; 2015. System for automated geoscientific analyses (SAGA) v. 3.0.0. Geosci Model Dev 8: 1991–2007.

DE UÑA ÁLVAREZ, E.; 2001. El clima. En: PRECEDO LEDO, A.; SANCHO COMÍNS, J. (eds.). Atlas de Galicia. Tomo 1: Medio Natural. Sociedade para o Desenvolvemento Comarcal de Galicia. Xunta de Galicia.

DGCN; 2006. III Inventario Forestal Nacional (1997–2006). Principado de Asturias, Galicia y León. Dirección General de Conservación de la Naturaleza. Secretaría General de Medio Ambiente. Ministerio de Medio Ambiente. Madrid.

DIÉGUEZ-ARANDA, U.; ROJO ALBORECA, A.; CASTEDO-DORADO, F.; ÁLVAREZ-GONZALEZ, J.G.; BARRIO-ANTA, M.; CRECENTE-CAMPO, F.; GONZÁLEZ-GONZÁLEZ, J.M.; PÉREZ-CRUZADO, C.; RODRÍGUEZ-SOALLEIRO, R.; LÓPEZ-SÁNCHEZ, C.A.; BALBOA-MURIAS, M.A.; GORGOSO VARELA, J.J.; SÁNCHEZ-RODRÍGUEZ, F.; 2009. Herramientas selvícolas para la gestión forestal sostenible en Galicia. Xunta de Galicia. 259 páginas. Santiago de Compostela.

EIMIL-FRAGA, C.; RODRÍGUEZ-SOALLEIRO, R.; SÁNCHEZ-RODRÍGUEZ, F.; PÉREZ-CRUZADO, C.; ÁLVAREZ-RODRÍGUEZ, E.; 2014. Significance of bedrock as a site factor determining nutritional status and growth of maritime pine. Forest Ecol Manag 331:19–24.

FIELDING, A.; BELL, J.; 1997. A review of methods for the assessment of prediction errors in conservation presence/absence models. *Environ Conserv* 24, 38–49.

FONTES, L.; TOMÉ, M.; THOMPSON, F.; YEOMANS, A.; SALES, L.J.; SAVILL, P.; 2003. Modelling the Douglas-fir (*Pseudotsuga menziesii* (Mirb.) Franco) site index from site factors in Portugal. *Forestry* 76:491–507.

GANDULLO, J.M.; SÁNCHEZ PALOMARES, O.; 1994. Estaciones ecológicas de los pinares españoles. MAPA-ICONA. 188 páginas. Madrid.

GRIGAL, D.F.; VANCE, E.D.; 2000. Influence of soil organic matter on forest productivity. *NZ J Forestry Sc* 30(1/2): 169–205.

GUISAN, A.; ZIMMERMANN, N.E.; 2000. Predictive habitat distribution models in ecology. *Ecol Model* 135:147–186.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I.H.; 2009. The WEKA data mining software: An update. *SIGKDD Explorations* 11 (1): 10–18.

HARRIS, R.M.B.; GROSE, M.R.; LEE, G.; BINDOFF, N.L.; PORFIRIO, L.L.; FOX-HUGHES, P.; 2014. Climate projections for ecologists. *WIREs Clim Change* 5: 621–637.

HENGL, T.; MENDES DE JESUS, J.; HEUVELINK, G.B.M.; RUIPEREZ GONZALEZ, M.; KILIBARDA, M.; BLAGOTIC, A.; SHANGGUAN, W.; WRIGHT, M.N.; GENG, X.; BAUER-MARSCHALLINGER, B.; GUEVARA, M.A.; VARGAS, R.; MACMILLAN, R.A.; BATJES, N.H.; LEENARS, J.G.B.; RIBEIRO, E.; WHEELER, I.; MANTEL S.; KEMPEN, B.; 2017. SoilGrids250m: global gridded soil information based on machine learning. *PLoS ONE* 12 (2), e0169748.

HIJMANS, R.J.; CAMERON, S.E.; PARRA, J.L.; JONES, P.; JARVIS, A.; 2005. Very high resolution interpolated climate surfaces for global land areas. *Int J Climatol* 25:1965–1978.

IGME; 2015a. Mapa Geológico de España a escala 1:200.000. Instituto Geológico y Minero de España, Ministerio de Ciencia, Innovación y Universidades. Madrid.

IGME; 2015b. Mapa Geológico de la Península Ibérica, Baleares y Canarias a escala 1:1.000.000. Instituto Geológico y Minero de España, Ministerio de Ciencia, Innovación y Universidades. Madrid.

IPCC; 2013. *Climate Change 2013: The physical science basis. Contribution of working group I to the fifth assessment report of the Intergovernmental Panel of Climate Change.* Cambridge University Press. Cambridge. New York.

LATTA, G.; TEMESGEN, H.; BARRETT, T.M.; 2009. Mapping and imputing potential productivity of Pacific Northwest forests using climate variables. *Can J For Res* 39: 1197–1207.

MADRIGAL COLLAZO, A.; ÁLVAREZ GONZÁLEZ, J.G.; RODRÍGUEZ SOALLEIRO, A.; ROJO ALBORECA, A.; 1999. Tablas de producción para los montes españoles. Fundación Conde de Valle de Salazar. 253 páginas. Madrid.

- MAPA; 2019. Anuario de Estadística Forestal 2019. Ministerio de Agricultura, Pesca y Alimentación. Madrid.
- NICOLÁS, A.; GANDULLO, J.M.; 1967. Ecología de los pinares españoles. I *Pinus pinaster* Ait. Instituto Forestal de Investigaciones y Experiencias (IFIE). 311 páginas. Madrid.
- OLIVEIRA, A.C.; PEREIRA, J.S.; CORREIA, A.V.; 2000. A silvicultura do pinheiro bravo. Centro Pinus. 111 páginas. Portugal.
- PÉRIÉ, C.; OUIOMET, R.; 2008. Organic carbon, organic matter and bulk density relationships in boreal forest soils. *Can J Soil Sci* 88 (3): 315–325.
- ROMANYÀ, J.; VALLEJO, V.R.; 2004. Productivity of *Pinus radiata* plantation in Spain in response to climate and soil. *For Ecol Manage* 195:177–189.
- RYAN, T.P.; 1997. Modern regression methods. John Wiley & Sons. 553 páginas. Nueva York.
- SAKIN, E.; 2012. Organic carbon organic matter and bulk density relationships in arid-semi arid soils in Southeast Anatolia region. *Afr J Biotechnol* 11(6):1373–1377.
- SKOVSGAARD, J.P.; VANCLAY, J.K.; 2008. Forest Site Productivity: A Review of the Evolution of Dendrometric Concepts for Even-Aged Stands. *Forestry* 81:13–31.
- THOMSON, A.M.; CALVIN, K.V.; SMITH, S.J.; KYLE, G.P.; VOLKE, A.; PATEL, P.; DELGADO-ARIAS, S.; BOND-LAMBERTY, B.; WISE, M.A.; CLARKE, L.E.; EDMONDS, J.A. 2011. RCP 4.5: a pathway for stabilization of radiative forcing by 2100. *Clim Change* 109:77–94.
- THUILLER, W.; 2003. BIOMOD: optimising predictions of species distributions and projecting potential future shifts under global change. *Global Change Biol.* 9: 1353–1362.
- VANCLAY, J.K.; 1994. Modelling Forest Growth and Yield: Applications to Mixed Tropical Forests. CAB International. 336 páginas. Wallingford.