



2025 | **16-20**
GIJÓN | **JUNIO**

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1784

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

Organiza





Un modelo simplista de estimación del crecimiento forestal basado en datos

VALLEJO ORTI, M. (1, 2), CORRAL-PAZOS-DE-PROVENS, E. (3), y DOMINGO-SANTOS, J. M. (3)

1. Instituto Pirenaico de Ecología, Consejo Superior de Investigaciones Científicas (IPE-CSIC), Zaragoza, España
2. Energía y Celulosa (ENCE), Huelva, España
3. Departamento de Ciencias Agroforestales, Escuela Técnica Superior de Ingeniería. Universidad de Huelva, Huelva, España

Resumen

Los modelos físicos de estimación de producción de biomasa forestal y de balance de carbono son complejos de implementar, sensibles a la calidad de sus variables de entrada y, generalmente, no contemplan la estimación de incertidumbre asociada. Modelos estadísticos más simples basados únicamente en datos permiten realizar cálculos más fáciles de transferir espacio-temporalmente. Estos modelos, mediante la reserva de datos para validación, permiten la generación de indicadores de ajuste bajo diferentes configuraciones. Proponemos un modelo de aprendizaje automático basado en árboles de decisión (*Random Forest*), utilizando 6 parcelas de plantaciones de eucaliptos distribuidas en la provincia de Huelva, donde disponemos de 6 años de datos mensuales de crecimiento, clima y suelo (2011-2016). Con 8 variables explicativas estimamos el crecimiento medio de las parcelas, modulando el número de años utilizados para el proceso de entrenamiento y el número de parcelas para probar la transferibilidad temporal y espacial de los datos. Los modelos entrenados con, al menos, la mitad de los años y/o parcelas son capaces del predecir crecimientos con $r^2 > 0,7$, lo cual puede ser suficiente para hacer proyecciones temporales a corto plazo, complementar datos de inventarios, calibrar datos satelitales para cálculos de biomasa o validar modelos de balance de carbono.

Palabras clave

Eucalyptus globulus, Random Forest, modelos empíricos, transferibilidad de datos

1. Introducción

Los cambios potenciales de calidad de estación, así como la productividad y supervivencia de las masas forestales frente al cambio climático que se proyecta en el siglo XXI, generan gran incertidumbre en el ámbito forestal. Los modelos empíricos convencionales de estimación de producción de biomasa forestal basados en curvas de crecimiento o tablas de producción según índice de sitio (p.e. DIÉGUEZ-ARANDA et al., 2009; MADRIGAL COLLAZO et al., 1999) están concebidos para climas promedio considerados inmutables que constituyen cada estación forestal, junto con otras condiciones ecológicas como el suelo y el relieve.



Los modelos de tipo fisiológico como 3PG (LANDSBERG Y WARING, 1997) y los modelos generalizados de balance de carbono basados en datos (p.e. KURZ et al., 2009) sí se adaptan a los posibles cambios en las condiciones ambientales y son capaces de dar estimaciones de producción de alta resolución temporal, por años o por meses. Sin embargo, son complejos de implementar, altamente sensibles a la calidad de sus múltiples variables de entrada y, generalmente, no permiten la estimación de la incertidumbre intrínseca asociada (IPCC, 2003).

Una aproximación intermedia al problema son modelos estadísticos más simples, basados únicamente en datos, que permiten realizar cálculos más fáciles de escalar o transferir espacio-temporalmente (RUIZ-MEDINA Y ESPEJO, 2014). En estos modelos, mediante la reserva de datos de referencia para validación, es factible la generación de indicadores de ajuste y bondad bajo diferentes configuraciones y situaciones extrínsecas, como la especie vegetal a modelar y su tipo de clima. En este caso, proponemos un modelo de aprendizaje automático utilizando 6 parcelas de plantaciones de eucalipto en la provincia de Huelva, distribuidas geográficamente en diferentes zonas, donde existen datos mensuales de crecimiento, clima y suelo de alta precisión durante una serie temporal de 6 años (2011-2016).

2. Objetivos

Los objetivos fundamentales de este estudio se orientan hacia:

- Investigar la posibilidad de usar enfoques basados en datos (*data-driven*) para llevar a cabo predicciones temporales a corto plazo (1-5 años) de crecimientos mensuales en plantaciones de *Eucalyptus globulus* y para complementar las mediciones *in-situ* de inventarios forestales. Además de aplicar el método se documenta su precisión y su capacidad predictiva empleando diferentes proporciones de datos para entrenamiento y prueba (*training/test*).
- Investigar y determinar la transferibilidad espacial de los datos y los modelos utilizados para evaluar si las mismas relaciones entre el crecimiento del arbolado y las variables climáticas y de suelo pueden ser aplicadas a otras parcelas dentro de la provincia de Huelva.
- Calcular la importancia relativa de las 8 variables explicativas en la creación del modelo y determinar el número mínimo de variables necesarias para reducir el modelo, optimizando los datos requeridos para generar predicciones operativamente utilizables.

3. Metodología

3.

a. Área de estudio y selección de parcelas

El área de estudio de este trabajo son las plantaciones de eucalipto localizadas en la provincia de Huelva. Los datos proceden de 6 parcelas experimentales, que

fueron seleccionadas teniendo en cuenta criterios edáficos y climáticos.

La información edáfica procede de estudios anteriores realizados por la Universidad de Huelva en colaboración con Ence (DOMINGO-SANTOS Y CORRAL-PAZOS-DE-PROVENS, 2025). En estos trabajos se agruparon las litofacies del Mapa Geológico Nacional (E. 1:50.000) teniendo en cuenta la semejanza de rocas y de periodos geológicos, estableciendo lo que se denominaron “litofacies simplificadas” (LtS). A pesar de esta simplificación, el número de LtS que aparecen en la provincia de Huelva es muy elevado, por lo que, para tratar de minimizar la variabilidad edafológica debida a la roca madre, se escogieron sólo tres LtS, de características edafológicas muy similares. Estas litofacies son:

- LtS 1300, pizarras, cuarcitas y areniscas del Devónico-Carbonífero inferior (formación PQ). Las facies principales que aparecen son “Pizarras, grauwas y cuarcitas”, “Pizarras areniscas y cuarcitas”, “Pizarras, cuarcitas, areniscas, cuarzowacas y grauwas con niveles volcánicos” o “Pizarras, areniscas y grauwas”.
- LtS 1100, rocas pizarrosas de facies Culm. Esta unidad está formada por facies como “Pizarras y grauwas con Posidonomyas, Goniatites y Archaeocalamites” o “Pizarras y pizarras con grauwas”.
- LtS 2100, materiales metamórficos tipo filitas, esquistos y materiales cuarcíferos acompañantes.

Las tres LtS seleccionadas representan el 45,6% de la superficie provincial (Figura 1) y un porcentaje aproximado del 70% de la superficie de plantaciones de eucalipto; además, están bien representadas en todas las zonas climáticas de la provincia.

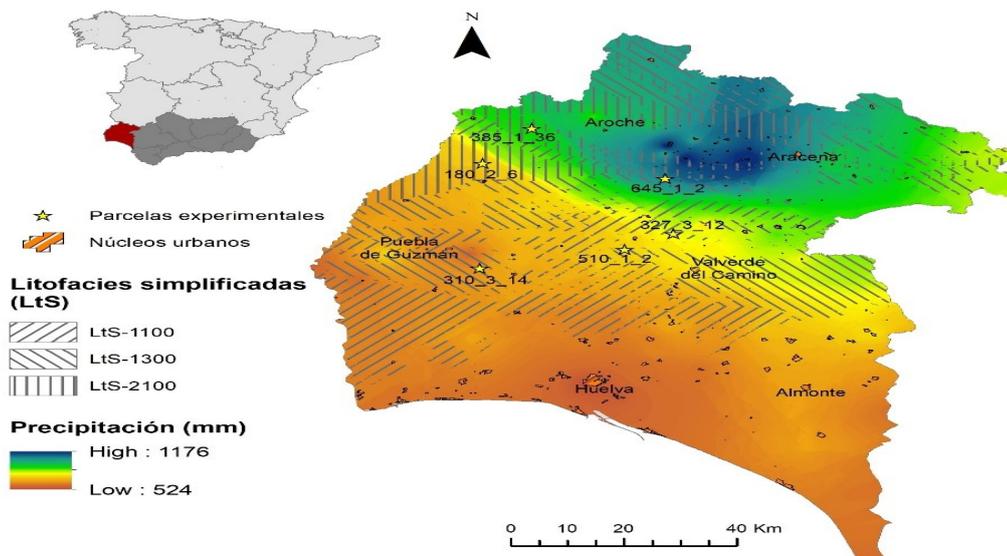


Figura 1. Localización en la provincia de Huelva de las 6 parcelas experimentales utilizadas en este trabajo. La selección de estas parcelas se realizó teniendo en cuenta criterios edáficos y climáticos.

Otro factor que se ha considerado, dada su influencia sobre la calidad de estación, es el régimen termopluviométrico. Las parcelas se seleccionaron de manera que tuvieran una buena distribución en el rango de precipitaciones y temperaturas que aparece en la provincia (Figura 1 y Tabla 1).

En cuanto a la procedencia del material vegetal, se ha trabajado sólo con material clonal, para minimizar la influencia del genotipo en la calidad de estación. Y se decidió elegir masas constituidas sólo por brinzales de menos de 7 años de edad, con el fin de poder tener, al menos, 6 años de mediciones antes de la corta.

Finalmente, sobre un total de 56 parcelas estudiadas, se seleccionaron 6 parcelas (Figura 1 y Tabla 1), que tenían, además, buena accesibilidad, pues debían realizarse mediciones cada mes.

Tabla 1. Datos básicos de las 6 parcelas experimentales utilizadas en este trabajo.

Cod. Parcela	Nombre monte	TTMM	Orientación	Altitud (m)	Pdte %	Temperatura media anual	Precipitación anual
180_2_6	Cruz de la Mujer	Santa Bárbara de Casa	NW	306,39	29	16,5	713
310_3_14	Los Lirios	Alosno	S	182,02	11	17,5	636
327_3_12	Doña Juana y el Toril	Zalamea la Real	NE	207,24	30	17,4	771
385_1_36	Los Rasos y otros	Aroche	N-NE	347,09	38	16	893
510_1_2	El Majadal	Calañas	SE-S	256,16	38	17,2	713
645_1_2	Valdillera y otros	Almonaster la Real	S	335,57	38	16,7	1038

3.

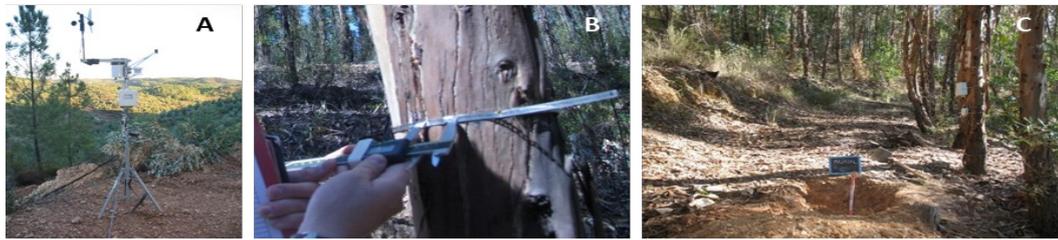
a. Recogida y preparación de datos

El dispositivo experimental que se instaló en cada una de las 6 parcelas consistió, en primer lugar, en una estación meteorológica automática completa de medición continua, de la que se obtuvieron datos de radiación PAR, temperatura del aire, humedad relativa, precipitación y dirección y velocidad de viento. La estación incluye también un sensor de temperatura de suelo.

Se colocaron también 30 dendrómetros de banda analógicos (cubren al menos el 50% del total de árboles de la parcela), de lectura manual, ajustados al perímetro normal del árbol, que permiten conocer su crecimiento diametral mensual. Se midió también la altura de estos 30 árboles.

Se realizaron, además, 3 muestreos de suelo en cada parcela, localizados en 3 terrazas diferentes. Se tomaron muestras cada 20 cm de espesor hasta alcanzar

roca dura, describiendo brevemente cada uno de los horizontes.



Fotografía 1. Recogida de datos en una parcela experimental. A) Estación meteorológica automática. B) Dendrómetro de banda analógico. C) Muestreo de suelo.

La toma de datos se realizó mensualmente durante un periodo de 6 años, desde enero de 2011 hasta diciembre de 2016; las muestras de suelo fueron procesadas y analizadas en el laboratorio, y toda la información se depuró y organizó en una base de datos. Entre toda la información obtenida las variables mejor relacionadas con los objetivos que se persiguen han sido las siguientes:

- Variables dasométricas: edad en meses de cada parcela (Edad_meses); área basimétrica total, en $\text{m}^2 \cdot \text{ha}^{-1}$, a final del mes (AB_FinalMes_m2ha); incremento en área basimétrica mensual (AB_CrecMens); y crecimiento perimetral medio (en cm) de los 30 árboles medidos a final de mes (CrecMensPerim30_Media).
- Variables climáticas: precipitación mensual (P_MES); temperatura media mensual del aire (TA_media); mes del año (MES), variable vinculada a la fenología y también al clima.
- Variables derivadas del balance hídrico: drenaje o agua sobrante una vez completada la reserva del suelo, al final de cada mes (DRJ_MES); evapotranspiración real máxima posible mensual (ETRMP_MES), calculada a partir de la evapotranspiración potencial (ETP) según Penman-Monteith (LAND AND WATER DIVISION, 2006); evapotranspiración real acumulada máxima en los últimos 30 días (ETR_AC30_max); evapotranspiración real acumulada en los últimos 90 días (ETR_90d); sequía fisiológica a final de cada mes (SF_MES); y sequía fisiológica acumulada máxima en los últimos 30 días (SF_AC30_max).

La Figura 2 muestra las relaciones de correlación lineal entre las diferentes variables descritas:

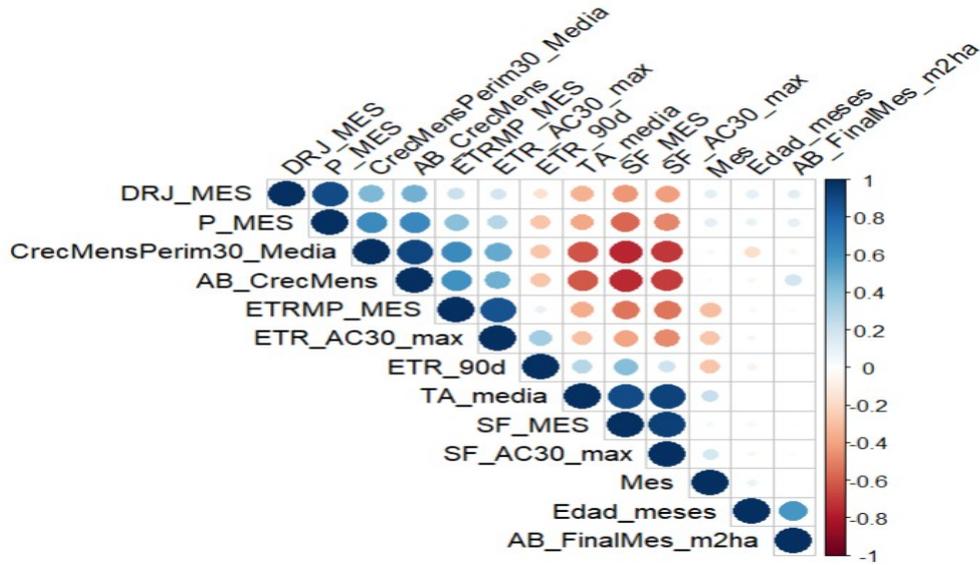


Figura 2. Correlación entre variables intervinientes en el modelo.

3.

a. Modelos de predicción

Se selecciona el modelo *Random Forest* (RF) para llevar a cabo experimentos fijando los hiperparámetros que definen el proceso de aprendizaje automático en 500 árboles de decisión y profundidad de cada árbol de 3 (BREIMAN, 2001).

Los experimentos siguientes se centran en realizar predicciones del valor de crecimiento medio mensual del área basimétrica para cada una de las seis parcelas de estudio. En una primera instancia, se busca utilizar la serie temporal histórica completa de ciertas parcelas para predecir la serie completa de las parcelas restantes. La unidad de análisis son los datos mensuales. Esto implica combinar los datos mensuales de todas las parcelas de entrenamiento para todos los meses de estudio, asumiendo que cada entrada es independiente como criterio predictivo (ver Figura 3a).

Un análisis paralelo consiste en seleccionar, para la fase de entrenamiento, únicamente una fracción de la serie temporal de todas las parcelas (por ejemplo, el primer año de la serie). De esta forma, se puede experimentar con la capacidad del modelo y los datos para realizar predicciones futuras (ver Figura 3b).

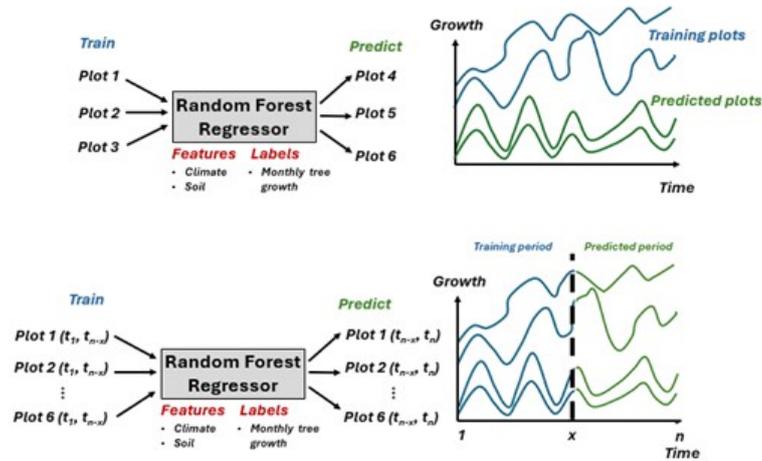


Figura 3. Esquema de los enfoques utilizados para las predicciones con el modelo *Random Forest Regressor*. (a) Enfoque basado en el uso de la serie temporal completa de ciertas parcelas de entrenamiento (*Training plots*) para predecir la serie completa de las parcelas restantes (*Predicted plots*). (b) Enfoque basado en el uso de una fracción del periodo temporal de todas las parcelas para entrenamiento (*Training period*) y predicción de valores en el periodo restante dentro de las mismas parcelas (*Predicted period*).

4. Resultados

En las siguientes imágenes se presentan los resultados de llevar a cabo las predicciones ajustando el modelo de RF, reduciendo progresivamente el número de años y/o parcelas. En cada escenario, se fija el número de años o parcelas a seleccionar y se realiza una selección aleatoria de esa cantidad entre las 6 parcelas o años disponibles (2011-2016), repitiendo el proceso 100 veces. Luego se calcula el promedio (Figura 4.a y 4.c) y la desviación estándar del coeficiente de determinación r^2 .

De manera similar, para cada uno de los 500 ajustes se calcula la importancia relativa de cada variable y se obtiene su promedio (Figura 4.b y 4.d). Las importancias se calculan según el aumento del error de predicción tras ignorar una determinada variable. Si la permutación no afecta el error, la variable se considera poco importante (BREIMAN, 2002).

Los resultados muestran que el cálculo por años (Figura 4.a) presenta niveles menores de precisión, variando desde un 71% (con 84% de datos de entrenamiento y 16% de prueba) hasta un 59% (con 85% de datos de prueba y 15% de entrenamiento). Por el contrario, al realizar el cálculo por parcelas (Figura 4.c), la precisión fluctúa entre el 84% y el 71%. Esto indica que existe una mayor transferibilidad espacial en la zona de estudio que capacidad predictiva a través del tiempo.

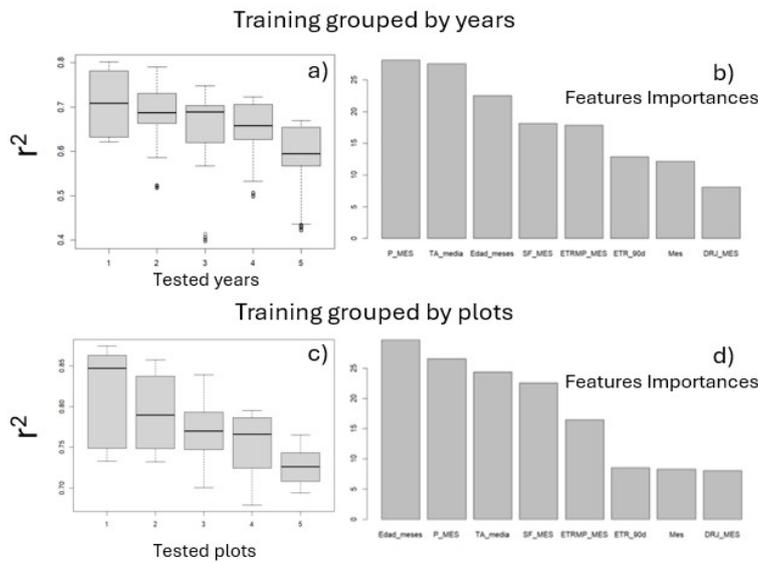


Figura 4. Resultados de los experimentos realizando el proceso de predicción y entrenamiento agrupando los datos por parcelas y por años. a) Boxplot del coeficiente de determinación, reduciendo progresivamente el número de parcelas usadas para el entrenamiento, de 5 hasta 1. b) Barplot con la importancia relativa de las variables explicativas en la composición del modelo por parcelas. c) Boxplot del coeficiente de determinación, reduciendo progresivamente el número de años usados para el entrenamiento, de 5 hasta 1. d) Importancia relativa de las variables explicativas en la composición del modelo por años.

En la Figura 5 se presentan los resultados obtenidos para la predicción del crecimiento mensual del perímetro medio de una parcela en concreto, utilizando la serie temporal de 1, 2, 3, 4 o 5 parcelas para su entrenamiento. Observamos que, en general, las tendencias se registran de manera adecuada, incluso en el caso más desfavorable (usando solamente una parcela para el entrenamiento). Lógicamente, los resultados mejoran al añadir más parcelas de entrenamiento, alcanzando un coeficiente de determinación (r^2) superior al 80% al usar 5 parcelas de entrenamiento para predecir una.

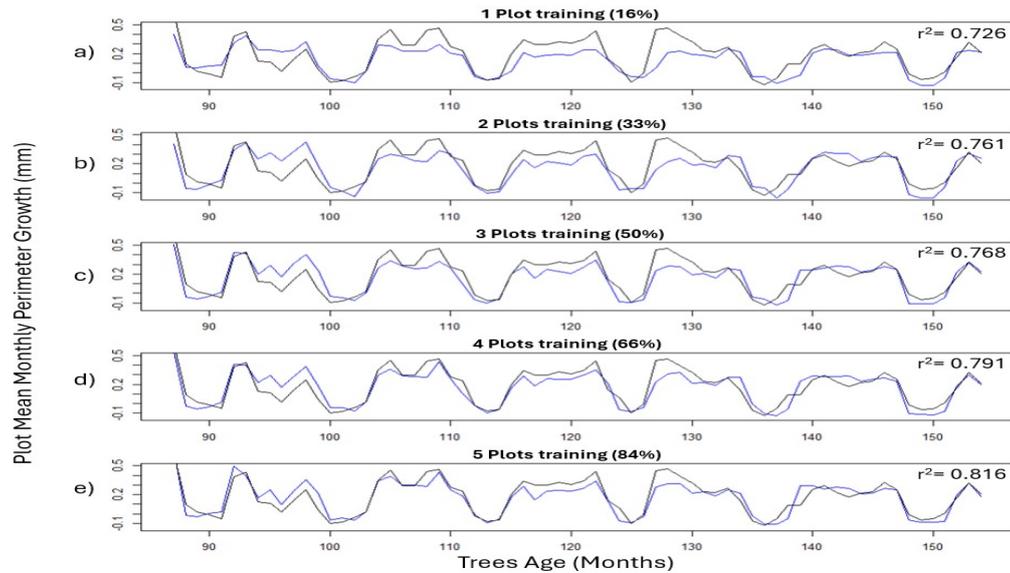


Figura 5. Resultados de un ejemplo de predicciones de crecimiento del perímetro medio por parcela (línea color azul) frente al crecimiento medido (línea color negro) para diferentes proporciones de las fracciones de entrenamiento y prueba, tomando siempre una única parcela de prueba: a) 1 parcela de entrenamiento (p.e.); b) 2 p.e.; c) 3 p.e.; d) 4 p.e.; e) 5 p.e..

En la Figura 6 observamos que las predicciones temporales presentan menor precisión, considerando las mismas proporciones de datos de entrenamiento y prueba que por parcelas. En cualquier caso, cuando el porcentaje de los datos de entrenamiento es $>50\%$, se alcanzan valores de $r^2 > 0.7$, lo que puede considerarse una estimación aceptable para llevar a cabo predicciones a corto plazo.

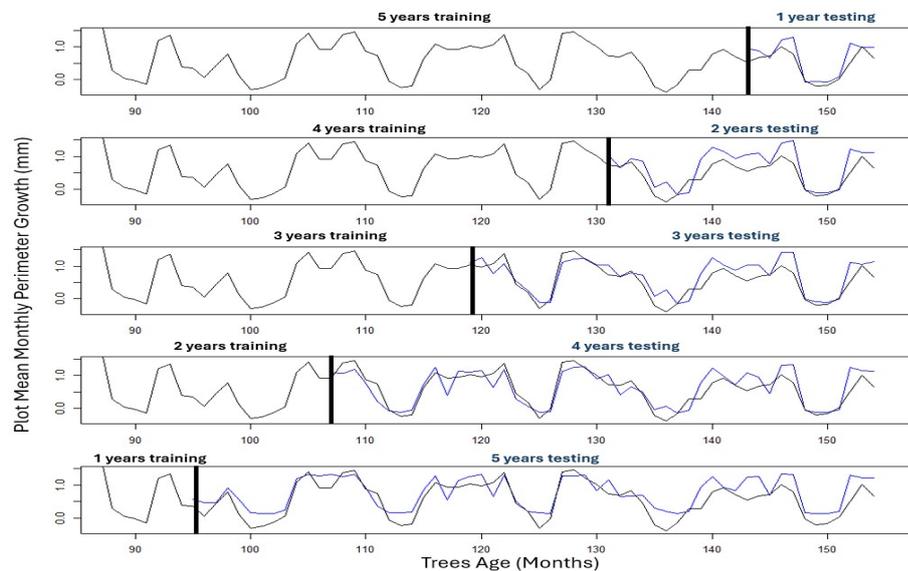


Figura 6. Resultados de un ejemplo de predicciones de crecimiento del perímetro medio por parcela (línea color azul), frente al crecimiento medido (línea color negro) para diferentes proporciones de las fracciones número de años de entrenamiento y prueba. a) 5 año de entrenamiento (a.e.), 1 año de prueba (a.p.); b) 4 a.e., 2 a.p.; c) 3 a.e., 3 a.p.; d) 2 a.e., 4 a.p.; e) 1 a.e., 5 a.p.;

A la vista de que las tres variables con mayor peso en el modelo son la edad de los árboles, la precipitación y la temperatura, variables que no requieren de recogida de datos in situ y se obtienen fácilmente, se procede a repetir el análisis considerando sólo estos tres parámetros, eliminando las variables relacionadas con el suelo, para evaluar si simplificar el modelo es conveniente y puede facilitar su aplicación práctica al reducir el trabajo de campo. En la Tabla 2 se presenta una comparativa de resultados. Cuando se usan únicamente la edad del arbolado y la temperatura media mensual y la precipitación mensual, tanto en la predicción por parcelas como en la realizada por años, los resultados son ligeramente inferiores, si bien se pierde un máximo del 3% de precisión en las predicciones con respecto al modelo completo con 8 parámetros.

Tabla 2. Comparativa de las correlaciones obtenidas en las predicciones realizadas con Random Forest con 8 (RF8) y 3 (RF3) parámetros explicativos en relación a los datos de prueba o referencia.

%Training size	Por años		Por parcelas	
	RF8	RF3	RF8	RF3
83%	0.71	0.69	0.81	0.79
66%	0.69	0.68	0.78	0.78
50%	0.65	0.66	0.76	0.76
33%	0.65	0.62	0.75	0.74
16%	0.57	0.54	0.72	0.70

5. Discusión

El objetivo principal de este estudio es identificar un método sencillo en su aplicación y fácilmente transferible y con capacidad predictiva a corto plazo. Para lograr esto, se han implementado modelos basados en árboles de decisión (RF) con 8 variables explicativas, aplicados a la estimación del crecimiento medio de las parcelas (rodales). Primero modulamos el número de años utilizados para el proceso de entrenamiento para predecir años futuros, verificando la capacidad predictiva del modelo y la sensibilidad del modelo al número de datos de entrenamiento. En segundo lugar, replicamos el procedimiento variando el número de parcelas para probar la transferibilidad temporal y espacial de los datos.

Los resultados de este estudio, basado en aprendizaje automático en datos, presentan un escenario prometedor para realizar estimaciones del crecimiento del arbolado en zonas geográficamente acotadas y en lapsos de tiempo reducidos. No obstante, existen algunos puntos de discusión que se deben considerar:



- Se recomienda la inclusión de un algoritmo que considere la memoria climática de los meses y años previos, tales como las redes neuronales long short-term memory- LSTM (HOCHREITER Y SCHMIDHUBER, 1997), ya que diversos estudios han demostrado que las condiciones pasadas de lluvia y balance hídrico, en general, tienen una influencia significativa en el crecimiento (DOMINGO SANTOS et al., 2009; GARCÍA, 1999).
- Se ha demostrado que, a la escala del trabajo, las variables relacionadas con el suelo tienen poca influencia, mientras que las de mayor impacto son la edad, la temperatura y la precipitación. Se trata de un resultado lógico, ya que de las parcelas tomadas presentan suelos de características muy parecidas. En este sentido, se recomienda explorar la inclusión de otras variables básicas, como la radiación solar, para complementar el análisis y verificar si estos parámetros de obtención *exsitu* son relevantes para reducir la incertidumbre en las estimaciones.
- Se sugiere testear el modelo con una muestra más amplia de parcelas que reflejen mayor variabilidad edáfica. Para minimizar el trabajo *in situ*, podrían estimarse indicadores de calidad del suelo, como la profundidad, mediante sensores remotos (DÍAZ-GONZÁLEZ et al., 2022) que midan la actividad vegetal en condiciones de déficit hídrico (ROLDÁN-CORTÉS et al., 2014). Esto permitiría evaluar la transferibilidad espacial del modelo y su potencial para estudios a mayor escala geográfica.
- Los resultados aportan claridad sobre su idoneidad para generar datos duplicados en los inventarios forestales, los cuales, de por sí, presentan cierta incertidumbre. Por ello, este método puede emplearse como herramienta de validación cruzada (*cross-validation*) para verificar inventarios o completar vacíos de información en zonas o años poco, mal o no inventariados. No obstante, es importante tener en cuenta que se trata de predicciones basadas en modelos, las cuales no consideran factores extremos como incendios, plagas o eventos climáticos extremos.
- Este estudio es aplicable a la provincia de Huelva, dentro de un ámbito geográfico y climático concreto, así como a un periodo temporal específico. Por ello, se recomienda replicarlo en otras zonas de características similares, como en zonas de eucalipto de Galicia, para corroborar la idoneidad del método como complemento a los inventarios forestales.
- Aunque su aplicación es claramente más sencilla que la de otros modelos fisiológicos como el 3PG, se recomienda realizar una comparativa con estos en términos de precisión, con el fin de llevar a cabo una evaluación clara del alcance y el potencial de estos métodos.

6. Conclusiones

Los modelos empleados de regresión de Random Forest sobre ocho variables climáticas, dasonómicas y de suelo pueden alcanzar valores de coeficiente de determinación superiores a 0.7 en un escenario de entrenamiento que utilice el 50% de los datos disponibles.



Al reducir las variables explicativas a tres (temperatura, precipitación y edad) e ignorar todas las variables relacionadas con el suelo, el coeficiente de determinación promedio se reduce únicamente en un máximo de 3%.

Las variables de mayor peso para las estimaciones del modelo que predice el comportamiento de una parcela a partir de las otras son, en orden decreciente, la edad de la plantación (en meses), la precipitación acumulada mensual, la temperatura media mensual, la sequía fisiológica acumulada mensual, la evapotranspiración real máxima posible mensual, la evapotranspiración real acumulada en los últimos 90 días, el mes del año y el drenaje acumulado mensual.

Las variables de mayor peso para las estimaciones del modelo que predice el comportamiento de una parcela en el tiempo a partir de lo ocurrido en años anteriores son similares a las del modelo anterior, si bien la precipitación y la temperatura se sitúan con mayor importancia que la edad de la plantación.

Para seguir progresando en la mejora del modelo, se recomienda implementar algoritmos con memoria que consideren datos climáticos acumulados del pasado y la influencia de eventos extremos, como redes neuronales recurrentes o el filtro de Kalman (Kalman, 1960).

En resumen, este artículo propone un método aplicable para la estimación del crecimiento mensual del arbolado, funcionando como una herramienta de interpolación espacial y predictiva para periodos de tiempo inferiores a 5 años.

7. Agradecimientos

ENCE, Energía y Celulosa S.A. ha prestado su apoyo económico y humano para el desarrollo de este trabajo.

Programa de recualificación del profesorado universitario, Plan de Recuperación, Transformación y Resiliencia, Ministerio de Universidades, Financiado por la Unión Europea-Next Generation EU.

Consejo Europeo de Investigación (European Research Council, ERC) a través del programa Starting Grant de Horizonte Europa 2021 bajo el acuerdo de subvención REA número 101039181 - SED@HEAD."

8. Bibliografía

BREIMAN, L., 2002. Manual On Setting Up, Using, And Understanding Random Forests V3.1.

BREIMAN, L., 2001. Random Forests. *Mach. Learn.* 45, 5–32. <https://doi.org/10.1023/A:1010933404324>

DÍAZ-GONZÁLEZ, F.A., VUELVAS, J., CORREA, C.A., VALLEJO, V.E., PATIÑO, D., 2022. Machine learning and remote sensing techniques applied to estimate soil indicators – Review. *Ecol. Indic.* 135, 108517. <https://doi.org/10.1016/j.ecolind.2021.108517>

DIÉGUEZ-ARANDA, U., ROJO-ALBORECA, A., CASTEDO-DORADO, F., GONZÁLEZ, J.,



ANTA, M., CRECENTE-CAMPO, F., GONZÁLEZ-GONZÁLEZ, J.M., PÉREZ CRUZADO, C., RODRÍGUEZ-SOALLEIRO, R., LÓPEZ-SÁNCHEZ, C., BALBOA-MURIAS, M., VARELA, J., SANCHEZ-RODRIGUEZ, F., GÓMEZ-GARCÍA, E., 2009. Herramientas selvícolas para la gestión forestal sostenible en Galicia. Consellería do Medio Rural, Xunta de Galicia, Lugo.

DOMINGO-SANTOS, J.M., CORRAL-PAZOS-DE-PROVENS, E., 2025. Suelos forestales de la provincia de Huelva: propiedades, evolución y distribución territorial. Universidad de Huelva, Huelva.

DOMINGO SANTOS, J.M., LÓPEZ FERNÁNDEZ, A. V., CORRAL PAZOS DE PROVENS, E., SEVILLA SÁNCHEZ, J., RUIZ FERNÁNDEZ, F., LAGO MACÍA, J., 2009. Calidad de estación de eucalipto y factores edafoclimáticos en la provincia de Huelva.

GARCÍA, O., 1999. Efectos en el crecimiento del eucalipto en Huelva. Documento inédito.

HOCHREITER, S., SCHMIDHUBER, J., 1997. Long Short-Term Memory. *Neural Comput.* 9, 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>

IPCC, I.P. on C.C., 2003. Good Practice Guidance for Land Use, Land-Use Change and Forestry. Institute for Global Environmental Strategies, Kamiyamaguchi Hayama, Kanagawa (Japan).

KALMAN, R.E., 1960. A New Approach to Linear Filtering and Prediction Problems. *J. Basic Eng.* 82, 35–45. <https://doi.org/10.1115/1.3662552>

KURZ, W.A., DYMOND, C.C., WHITE, T.M., STINSON, G., SHAW, C.H., RAMPLEY, G.J., SMYTH, C., SIMPSON, B.N., NEILSON, E.T., TROFYMOW, J.A., METSARANTA, J., APPS, M.J., 2009. CBM-CFS3: A model of carbon-dynamics in forestry and land-use change implementing IPCC standards. *Ecol. Modell.* 220, 480–504. <https://doi.org/10.1016/j.ecolmodel.2008.10.018>

LAND AND WATER DIVISION, 2006. Evapotranspiración del cultivo - Guías para la determinación de los requerimientos de agua de los cultivos. Estudio FAO: riego y drenaje n° 56, 1st ed. Food and Agriculture Organization of the United Nations, Roma.

LANDSBERG, J.J., WARING, R.H., 1997. A generalised model of forest productivity using simplified concepts of radiation-use efficiency, carbon balance and partitioning. *For. Ecol. Manage.* 95, 209–228. [https://doi.org/https://doi.org/10.1016/S0378-1127\(97\)00026-1](https://doi.org/https://doi.org/10.1016/S0378-1127(97)00026-1)

MADRIGAL COLLAZO, A., ÁLVAREZ GONZÁLEZ, J.G., RODRÍGUEZ SOALLEIRO, R., ROJO ALBORECA, A., 1999. Tablas de Producción para los montes españoles. . Fundación Conde Valle de Salazar. Escuela Técnica Superior de Ingenieros de Montes, Madrid.

ROLDÁN-CORTÉS, M. A., DE LOS SANTOS-POSADAS, H. M., RAMÍREZ-MALDONADO, H., VALDEZ-LAZALDE, J. R., ÁNGELES-PÉREZ, G., & VELÁZQUEZ-MARTÍNEZ, A., 2014. Estimadores de muestreo para inventario de plantaciones forestales comerciales de eucalipto en el sureste mexicano. *Rev. Mex. Cienc. For.* 5(26), 38-57.

RUIZ-MEDINA, M.D., ESPEJO, R.M., 2014. A spatio-temporal autoregressive model for functional data. *J. Multivar. Anal.* 123, 241–256.