



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



Relación entre NDVI y la biomasa y productividad forestal en Andalucía

DIAZ HERRAIZ, A^{1,2}, MESAS CARRASCOSA F. J.³, SALAZAR ZARZOSA P¹, RUIZ-BENITO P⁴, y VILLAR MONTERO R.¹

¹ Área de Ecología, Dpto. Botánica, Ecología y Fisiología Vegetal, Facultad de Ciencias, Universidad de Córdoba

² Campus Humaitá, Instituto Federal de Ciéncia e Tecnología do Amazonas, IFAM

³ Ing. Gráfica y Geomática. E.T.S. Ing. Agronómica y de Montes, Universidad de Córdoba

⁴ Departamento de Ecología, Universidad de Alcalá

Resumen

El desarrollo de servicios de computación en la nube (cloud computing) ha permitido de forma rápida el acceso y procesamiento de grandes volúmenes de datos satelitales. La información derivada de imágenes satélite como los índices de vegetación NDVI (Normalized Difference Vegetation Index) o SAVI (Soil Adjusted Vegetation Index) son herramientas que permiten estimar la actividad vegetal en la superficie terrestre auxiliando la toma de decisiones. El objetivo de nuestro trabajo consistió en modelar la biomasa y la productividad forestal en Andalucía durante dos etapas del Inventario Forestal Nacional (IFN₂ e IFN₃) usando valores del NDVI a partir de escenas de Landsat 5 y 7, índice sintético obtenido mediante acceso gratuito a la plataforma Google Earth Engine de computación en la nube. Los modelos generales para la biomasa y la productividad muestran resultados modestos, aunque significativos ($R^2=0,34$ y 0.27 respectivamente) destacando la mejora de los modelos específicos como en los *Pinus* donde *P. halepensis* alcanzó valores de $R^2=0,56$ mientras que *Quercus* no superó el $R^2=0,4$ de *Q. suber*. En los modelos de productividad específicos la R^2 disminuye en la mayoría de los modelos a excepción de *Q. ilex* donde alcanza un $R^2=0,39$; se aproximando del $R^2=0,41$ de *P. halepensis*, mejor modelo para esta variable. Los modelos diseñados, aunque no consiguen captar mucha de la variabilidad mostrada por la biomasa y la productividad forestal pueden ayudar a predecir la variación espaciotemporal en el territorio andaluz y podrían ser utilizados para la respuesta futura ya posibles cambios en la distribución de especies.

Palabras clave

Teledetección, cloud computing, inventario forestal, biomasa forestal, productividad forestal.

1. Introducción

Los bosques albergan gran parte de la biodiversidad suministrando simultáneamente a la sociedad importantes servicios ecosistémicos como la regulación de gases atmosféricos, temperatura y humedad, la protección al suelo contra la erosión, la producción primaria de biomasa, la mejora de la calidad del agua, y los servicios sociales y culturales ofrecidos a la sociedad. Por todo esto, su conservación es fundamental para el bienestar presente y futuro del ser humano (Guzmán Álvarez et al., 2012; Jurado et al., 2020; Maestre et al., 2012; Ruiz-Benito et al., 2013). Sin embargo, muchos los estudios ya proyectan los cambios en los bosques debido a los escenarios del cambio climático (Berdugo et al., 2020). En España, aunque las especies mediterráneas como la encina poseen gran variabilidad intraespecífica permitiendo adaptación a condiciones de estrés hídrico (Benito Garzón et al., 2011; Forner et al., 2018; Gentilesca et al., 2017; Salazar et al., 2021), un aumento de la aridez (estrés hídrico) podría provocar la desaparición o reducción de las especies más sensibles (Aranda et al., 2014; Aguirre et al., 2019; Cherif et al., 2020).

En España, a lo largo de los últimos años diversas variables relativas al estado de los bosques como densidad, y biomasa han sido estudiados periódicamente gracias al denominado Inventario Forestal Nacional (IFN) (Aguirre et al., 2019; González-Díaz et al., 2019; Ruiz-Benito and García-Valdés, 2016). El IFN se realiza cada década aproximadamente desde el año 1966/75, sin embargo, cada edición su ejecución es demorada y demanda una gran cantidad de recursos. Por este motivo, cada vez más se hace necesario el uso de herramientas que de forma remota, rápida y barata, obtengan información continua en el espacio y tiempo sobre la composición y crecimiento del bosque (Aguirre et al., 2019; Basin, 2020; García et al., 2010; Mulder et al., 2019; Pettorelli et al., 2018).

Por otro lado, la biomasa forestal ha sido ampliamente utilizada para medir la cantidad de materia acumulada en forma de masa por unidad de superficie ($Mg\ ha^{-1}$) (Montero et al., 2005; Sar and Further, 2020). Por otro lado, la variación de la biomasa a lo largo del tiempo se define como productividad forestal ($Mg\ ha^{-1}\ año^{-1}$). La productividad forestal permite cuantificar la rentabilidad del bosque y los servicios económicos que ofrece. Para poder comprender el comportamiento de la productividad de los bosques se hace imprescindible el conocimiento del efecto de diversas variables climáticas, topográficas, edáficas y bióticas sobre las masas forestales a lo largo del tiempo (Aguirre et al., 2019; Guzmán Álvarez et al., 2012; Schneider et al., 2017).

Con el objetivo de modelar y predecir en el espacio y el tiempo el efecto del cambio climático sobre el funcionamiento de los ecosistemas agrícolas y forestales, se han desarrollado metodologías de alta resolución espaciotemporal usando la teledetección. Así, por ejemplo, se ha conseguido relacionar los índices espectrales de vegetación como el NDVI (*Normalized Difference Vegetation Index*) con distintas variables como la aridez, la diversidad, crecimiento y distribución de especies o la cobertura vegetal (Banti et al., 2019; Margalef-Marrase et al., 2020; Pérez Navarro et al., 2019; Pettorelli et al., 2018).

Sin embargo, para la obtención y procesamiento de grandes volúmenes de datos en el espacio y tiempo que ayuden a entender las dinámicas temporales y espaciales es necesario acudir a herramientas tecnológicas recientes como la computación en la nube como *Google Earth Engine* (GEE), la cual permite realizar en periodos reducidos de tiempo tareas de procesamiento de grandes volúmenes de datos espaciales respaldando la toma de decisiones en tiempo real.

2. Objetivos

El objetivo principal del trabajo busca modelar la biomasa y productividad forestal con variables abióticas y espectrales en los bosques andaluces partiendo los datos del Inventario Forestal Nacional en su segunda y tercera edición (1995/2007).

Como objetivos específicos:

- Modelar la biomasa y la productividad forestal tanto para toda la masa forestal andaluza como para las 6 especies más abundantes (*Quercus ilex*, *Q. suber*, *Pinus pinea*, *P. halepensis*, *P. nigra* y *P. pinaster*).
- Estudiar las relaciones de las variables (espectrales, climáticas, edáficas y topográficas) en los modelos de la biomasa y la productividad forestal obtenidos.

3. Metodología

3.1 Obtención de datos.

Los datos bióticos (biomasa, productividad, densidad y especie forestal) de cada parcela fueron obtenidos de la base de datos del IFN (<https://www.mapa.gob.es/>); más de 7000 parcelas del IFN fueron consultadas a lo largo de todo el territorio andaluz (Figs. 1A y 1B).

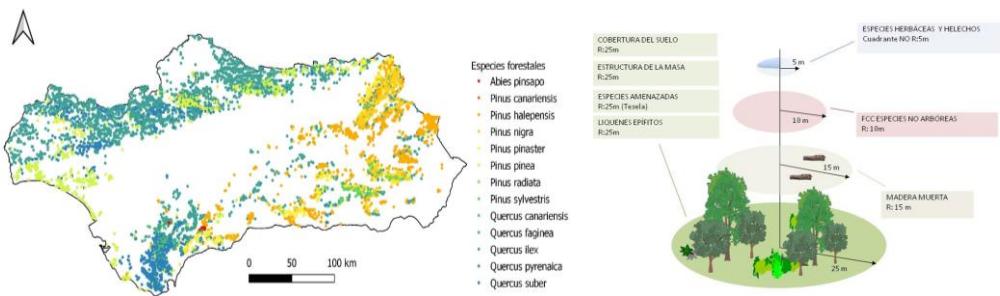


Figura 1. A) distribución de puntos del IFN en Andalucía. B) Detalle zoneamiento en parcela del IFN (Alberdi 2017).

Los datos abióticos climáticos como el índice de aridez de Martonne (relación entre precipitación y temperatura, Salazar et al., 2021) fueron obtenidos partiendo de series climáticas históricas del WorldClim (1.4). Además de la aridez promediada a lo largo de los últimos 50 años, fueron obtenidos valores medios anuales de la humedad del suelo, radiación y evapotranspiración efectiva y potencial. Variables relativas a la precipitación y temperatura fueron descartadas por estar ya relacionadas con el índice de aridez utilizado. Para la construcción de los modelos de productividad forestal estas variables se promediarán entre los períodos del IFN.

Los datos edáficos y topográficos fueron obtenidos en forma de ráster para toda la región mediante acceso a la red REDIAM ([ps://descargasrediam.cica.es](http://descargasrediam.cica.es)). Se hizo una selección de todas las variables edáficas disponibles en la REDIAM (junta de Andalucía) retirando aquellas que mostraran elevada colinealidad ($VIF > 0.8$). Siendo así fueron seleccionadas nueve variables de entre las cuales están: el contenido en materia orgánica y nitrógeno superficial, la concentración en arena y de tierra fina, el pH, la profundidad del suelo, la capacidad de intercambio catiónico, la saturación de bases y el porcentaje de saturación del suelo. En las variables topográficas, además de la elevación, al pendiente y el sombreado fueron incluidas en los modelos.

Por último, los datos del NDVI fueron calculados y descargados desde la plataforma del GEE (<https://earthengine.google.com>) para cada una de las parcelas del IFN para todo el periodo que comprende la realización de la segunda y tercera edición. Mas de 3000 escenas de la constelación Landsat (LA05 y LA07) fueron consultadas. Como métrica utilizada para los modelos de biomasa forestal se optó por usar la media anual para cada punto (NDVI diff), mientras que para la construcción de los modelos de productividad se promedió el valor de NDVI medio entre IFNs y además introdujo una nueva variable espectral que refleja el acumulado del NDVI a lo largo del periodo entre IFNs (NDVI sum).

Todas las variables explicativas fueron estandarizadas para posteriormente aplicar modelos lineales (LM). En la selección y construcción del modelo se aplicó una inferencia multimodal (*multimodel inference*) obteniendo el modelo más parsimonioso para cada caso.

Para estudiar las relaciones entre las variables se utilizaron modelos lineales mediante uso del software libre R y Rstudio.

4. Resultados

4.1 Modelos de biomasa y productividad forestal.

Los modelos con toda la masa forestal andaluza fueron significativos pero modestos $R^2=0.34$ y $R^2=0.27$ para la biomasa y la productividad forestal (Fig. 2A y B). El rango de las predicciones es menor que el de las observaciones para los dos modelos. Aunque en ambos modelos la tendencia es positiva, ambos subestiman las predicciones. El modelo de la biomasa parecen subestimar gran

número de parcelas a partir de 50 mg ha^{-1} mientras que el modelo de productividad forestal hace lo mismo a partir de $2 \text{ Mg ha}^{-1} \text{ año}^{-1}$.

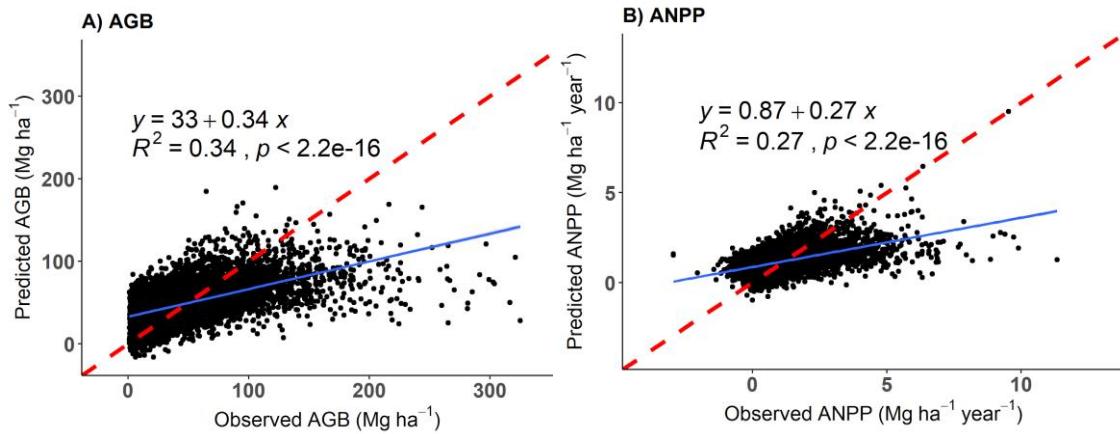


Figura 2. Predicción de los modelos para la biomasa (A) y la productividad forestal (B).

La predicción de los modelos fue proyectada sobre el espacio geográfico en estudio parece que los mayores errores parecen estar localizados en áreas montañosas como la Sierra de Cazorla (Figs. 4A y B).

Cuando los modelos son específicos de cada especie forestal, los modelos de la biomasa mejoran notablemente donde *P. halepensis* alcanza el mayor valor con $R^2 = 0.55$ (Fig. 3 y Tabla 1). Todos los modelos de *Pinus* spp. superan al modelo general, sin embargo, en *Quercus*, mientras que *Q. suber* supera el modelo general con un $R^2 = 0.4$, *Q. ilex* apenas llega a 0.2. La mayoría de los modelos de productividad forestal específicos mejoran sus índices de correlación frente al modelo general a excepción de *Q. suber* con un $R^2 = 0.23$. Los modelos de *Pinus* (Fig. 3 y Tabla 1) continúan mostrando los mejores índices con *P. halepensis* ($R^2 = 0.41$).

Todos los modelos específicos (Fig. 3) sea para la biomasa o la productividad forestal se muestran significativos con una tendencia positiva, aunque el valor de R^2 no sea el deseado.

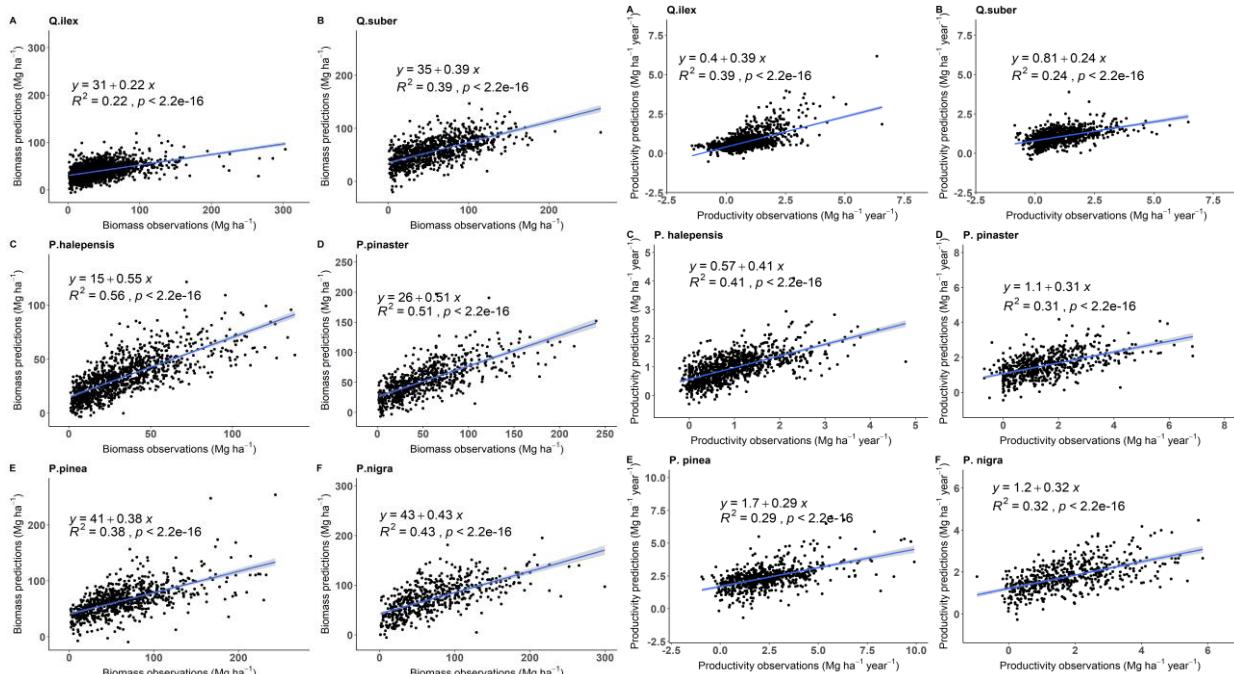


Figura 3. Predicción de los modelos específicos para biomasa y productividad forestal.

Atendiendo al error cuadrático medio (RMSE, tabla 1), los modelos de la biomasa específicos a excepción de *P. pinea* y *P. nigra* demuestran ser mejores que el modelo general, en este sentido *P. halepensis* continúa siendo el mejor modelo con un RMSE = 16.55 Mg ha⁻¹. Em los modelos específicos de la productividad forestal, apenas *P. halepensis* y *Q. ilex* mejoran el error del modelo general con RMSE = 0.55 y 0.57 Mg ha⁻¹año⁻¹ respectivamente, siendo *P. pinea* el modelo que peor desempeño parece tener (RMSE = 1.42 Mg ha⁻¹año⁻¹).

Tabla 1. Cuadro resumen de los modelos de biomasa y productividad forestal.

		Biomasa			Productividad		
	N	R ²	Media	RMSE (Mg ha ⁻¹)	R ²	Media	RMSE (Mg ha ⁻¹ año ⁻¹)
General	7297	0.34	51.16	33.08	0.27	1.20	0.85
Q ilex	2276	0.22	40.15	26.28	0.38	0.67	0.55
Q suber	859	0.39	58.03	30.48	0.23	1.05	0.85
P halepensis	1017	0.55	34.91	16.55	0.41	0.97	0.57
P pinea	683	0.37	69.38	35.37	0.29	2.39	1.42
P pinaster	639	0.51	55.05	27.80	0.3	1.58	1.07
P nigra	533	0.41	75.22	39.07	0.32	1.81	1.00

RMSE: Root Mean Squared Error (error cuadrático medio), N: número de observaciones.

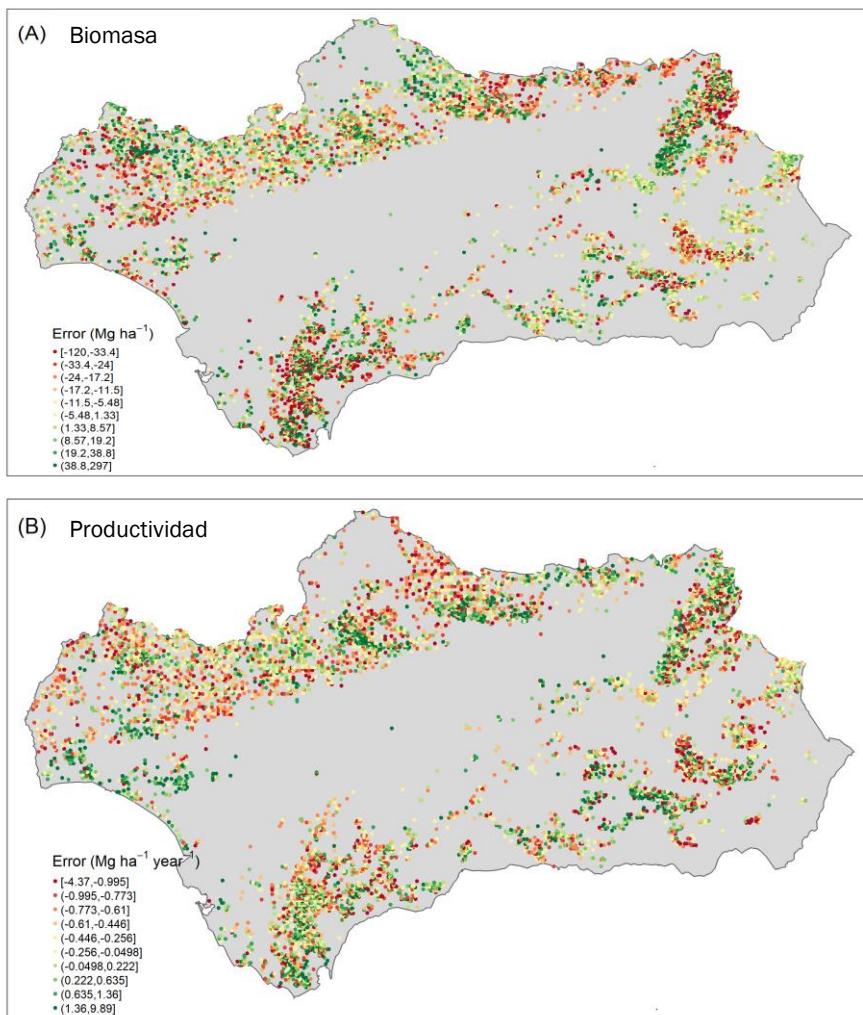


Figura 4. Distribución geográfica de los modelos para la biomasa (A) y la productividad forestal (B).

4.2 Importancia de las variables dentro de los modelos de biomasa y productividad forestal.

Los estimates estandarizados de las variables muestran el peso de cada variable dentro de cada modelo (tabla 2 y 3).

Tanto para los modelos de biomasa como para los modelos de productividad la variable densidad (dens) y diferencia de la densidad (dens diff) muestran significancia y relevancia, así como las variables espectrales (NDVI, NDVI sum y NDVI diff).

En el modelo general de la biomasa el NDVI aparece la variable más importante mientras que en el modelo general de la productividad lo es la densidad (dens diff). Otra variable que muestra su importancia negativa en la mayoría de los modelos es la aridez, mientras que las variables edáficas muestran su relevancia sobre todo en el modelo general de productividad (tabla 3), y las variables topográficas lo hacen sobre el de biomasa.

En los modelos específicos de biomasa (tabla 2), dentro de las variables climáticas, aunque la radiación es la que aparece en la mayoría de los modelos (de forma positiva en las especies *Quercus*), la aridez continúa siendo la que mayor magnitud negativa muestra en los modelos, ya en las variables edáficas la cantidad de materia orgánica aparece en la mayoría de los modelos positivamente, la profundidad de los suelos también se destaca sobre los dos *Quercus* aunque de

forma opuesta para cada una de ellas. En lo que se refiere a las variables topográficas, cabe destacar la relevancia de forma negativa de la pendiente en los dos especies de *Quercus*.

Tabla 2. Estimate y significancia de las variables de los modelos de biomasa.

	Var	General	<i>P halepensis</i>	<i>P nigra</i>	<i>P pinaster</i>	<i>P pinea</i>	<i>Q ilex</i>	<i>Q suber</i>
Espectral	NDVI	15.62***	9***	17.97***	13.81***	14.57***	10.4***	13.4***
Bióticas	Dens	12.58***	12.06***	16.87***	16.97***	20.3***	6.24***	8.66***
Climático	Arid	-3.32***			-7.01***		-3.86***	
	EVPE			-5.76**				
	EVPP			-6.27**				
	HS		1.2*		-2.94*		3.03***	
	Rad				-4.99***		3.49***	2.8*
Edáfico	TF	3.5***					1.94**	3.6**
	AR		-2.39***	-9.36***				
	CIC					3.85**		4.4**
	MO	5.02***	2.46***	10.46***	6.35***			5.5***
	pH		-1.92**				-2.08**	4.4**
	P							
	PSB	-1.91***			-3.72**			-3.8**
	Cond	-1.4***					-2.27***	-2.7*
Topográfico	N	1.76***				-3.58*		
	Somb	1.21**	1.88***					3.4**
	Pend	-2.35***					-2.62***	-4.3***
Topográfico	Elev					-6.12***		5.3***

EVPE: evapotranspiración efectiva, EVPP: evapotranspiración de referencia, HS: humedad del suelo, Rad: radiación del suelo, TF: tierra fina, AR: arena, CIC: capacidad de intercambio catiónico, MO: materia orgánica, P: profundidad del suelo, PSB: porcentaje de saturación de bases, Cond: conductividad hidráulica, N: nitrógeno, Somb: sombreadamiento, Pend: pendiente, Elev: elevación.

Cuando se analiza el peso de las variables sobre los modelos específicos de productividad (tabla 3), el NDVI es la variable más importante para los modelos de productividad en *Quercus*, mientras que los *Pinus* sólo lo es para *P. nigra*. Dentro de las variables climáticas la aridez aparece como la variable de mayor presencia en los modelos, incluso en el modelo general; siendo la que mayor magnitud negativa presenta en los modelos donde aparece. En las variables edáficas, destaca el porcentaje de saturación de bases como variable negativa en la gran parte de los

modelos, también se destaca positivamente la profundidad en las dos especies de *Quercus*. La profundidad se destaca positivamente en los *Quercus*, mientras que en *Pinus* apenas el porcentaje de tierra fina (TF) aparece negativamente para *P. halepensis* y *P. nigra* mientras que lo hace positivamente para *P. pinea*.

Tabla 3. Estimate y significancia de las variables de los modelos de productividad.

	var	General	<i>P halepensis</i>	<i>P nigra</i>	<i>P pinaster</i>	<i>P pinea</i>	<i>Q ilex</i>	<i>Q suber</i>
Espectral	NDVIdiff	0.1***	0.05*	0.33***	0.3***	0.23***	0.03*	
	NDVI sum	0.35***	0.27***	0.45***	0.47***	0.5***	0.1***	0.27***
Biótico	dens diff	0.4***	0.28***	0.4***	0.28***	0.62***	0.4***	0.23***
Climático	EVPP					0.3***		
	HS						0.03*	
	Rad						-0.04**	
	Arid	-0.19***	-0.08***	-0.14**	-0.3***		-0.1***	
Edáfico	TF		-0.07**	-0.13**	0.09*			0.12***
	AR	0.1***			-0.1*			
	CIC	-0.18***			-0.19***			
	MO	0.11***						0.16***
	pH	0.08***	-0.05*					
	P	0.06***	0.08***				0.032*	0.16***
	PSB	-0.05***		-0.14**	-0.16***		-0.02*	-0.15***
	Cond	-0.03*				-0.15*		-0.06*
	N	-0.04*		-0.14**			0.03*	
Topográfico	Somb							0.08**
	Elev				-0.13**			

EVPE: evapotranspiración efectiva, EVPP: evapotranspiración de referencia, HS: humedad del suelo, Rads: radiación del suelo, TF: tierra fina, AR: arena, CIC: capacidad de intercambio catiónico, MO: materia orgánica, P: profundidad del suelo, PSB: porcentaje de saturación de bases, Cond: conductividad hidráulica, N: nitrógeno, Somb: sombreadimiento, Pend: pendiente.

5. Discusión

Aunque los resultados muestran modelos modestos, estos pueden explicar la respuesta de la biomasa y la productividad forestal de los bosques andaluces frente a variables bióticas, no bióticas y espectrales. Hay consenso en que variables de detección remota son opciones serias a la hora de construir modelos espaciotemporales que monitorean el estado de los bosques, reduciendo los recursos para obtener estos datos en campo (Durante et al., 2019; Pettorelli et al., 2018).

Todos los modelos mostraron la importancia del NDVI (Xue y Su, 2017), de la densidad (Astigarraga et al., 2020; Salazar et al., 2021) y de la aridez (Gómez-Aparicio et al., 2011; Khoury y Coomes, 2020). Aunque con menor influencia, los factores edáficos como la materia orgánica (MO) y la saturación de bases (BS) también pueden afectar la biomasa y la productividad (Grijal y Vance, 2000).

Andalucía es una región heterogénea sometida a un elevado número de variables y especies, motivo por el cual nuestros modelos generales alcanzan R^2 relativamente modestos, sin embargo, los valores de RMSE pueden ser comparados con otros estudios (Domingo et al., 2018; García et al., 2009).

El error de nuestros modelos sugiere que las parcelas con biomasa y productividad altas (más de 100 Mg ha⁻¹ y 2 Mg ha⁻¹ año⁻¹, respectivamente) a menudo son subestimadas, posiblemente debido al número reducido de este tipo de parcelas. Es posible que las parcelas con vegetación densa saturen la señal espectral dificultando su relación con la biomasa (Santos et al., 2016; Liu et al., 2012). Es importante notar que las parcelas subestimadas o sobreestimadas parecen estar distribuidas uniformemente en la zona de estudio. Posiblemente otras variables no consideradas en este estudio como las antrópicas (Maciel et al., 2021; Mayer et al., 2020), pueden estar afectando a los modelos.

La mayoría de los estudios buscan modelar la biomasa o la productividad a través de variables remotas como las espectrales (Santos et al., 2016) o climáticas (Gómez-Aparicio et al., 2011), sin embargo, no tienen en cuenta el peso de las variables con un impacto directo en la dinámica de disponibilidad de agua y fertilidad como las edáficas o topográficas (Blackard et al., 2008; Muller-Landau et al., 2020).

6. Conclusiones

Los datos espectrales (NDVI) se muestran necesarios para modelar la biomasa forestal y la productividad en los bosques mediterráneos. La densidad forestal como era de esperar muestra una relación directa y positiva tanto con la biomasa como con la productividad en todos los modelos y especies. Nuestros resultados mostraron que las variables edáficas y topográficas también deben usarse para modelar la biomasa y la productividad del bosque, y pueden ser especialmente importantes para algunas especies. Por otro lado, la aridez continúa siendo un factor que afecta negativamente a la biomasa y la productividad.

7. Agradecimientos

Agradecer el apoyo financiero proporcionado por el proyecto *Ecología funcional de los bosques andaluces y predicciones sobre sus cambios futuros (For-Change)* (UCO-FEDER 18 REF 27943 MOD B), el proyecto *Funcionalidad y servicios ecosistémicos de los bosques andaluces y normarroquíes: relaciones con la diversidad vegetal y edáfica ante el cambio climático* (P18-RT-3455) de la Junta de Andalucía (España), del proyecto español MEC DIVERBOS (CGL2011-30285-C02-02), ECO-MEDIT (CGL2014-53236-R) y ForFun (Ref. PID2020-115809RB-I00) y fondos FEDER. Agradecemos al MAPA (Ministerio de Agricultura, Pesca y Alimentación) y MITECO (Ministerio de Transición Ecológica) el acceso y la disponibilidad en libre acceso del Inventario Forestal Español.

8. Bibliografía

AGUIRRE, A., DEL RÍO, M., CONDÉS, S., 2019. Productivity estimations for monospecific and

mixed pine forests along the Iberian Peninsula aridity gradient. *Forests* 10. <https://doi.org/10.3390/f10050430>

ALBERDI, I., VALLEJO, R., ÁLVAREZ-GONZÁLEZ, J.G., CONDÉS, S., GONZÁLEZ-FERREIRO, E., GUERRERO, S., HERNÁNDEZ, L., MARTÍNEZ-JAUREGUI, M., MONTES, F., OLIVEIRA, N., PASALODOS-TATO, M., ROBLA, E., RUIZ-GONZÁLEZ, A.D., SÁNCHEZ-GONZÁLEZ, M., SANDOVAL, V., SAN MIGUEL, A., SIXTO, H., CAÑELLAS, I., 2017. The multi-objective Spanish National Forest Inventory. *For. Syst.* 26, 1–17. <https://doi.org/10.5424/fs/201726-10577>

ASTIGARRAGA, J., ANDIVIA, E., ZAVALA, M.A., GAZOL, A., CRUZ-ALONSO, V., VICENTE-SERRANO, S.M., RUIZ-BENITO, P., 2020. Evidence of non-stationary relationships between climate and forest responses: Increased sensitivity to climate change in Iberian forests. *Glob. Chang. Biol.* 26, 5063–5076. <https://doi.org/10.1111/gcb.15198>

BANTI, M., KIACHIDIS, K., GEMITZI, A., 2019. Estimation of spatio-temporal vegetation trends in different land use environments across Greece. *J. Land Use Sci.* 14, 21–36. <https://doi.org/10.1080/1747423X.2019.1614687>

BASIN, A., 2020. Forest cover changes, Advanced Remote Sensing. <https://doi.org/10.1016/b978-0-12-815826-5.00025-8>

BENITO GARZÓN, M., Alía, R., Robson, T.M., Zavala, M.A., 2011. Intra-specific variability and plasticity influence potential tree species distributions under climate change. *Glob. Ecol. Biogeogr.* 20, 766–778. <https://doi.org/10.1111/j.1466-8238.2010.00646.x>

BERDUGO, M., DELGADO-BAQUERIZO, M., SOLIVERES, S., HERNÁNDEZ-CLEMENTE, R., ZHAO, Y., GAITÁN, J.J., GROSS, N., SAIZ, H., MAIRE, V., LEHMAN, A., RILLIG, M.C., SOLÉ, R. V., MAESTRE, F.T., 2020. Global ecosystem thresholds driven by aridity. *Science* (80-.). 367, 787–790. <https://doi.org/10.1126/science.aay5958>

CHERIF, S., EZZINE, O., KHOUJA, M.L., NASR, Z., 2020. A comparison of the physiological responses of three pine species in different bioclimatic zones in Tunisia. *Appl. Ecol. Environ. Res.* 18, 1–13. https://doi.org/10.15666/aeer/1801_001013

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. <https://doi.org/10.3390/f9040158>

DURANTE, P., MARTÍN-ALCÓN, S., GIL-TENA, A., ALGEET, N., TOMÉ, J.L., RECUERO, L., PALACIOS-ORUETA, A., OYONARTE, C., 2019. Improving aboveground forest biomass maps: From high-resolution to national scale. *Remote Sens.* 11. <https://doi.org/10.3390/rs11070795>

FORNER, A., VALLADARES, F., BONAL, D., GRANIER, A., GROSSIORD, C., ARANDA, I., 2018. Extreme droughts affecting Mediterranean tree species' growth and water-use efficiency: The importance of timing. *Tree Physiol.* 38, 1127–1137.

<https://doi.org/10.1093/treephys/tpy022>

GARCÍA, M., RIAÑO, D., CHUVIECO, E., DANSON, F.M., 2010. Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. *Remote Sens. Environ.* 114, 816–830. <https://doi.org/10.1016/j.rse.2009.11.021>

GENTILESCA, T., CAMARERO, J.J., COLANGELO, M., NOLÈ, A., RIPULLONE, F., 2017. Drought-induced oak decline in the western mediterranean region: An overview on current evidences, mechanisms and management options to improve forest resilience. *IForest* 10, 796–806. <https://doi.org/10.3832/ifor2317-010>

GONZÁLEZ-DÍAZ, P., RUIZ-BENITO, P., RUIZ, J.G., CHAMORRO, G., ZAVALA, M.A., 2019. A multifactorial approach to value supporting ecosystem services in Spanish forests and its implications in a warming world. *Sustain.* 11. <https://doi.org/10.3390/su11020358>

GÓMEZ-APARICIO, L., GARCÍA-VALDÉS, R., RUÍZ-BENITO, P., ZAVALA, M.A., 2011. Disentangling the relative importance of climate, size and competition on tree growth in Iberian forests: Implications for forest management under global change. *Glob. Chang. Biol.* 17, 2400–2414. <https://doi.org/10.1111/j.1365-2486.2011.02421.x>

GRIGAL, D.F., VANCE, E.D., 2000. Influence of soil organic matter on forest productivity. *New Zeal. J. For. Sci.* 30, 169–205.

GUZMÁN ÁLVAREZ, J.R., VENEGAS TRONCOSO, J., SESEÑA RENGEL, A., SILLERO ALMAZÁN, M.L., ÁLVAREZ, J., RODRÍGUEZ, A., 2012. Biomasa forestal en Andalucía.

HERRAIZ, A.D., GRAÇA, P.M.L. DE A., FEARNSIDE, P.M., 2017. Amazonian flood impacts on managed Brazilnut stands along Brazil's Madeira River: A sustainable forest management system threatened by climate change. *For. Ecol. Manage.* 406, 46–52. <https://doi.org/10.1016/j.foreco.2017.09.053>

JURADO, J.M., RAMOS, M.I., ENRÍQUEZ, C., FEITO, F.R., 2020. The impact of canopy reflectance on the 3D structure of individual trees in a Mediterranean Forest. *Remote Sens.* 12, 1–21. <https://doi.org/10.3390/RS12091430>

KHOURY, S., COOMES, D.A., 2020. Resilience of Spanish forests to recent droughts and climate change. *Glob. Chang. Biol.* 26, 7079–7098. <https://doi.org/10.1111/gcb.15268>

LIU, F., QIN, Q., ZHAN, Z., 2012. A novel dynamic stretching solution to eliminate saturation effect in NDVI and its application in drought monitoring. *Chinese Geogr. Sci.* 22, 683–694. <https://doi.org/10.1007/s11769-012-0574-5>

MACIEL, E.A., MARTINS, V.F., DE PAULA, M.D., HUTH, A., GUILHERME, F.A.G., FISCHER, R., GILES, A., BARBOSA, R.I., CAVASSAN, O., MARTINS, F.R., 2021. Defaunation and changes in climate and fire frequency have synergistic effects on aboveground biomass loss in the Brazilian savanna. *Ecol. Model.* 454. <https://doi.org/10.1016/j.ecolmodel.2021.109628>

MAESTRE, F.T., QUERO, J.L., GOTELLI, N.J., ESCUDERO, A., OCHOA, V., DELGADO-

BAQUERIZO, M., GARCÍA-GÓMEZ, M., BOWKER, M.A., SOLIVERES, S., ESCOLAR, C., GARCÍA-PALACIOS, P., BERDUGO, M., VALENCIA, E., GOZALO, B., GALLARDO, A., AGUILERA, L., ARREDONDO, T., BLONES, J., BOEKEN, B., BRAN, D., CONCEIÇÃO, A.A., CABRERA, O., CHAIEB, M., DERAK, M., ELDRIDGE, D.J., ESPINOSA, C.I., FLORENTINO, A., GAITÁN, J., GABRIEL GATICA, M., GHILOUFI, W., GÓMEZ-GONZÁLEZ, S., GUTIÉRREZ, J.R., HERNÁNDEZ, R.M., HUANG, X., HUBER-SANNWALD, E., JANKJU, M., MIRITI, M., MONERRIS, J., MAU, R.L., MORICI, E., NASERI, K., OSPINA, A., POLO, V., PRINA, A., PUCHETA, E., RAMÍREZ-COLLANTES, D.A., ROMÃO, R., TIGHE, M., TORRES-DÍAZ, C., VAL, J., VEIGA, J.P., WANG, D., ZAADY, E., 2012. Plant species richness and ecosystem multifunctionality in global drylands. *Science* (80-). 335, 214–218. <https://doi.org/10.1126/science.1215442>

MARGALEF-MARRASE, J., PÉREZ-NAVARRO, M.Á., LLORET, F., 2020. Relationship between heatwave-induced forest die-off and climatic suitability in multiple tree species. *Glob. Chang. Biol.* 26, 3134–3146. <https://doi.org/10.1111/gcb.15042>

MAYER, M., PRESCOTT, C.E., ABAKER, W.E.A., AUGUSTO, L., CÉCILLON, L., FERREIRA, G.W.D., JAMES, J., JANDL, R., KATZENSTEINER, K., LACLAU, J.P., LAGANIÈRE, J., NOUVELLON, Y., PARÉ, D., STANTURF, J.A., VANGUELOVA, E.I., VESTERDAL, L., 2020. Influence of forest management activities on soil organic carbon stocks: A knowledge synthesis. *For. Ecol. Manage.* 466, 118127. <https://doi.org/10.1016/j.foreco.2020.118127> MONTERO, G., RICARDO RUIZ-PEINADO, MARTA, M., 2005. Monografía Forestal 13. Producción de Biomasa y fijación CO₂ por los bosques españoles. Instituto Nacional de Investigación y Tecnología Agraria y Alimentaria Ministerio de Educación y Ciencia.

MULDER, V.L., VAN ECK, C.M., FRIEDLINGSTEIN, P., ARROUAYS, D., REGNIER, P., 2019. Controlling factors for land productivity under extreme climatic events in continental Europe and the Mediterranean Basin. *Catena* 182, 104124. <https://doi.org/10.1016/j.catena.2019.104124>

MULLER-LANDAU, H.C., CUSHMAN, K.C., ARROYO, E.E., MARTINEZ CANO, I., ANDERSON-TEIXEIRA, K.J., BACKIEL, B., 2021. Patterns and mechanisms of spatial variation in tropical forest productivity, woody residence time, and biomass. *New Phytol.* 229, 3065–3087. <https://doi.org/10.1111/nph.17084> PÉREZ NAVARRO, M.Á., SAPES, G., BATLLORI, E., SERRA-DIAZ, J.M., ESTEVE, M.A., LLORET, F., 2019. Climatic Suitability Derived from Species Distribution Models Captures Community Responses to an Extreme Drought Episode. *Ecosystems* 22, 77–90. <https://doi.org/10.1007/s10021-018-0254-0>

PETTORELLI, N., SCHULTE TO BÜHNE, H., TULLOCH, A., DUBOIS, G., MACINNIS-NG, C., QUEIRÓS, A.M., KEITH, D.A., WEGMANN, M., SCHRODT, F., STELLMES, M., SONNENSCHEIN, R., GELLER, G.N., ROY, S., SOMERS, B., MURRAY, N., BLAND, L., GEIJZENDORFFER, I., KERR, J.T., BROSZEIT, S., LEITÃO, P.J., DUNCAN, C., EL SERAFY, G., HE, K.S., BLANCHARD, J.L., LUCAS, R., MAIROTA, P., WEBB, T.J., NICHOLSON, E., 2018. Satellite remote sensing of ecosystem functions: opportunities, challenges and way forward. *Remote Sens. Ecol. Conserv.* 4, 71–93. <https://doi.org/10.1002/rse2.59>

RUIZ-BENITO, P., GARCÍA-VALDÉS, R., 2016. Forest inventories for the study of patterns and processes in Ecology. *Ecosistemas* 25, 1–5. <https://doi.org/10.7818/ECOS.2016.25-3.01>

RUIZ-BENITO, P., HERRERO, A., ZAVALA, M., 2013. Vulnerabilidad de los bosques españoles frente al Cambio Climático: evaluación mediante modelos. Ecosistemas 22, 21–28. <https://doi.org/10.7818/ECOS.2013.22-3.04>

SALAZAR ZARZOSA, P., DIAZ HERRAIZ, A., OLMO, M., RUIZ-BENITO, P., BARRÓN, V., BASTIAS, C.C., DE LA RIVA, E.G., VILLAR, R., 2021. Linking functional traits with tree growth and forest productivity in *Quercus ilex* forests along a climatic gradient. Sci. Total Environ. 786, 147468. <https://doi.org/10.1016/j.scitotenv.2021.147468> santos

SAR, I., FURTHER, R., 2020. Aboveground biomass, Advanced Remote Sensing. <https://doi.org/10.1016/b978-0-12-815826-5.00014-3>

SCHNEIDER, F.D., MORSDORF, F., SCHMID, B., PETCHEY, O.L., HUENI, A., SCHIMEL, D.S., SCHAEPMAN, M.E., 2017. Mapping functional diversity from remotely sensed morphological and physiological forest traits. Nat. Commun. 8. <https://doi.org/10.1038/s41467-017-01530-3>

SCHRÖTER, D., CRAMER, W., LEEMANS, R., PRENTICE, I.C., ARAÚJO, M.B., ARNELL, N.W., BONDEAU, A., BUGMANN, H., CARTER, T.R., GRACIA, C.A., DE LA VEGA-LEINERT, A.C., ERHARD, M., EWERT, F., GLENDINING, M., HOUSE, J.I., KANKAANPÄÄ, S., KLEIN, R.J.T., LAVOREL, S., LINDNER, M., METZGER, M.J., MEYER, J., MITCHELL, T.D., REGINSTER, I., ROUNSEVELL, M., SABATÉ, S., SITCH, S., SMITH, B., SMITH, J., SMITH, P., SYKES, M.T., THONICKE, K., THUILLER, W., TUCK, G., ZAEHLE, S., ZIERL, B., 2005. Ecology: Ecosystem service supply and vulnerability to global change in Europe. Science (80-.). 310, 1333–1337. <https://doi.org/10.1126/science.1115233>

TELLO, J., GÓMEZ-BÁGUENA, R., CASTERAD, M.A., 2017. Comparison and adjustment in agricultural areas of vegetation indexes derived from Landsat-8 and Sentinel-2. Nuevas plataformas y sensores teledetección. XVII Congr. la Asoc. Española Teledetección. 81–84.

VAYREDA, J., MARTINEZ-VILALTA, J., GRACIA, M., RETANA, J., 2012. Recent climate changes interact with stand structure and management to determine changes in tree carbon stocks in Spanish forests. Glob. Chang. Biol. 18, 1028–1041. <https://doi.org/10.1111/j.1365-2486.2011.02606.x>

ZHU, X., LIU, D., 2015. Improving forest aboveground biomass estimation using seasonal Landsat NDVI time-series. ISPRS J. Photogramm. Remote Sens. 102, 222–231. <https://doi.org/10.1016/j.isprsjprs.2014.08.014>.