

(06-007) - RESIM: Resin production simulator for new projects in the northeastern Iberian Peninsula

López Alvarez, Oscar ¹; Franco Vázquez, Luis ¹; Marey Pérez, Manuel Francisco ¹

¹ Universidad de Santiago de Compostela

The forecast of the resources that can potentially be obtained from any raw material is basic to plan the decision making in a project. To make this type of judgments, managers use tools that are capable of obtaining an estimate of the productive potential. In non-timber forest products, and particularly in pine resin, there is a lack of such tools. In this work, a computer tool was developed using R Shiny capable of estimating the potential resin production both at the stand and individual tree level of *Pinus pinaster* in the northwest of the Iberian Peninsula. For this purpose, a classification model was used, capable of assigning with an accuracy of 14,5 % to which group the data belonged according to environmental and dendrometric variables, the extraction method and the stimulant paste. Subsequently, for each group, different production models developed by Machine Learning were used to estimate the production. This work is the first tool to predict resin production at the individual tree level integrated in an online computer application.

Keywords: *Pinus pinaster*; clustering; Machine Learning; computer development

RESIM: Simulador de la producción de resina en proyectos de nueva implantación en el NE de la Península Ibérica

La previsión de los recursos que potencialmente se pueden obtener de cualquier materia prima es básica para planificar la toma de decisiones en un proyecto. Para realizar este tipo de juicios, los gestores se ayudan de herramientas que son capaces de obtener una estimación del potencial productivo. En los productos forestales no madereros, y particularmente en la resina de pino, existe una carencia de este tipo de herramientas. En este trabajo se desarrolló una herramienta informática empleando R Shiny capaz de estimar la producción potencial de resina tanto a nivel masa como árbol individual de *Pinus pinaster* en el Noroeste Peninsular. Para ello, se utilizó un modelo de clasificación capaz de asignar con un acierto del 14,5 % a que grupo pertenecen los datos en función de variables ambientales, dendrométricas, el método de extracción y la pasta estimulante. Posteriormente, para cada grupo se emplearon diferentes modelos de producción desarrollados mediante Machine Learning capaces de estimar la producción. Este trabajo supone la primera herramienta de predicción de la producción de resina a nivel árbol individual integrado en una aplicación informática online.

Palabras clave: *Pinus pinaster*; clusterización; Machine Learning; desarrollo informático

Correspondencia: manuel.marey@usc.es

Agradecimientos: Este trabajo ha contado con el apoyo del Gobierno español ("ACREMA", MAPA/AEI-Agri/FEADER, UE) [O00000226e2000043659], el Gobierno de Galicia (Xunta de Galicia) con una subvención para Grupos de Grupos de Referencia ED431C-2021-27 y el contrato predoctoral Campus Terra-USC 2023.



©2024 by the authors. Licensee AEIPRO, Spain. This article is licensed under a Creative Commons Attribution-NonCommercial-NoDerivatives 4.0 International License (<https://creativecommons.org/licenses/by-nc-nd/4.0/>).

1. Introducción

La gestión de los recursos naturales es una actividad que actualmente es esencial debido a los nuevos desafíos a los que se enfrenta la sociedad (Ibrahim et al., 2023). La recurrencia de incendios cada vez más grandes y difíciles de extinguir (Marey-Perez et al., 2021) y las nuevas tendencias en la generación de energía, en donde cada vez se emplean más energías de origen sostenible y renovables (Sampene et al., 2022), son dos de los principales argumentos para realizar una gestión activa de los recursos naturales. Entre estos, los que actualmente poseen un papel fundamental y que se seguirá incrementando con el tiempo son los recursos de origen forestal (Achim et al., 2022).

Los recursos forestales son bienes y servicios que los bosques son capaces de brindar para satisfacer las necesidades humanas, bien sea de manera directa o indirecta. La multifuncionalidad de los bosques hace de ellos herramientas cada vez más útiles en tareas como la lucha contra el cambio climático mediante la captura e inmovilización de CO₂, o en la generación de recursos y fuentes de energía capaces de sustituir a los derivados del petróleo (Batala et al., 2023; Giurca & Befort, 2023). Estos productos generados se pueden dividir en dos grandes grupos, maderables y no maderables o productos forestales no madereros (PFNMs). Los primeros consisten en la madera o leñas que se obtiene del procesamiento de los árboles presentes en bosques o plantaciones. En el caso de los PFMNs estos son todos aquellos productos de origen biológico distinto a la madera que se obtienen de las masas forestales (corcho, piñones, resina, miel, caza...). Entre estos últimos, la resina de pino resinero (*Pinus pinaster*) posee una relevancia sustancial en toda la Península Ibérica, especialmente en zonas de la meseta central (Segovia, Soria, Ávila y Valladolid) y Portugal (López-Álvarez, Zas y Marey-Perez, 2023).

La resina se trata de una sustancia empleada por diferentes especies del género *Pinus* como defensa natural ante ataques bióticos o abióticos. Además de esta tarea de defensa, desde hace miles de años el hombre lleva aprovechándose de las cualidades de este material empleándolo en diferentes tareas, que van desde la elaboración de pinturas en el antiguo Egipto, como fuente de iluminación debido a su carácter inflamable o el impermeabilizado de barcos, actividad que tuvo una importante relevancia a partir del siglo XVI (Michavila et al., 2017). En la actualidad, la resina de pino y sus derivados son ampliamente empleados por la industria química en productos como bioherbicidas, inhibidores de la ureasa, tinta de impresoras o biocombustibles para jets (Neis et al., 2017; Bolonio et al., 2022). Además de los usos directos de la resina de pino como materia prima, posee beneficios ambientales asociados, como la reducción de vegetación en el sotobosque, consiguiendo un descenso en la cantidad de combustible disponible susceptible de arder en un incendio forestal, o realizar una labor de vigilancia de incendios forestales a lo largo del año, intensificándose en los meses de verano, que es durante la época que se lleva a cabo la extracción de la resina (Palma et al., 2016). Esta actividad, además de los beneficios productivos y ambientales, también posee una importante componente social, ya que se trata de una actividad que se lleva a cabo en ámbitos rurales y sirve como fijador de la población generando empleo en este tipo de zonas (Soliño et al., 2018).

Por todo esto, recientemente comienzan a aparecer nuevas iniciativas relacionadas con la extracción de resina de pino a lo largo de España. Uno de estos lugares es el noroeste de la Península Ibérica (Galicia, Asturias y el Noroeste de Castilla y León), donde existen vastas extensiones de masas de pino resinero en las cuales únicamente se está realizando un aprovechando maderero, no beneficiándose de obtener al mismo tiempo producciones complementarias como la producción de resina. Con la aparición de estos nuevos proyectos los gestores forestales necesitan tener herramientas con las que realizar una gestión de los recursos eficiente, de manera que permitan compatibilizar ambos aprovechamientos y

maximizar los beneficios. Parte de esa gestión de los recursos pasa la selección de los emplazamientos óptimos donde realizar la extracción de resina y prever la producción potencial que se es capaz de obtener de cada una de esas masas. Esta estimación permitirá posteriormente realizar una estimación de los inputs que va a generar y ver si es económicamente rentable realizar tareas de resinación en esa masa. El empleo de este tipo de herramientas está ampliamente extendido en otros campos como el forestal o el agrícola (Barbosa et al., 2020; Tian et al., 2022), pero en el campo de la los PFNMs está vagamente extendido, no existiendo este tipo de herramientas para prácticamente ningún PFNM y mucho menos para la producción de resina (Miina et al., 2020). Es por esto que poseer este tipo de herramientas son necesarias para desarrollar el sector y que este sea capaz de crecer aún más.

2. Objetivos

Este trabajo tiene como finalidad explicar el desarrollo y utilización del primer simulador web capaz de predecir la producción de resina a nivel árbol individual en masas de *Pinus pinaster* en el noroeste de la Península Ibérica.

Para ello se explicará el funcionamiento de los modelos que lo componen (modelo de clasificación y modelo de producción) y la implementación informática llevada a cabo.

3. Metodología

La metodología empleada para desarrollar esta aplicación consta de tres fases: implementación de los modelos de producción, desarrollo de un modelo de clasificación e implementación informática.

3.1 Modelos de producción

Para predecir la producción de resina de las masas seleccionadas por el usuario se emplearon los modelos de desarrollados en López-Álvarez et al. (2024), el cual se trata de un trabajo perteneciente a esta misma línea de investigación. En él se desarrollaron modelos de predicción de resina empleando técnicas de machine learning en base a variables espaciales, dasométricas, así como dependientes del método de extracción y la pasta estimulante para el noroeste de la Península Ibérica. La metodología desarrollada consta de un proceso bietápico que engloba, un primer paso en el que se obtiene y se clasifican los datos en función del número óptimo de grupos en los que se pararon los datos, y un segundo paso en el que se modeliza la producción en función de cada grupo.

El primer paso se basa por lo tanto en aprendizaje no supervisado, ya que obtiene el número óptimo de grupos realizando un proceso de clusterización para datos mixtos llamado k-prototype, que se encuentra implementado en el paquete de R "clustMixType". Este algoritmo permite segmentar el set de datos empleando para ello tanto variables numéricas como categóricas. Una vez que el set de datos estuvo segmentado se emplearon los índices de validación de Silhouette y Tau para obtener el número óptimo de clusters. En este caso se obtuvo que el número óptimo de grupos era 6.

En el segundo paso se modelizó la producción de resina utilizando el paquete de R "h2o" y empleando las variables diámetro a la altura del pecho (DBH), altura total (HT), localización (Pantón, Godos, Culleredo, Asturias y Coca), empleo del método de extracción tradicional no mecanizado (TNM), empleo del método de extracción circular mecanizado (MCM), empleo de la pasta estimulante ASACIF (ASF) y empleo de la pasta estimulante Ethephon (ETH). Este paquete permite ajustar modelos empleando diferentes técnicas de machine learning (eXtreme Gradient Boosting o XGBoost, Deep Learning, Random Forest...). En cinco de los seis grupos, los modelos que tuvieron un mejor rendimiento fueron los que

emplearon Deep Learning. En el grupo restante el algoritmo que mejor funcionó fue el XGBoost. Estos modelos obtuvieron un RRMSE del 26.5% para el agregado de los cluster, y en el mejor de los grupos un RRMSE del 13.5%.


3.2 Modelo de clasificación

Tras obtener los modelos de producción se ajustó un modelo de clasificación capaz de clasificar los nuevos datos introducidos en la aplicación en uno de los seis grupos. Este modelo asigna en función a las variables previamente citadas la pertenencia a un grupo concreto, información que posteriormente se empleará en la aplicación web para predecir el modelo correspondiente en cada caso.

Este modelo se construyó empleando el algoritmo XGBoost implementado en el paquete de R “xgboost” y mediante el uso del paquete “tydymodels”. El acierto de este modelo clasificando sobre los datos de test fue de un 90%. Para comprender la importancia de las variables introducidas en el modelo se calcularon los valores de SHAP (SHapley Additive exPlanations). Estos valores son capaces de determinar la importancia de las variables dentro del modelo permitiendo así identificar cuales son las más relevantes para cada uno de los grupos y cuáles son las que menos.

En este caso en la Figura 1 se puede ver como las variables que más relevancia tienen en el modelo de clasificación son las variables relacionadas con los métodos de extracción (MCM y TNM) y las variables dasométricas (DBH y HT). Las variables relacionadas con la localización y las relacionadas con las pastas estimulantes (ASF y ETH), inciden de una manera más discreta en el modelo.

Figura 1: Valores de SHAP para cada una de las variables introducidas en el modelo de clasificación.

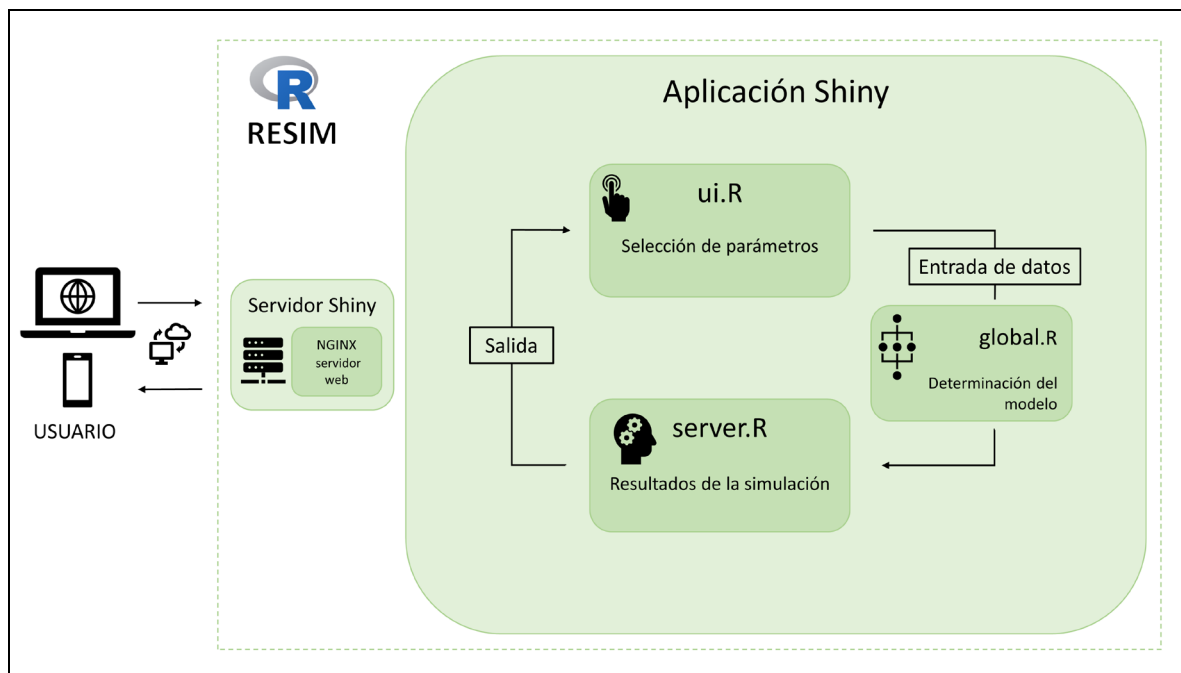


3.4 Implementación informática

Para construir la aplicación informática se empleó el lenguaje de programación R como base, aunque incluye partes del código en javascript embebido. Más específicamente, se empleó un desarrollo basado en módulos Shiny, con el fin de obtener una aplicación web interactiva. Los módulos Shiny son un conjunto de funciones cuyo propósito es facilitar el desarrollo de aplicaciones web que permiten a los usuarios interactuar con el código de R en un navegador mediante elementos de la interfaz de usuario (UI) como controles deslizantes, menús desplegables... Para hacer esta aplicación accesible a todos los usuarios se debió de instalar un servidor Shiny, que incorpora un servidor web NGINX, el cual tiene una estructura asíncrona y controlada por eventos, lo que permite el procesamiento de muchas solicitudes al mismo tiempo, y configurar la aplicación desarrollada para hacer uso de ese servicio.

En la Figura 2 se puede apreciar el flujo que sigue la aplicación, desde la conexión que realiza el usuario con el servidor web, hasta cómo funciona internamente la aplicación Shiny.

Figura 2: Flujo de la aplicación




Si se detalla un poco más lo presente en la Figura 2, el proceso comienza con el usuario haciendo una solicitud desde su dispositivo al servidor donde está alojada la aplicación Shiny, una vez que se establece esta conexión entre ambos, el usuario debe de seleccionar los parámetros de localización y características dasométricas de su masa, así como el método de extracción y la pasta estimulante que desea emplear mediante la UI.

Una vez que se seleccionaron los parámetros deseados la aplicación determina el modelo de predicción de resina que se debe de emplear en cada caso en función de a que cluster asigne los datos el modelo de clasificación. Para poder emplear el modelo de asignación de cluster asigna a la localización indicada por el usuario a una zona de influencia en función de las parcelas empleadas para ajustar los modelos. Estas zonas de influencia se pueden ver en la Figura 3, en ella aparecen las parcelas empleadas para ajustar los modelos de

producción, así como las zonas de influencia de cada parcela calculadas empleando los polígonos de Voronoi. Por último, la aplicación genera una estimación de la producción potencial de resina que se podrá obtener el primer año si se realizase la extracción de la resina.

Figura 3: Zona para la que se construyó la aplicación (en color gris).



Nota: Además, aparecen las parcelas empleadas para ajustar los modelos, así como su zona de influencia. Las zonas en azul son el rango de distribución del *Pinus pinaster* de acuerdo con Caudullo, Welk y San-Miguel-Ayanz (2017).

4. Resultados

Como resultado de la metodología anteriormente descrita se obtuvo la aplicación RESIM (<http://resim.proepla.com>). Esta aplicación permite obtener la producción potencial de resina a ocho picas en árboles *Pinus pinaster* en el noroeste de la Península Ibérica (Galicia, Asturias y Castilla y León). Se han implementado seis modelos distintos que permiten calcular la cantidad de resina que se puede obtener de árboles individuales o masas de pino marítimo en base a variables dasométricas y espaciales. Además, se tuvo en cuenta los dos principales métodos de extracción que más se están empleando en las zonas donde se desarrolló el estudio, así como las dos principales pastas comerciales que más se utilizan y que menor perjuicio ambiental y para el árbol generan. En la Figura 4 se puede ver la pantalla principal de la aplicación web.

Las secciones en las que se divide la UI de RESIM, y que están señaladas en la Figura 4, son las siguientes:

1. Selección de la parcela
2. Técnicas de resinación
3. Características del arbolado

Figura 4: Captura del aspecto general de la aplicación

Proc

Simulador de producción de resina a 8 picas

© Acerca del simulador

Esta aplicación realiza una simulación de la producción de resina de las 8 primeras picas teniendo en cuenta diversos factores, como el lugar, el tipo de pasta empleada o el método de extracción.

El grupo operativo GO ACREMA - Adaptación de la actividad resinera a masas de pino con fines productores de madera, ha recibido para su proyecto de innovación una subvención de 559,127,30 €. El importe del proyecto es cofinanciado al 80% por el Fondo Europeo Agrícola de Desarrollo Rural (FEADER) y al 20% por fondos de la Administración General del Estado (AGE), tal como se establece en el Real Decreto 169/2018, de 23 de marzo.

El organismo responsable del contenido es el GO-ACREMA y la Dirección General de Desarrollo Rural, Innovación y Formación Agroalimentaria (DGDRIFA) como autoridad de gestión encargada de la aplicación de la ayuda FEADER y nacional correspondiente.

Comisión Europea
AGREMA
PROEPLA
GO-1716 PROYECTOS E PLANIFICACIÓN

1 Primer paso: seleccionar parcela

Haga click sobre su parcela
Válido sólo para Galicia, Asturias y Castilla y León

Coordenadas: -6.97770779041914, 42.9499559111156

2 Segundo paso: técnicas de resinación

Método de extracción

Entalladura circular
 Pica de corteza

Ancho/perímetro pica (cm):
5 16 35

Pasta estimulante

Sin pasta
 Salicilica
 Ethephon

3 Final: características del arbolado

Altura total (m):
10 35

Diámetro normal (cm):
20 65

Número de pies:
1

+ Añadir Eliminar

Imprimir Descargar

Tabla 1: Cálculos para su parcela.

Altura	Diámetro	Pies	Predicción (gr)
Ningún dato disponible en esta tabla			

Mostrando registros del 0 al 0 de un total de 0 registros

Anterior Siguiente

Grupo operativo Acrema
Desarrollado por GI-1716 Proyectos y Planificación (PROEPLA)

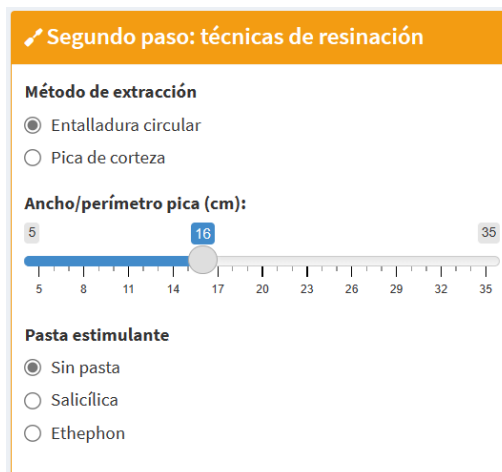
En la Figura 5 se puede ver en detalle la sección número 1, esta sección es la que permite seleccionar la parcela en la que se desea hacer el cálculo de producción de resina. En ella se dispone de un visor que tiene cargada la ortofoto de máxima actualidad del PNOA, así como las geometrías y el número de las parcelas catastrales. Únicamente es posible seleccionar parcelas dentro de las CCAA de Galicia, Asturias y Castilla y León.

Figura 5: Detalle de la sección 1 en la que se muestra el visor donde seleccionar la parcela deseada



La Figura 6 muestra el selector que permite al usuario elegir que método de extracción y que pasta desea emplear. Los métodos que puede elegir son el método de “pica de corteza” o tradicional no mecanizado, y el método de más reciente aparición y que se está extendiendo sobre todo en Galicia y Asturias por las ventajas que ofrece en limas más húmedas, el método circular mecanizado. A su vez también se puede seleccionar el ancho/perímetro de la hendidura con la que se desea trabajar, ya que, en función de la zona geográfica, normalmente en el sistema no mecanizado, los anchos de pica varían. Por último, también se debe seleccionar el tratamiento químico que se desea emplear como estimulante de la producción. En este caso se puede seleccionar dos tipos de estimulantes comúnmente empleados, uno es el estimulante Ethephon y otro se trata del estimulante ASACIF.

Figura 6: Detalle de la sección 2 que permite seleccionar el método de extracción y la pasta estimulante



Por último, en la Figura 7 se muestra la sección 3, en ella se debe introducir las características dasométricas del arbolado de la masa. En esta sección se permite mediante controles deslizantes introducir los valores de diámetro y altura de un árbol individual o de varios de ellos en función del número de pies que se indiquen en la sección "Número de pies". Una vez vas añadiendo registros en el botón "Añadir" van apareciendo registros en la parte inferior, indicando el número de árboles a los que hace referencia el registro, el diámetro y la altura empleados para hacer el cálculo y por último la producción de resina en gramos. Para obtener los resultados de las predicciones hechas por la aplicación la aplicación ofrece dos alternativas, imprimir un PDF de una página creada con html con los resultados presentados en la parte inferior de la sección 3, o descargarlos en formato PDF, Excel o CSV.

Figura 7: Detalle de la sección 3 que permite introducir los valores dasométricos y el número de árboles a los que hacen referencia, así como visualizar los resultados de la predicción

🌲 Final : características del arbolado

Altura total (m):
10 35
10 13 16 19 22 25 28 31 34

Diámetro normal (cm):
20 65
20 25 30 35 40 45 50 55 60 65

Número de pies:
1

+ Añadir 🗑 Eliminar

Imprimir Descargar ▾

Tabla 1: Cálculos para su parcela.

Altura	Diámetro	Pies	Predicción (gr)
Ningún dato disponible en esta tabla			

Mostrando registros del 0 al 0 de un total de 0 registros

Anterior Siguiente

4. Conclusiones

Este trabajo busca presentar el flujo de trabajo llevado a cabo para desarrollar la primera aplicación web interactiva capaz de estimar la producción de resina empleando modelos basados en técnicas de machine learning que son capaces de generar predicciones disminuyendo el error generado.

Que se halla desarrollado una herramienta como la aquí presentada tiene unas implicaciones muy relevantes para un sector tan estratégico como es el forestal, ya que permite a los gestores forestales poder realizar estimaciones de la cantidad de resina que potencialmente podrían obtener el primer año de resinado de sus masas de *Pinus pinaster*. Esto incentivará la multifuncionalidad de los montes y el aumento en los beneficios generados entre cortas. Además, que tendrá beneficios asociados como la eliminación del matorral en el sotobosque, tarea necesaria para poder llevar a cabo las tareas de resinación cómodamente, eliminando así combustible y atenuando los posibles efectos de un futuro incendio forestal, y servirá como fijador de población en territorios actualmente despoblados o en riesgo de despoblación como son los territorios rurales.

Por otro lado, de cara al establecimiento de nuevos proyectos de extracción de resina, el soporte que brinda esta aplicación siendo capaz de generar una estimación de la cantidad de masas en las que se deberá de realizar el aprovechamiento resinero, así como predecir la cantidad de resina que se obtendrán a final de la campaña, pudiendo hacer una previsión de ingresos y gastos y evaluar la rentabilidad del proyecto hará que el riesgo asociado a comenzar un proyecto de este tipo se reduzca.

5. Referencias

- Achim, A., Moreau, G., Coops, N. C., Axelson, J. N., Barrette, J., Bédard, S., Byrne, K. E., Caspersen, J., Dick, A. R., D'Orangeville, L., Drolet, G., Eskelson, B. N. I., Filipescu, C. N., Flamand-Hubert, M., Goodbody, T. R. H., Griess, V. C., Hagerman, S. M., Keys, K., Lafleur, B., ... White, J. C. (2022). The changing culture of silviculture. *Forestry: An International Journal of Forest Research*, 95(2), 143–152. <https://doi.org/10.1093/forestry/cpab047>
- Barbosa, A., Trevisan, R., Hovakimyan, N., & Martin, N. F. (2020). Modeling yield response to crop management using convolutional neural networks. *Computers and Electronics in Agriculture*, 170, 105197. <https://doi.org/10.1016/j.compag.2019.105197>
- Batala, L. K., Qiao, J., Regmi, K., Weiwen, W., & Rehman, A. (2023). The implications of forest resources depletion, agricultural expansion, and financial development on energy demand and ecological footprint in BRI countries. *Clean Technologies and Environmental Policy*, 25(9), 2845–2861. <https://doi.org/10.1007/s10098-023-02575-3>
- Bolonio, D., Sánchez-Canales, M., Jiménez-Oyola, S., Ortega, M. F., Donoso, D., García-Martínez, M.-J., Lapuerta, M., & Canoira, L. (2022). Techno-economic, life cycle, and environmental cost assessment of biojet fuel obtained from *Pinus pinaster* by turpentine hydrogenation. *Sustainable Energy & Fuels*, 6(10), 2478–2489. <https://doi.org/10.1039/D2SE00275B>
- Caudullo, G., Welk, E., & San-Miguel-Ayanz, J. (2017). Chorological maps for the main European woody species. *Data in Brief*, 12, 662–666. <https://doi.org/10.1016/J.DIB.2017.05.007>

- Giurca, A., & Befort, N. (2023). Deconstructing substitution narratives: The case of bioeconomy innovations from the forest-based sector. *Ecological Economics*, 207, 107753. <https://doi.org/10.1016/j.ecolecon.2023.107753>
- Ibrahim, R. L., Huang, Y., Mohammed, A., & Adebayo, T. S. (2023). Natural resources-sustainable environment conflicts amidst COP26 resolutions: investigating the role of renewable energy, technology innovations, green finance, and structural change. *International Journal of Sustainable Development & World Ecology*, 30(4), 445–457. <https://doi.org/10.1080/13504509.2022.2162147>
- López-Álvarez, Ó., Franco-Vázquez, L., & Marey-Perez, M. (2024). Methodological framework for applying divide and conquer approach and machine learning: a case study on pine resin yield. *Under Review*
- López-Álvarez, Ó., Zas, R., & Marey-Perez, M. (2023). Resin tapping: A review of the main factors modulating pine resin yield. *Industrial Crops and Products*, 202, 117105. <https://doi.org/10.1016/j.indcrop.2023.117105>
- Marey-Perez, M., Loureiro, X., Corbelle-Rico, E. J., & Fernández-Filgueira, C. (2021). Different Strategies for Resilience to Wildfires: The Experience of Collective Land Ownership in Galicia (Northwest Spain). *Sustainability*, 13(9), 4761. <https://doi.org/10.3390/su13094761>
- Michavila, S., Moreno-González, V., Labarga, D., Martínez, E., & Acebes, J. L. (2017). El hombre y la resina de pino: desde su uso pasado hasta la actualidad con especial atención en España. *AmbioCiencias*, 15, 21–30. <https://buleria.unileon.es/handle/10612/7542>
- Miina, J., Kurttila, M., Calama, R., de-Miguel, S., & Pukkala, T. (2020). Modelling Non-timber Forest Products for Forest Management Planning in Europe. *Current Forestry Reports*, 6(4), 309–322. <https://doi.org/10.1007/s40725-020-00130-7>
- Neis, F. A., de Costa, F., de Araújo, A. T., Fett, J. P., & Fett-Neto, A. G. (2019). Multiple industrial uses of non-wood pine products. *Industrial Crops and Products*, 130, 248–258. <https://doi.org/10.1016/j.indcrop.2018.12.088>
- Palma, A., Pereira, J. M., & Soares, P. (2016). Short Communication. Resin tapping activity as a contribution to the management of maritime pine forest. *Forest Systems*, 25(2), eSC11. <https://doi.org/10.5424/fs/2016252-08925>
- Sampene, A. K., Li, C., Khan, A., Agyeman, F. O., Brenya, R., & Wiredu, J. (2023). The dynamic nexus between biocapacity, renewable energy, green finance, and ecological footprint: evidence from South Asian economies. *International Journal of Environmental Science and Technology*, 20(8), 8941–8962. <https://doi.org/10.1007/s13762-022-04471-7>
- Soliño, M., Yu, T., Alía, R., Auñón, F., Bravo-Oviedo, A., Chambel, M. R., de Miguel, J., del Río, M., Justes, A., Martínez-Jauregui, M., Montero, G., Mutke, S., Ruiz-Peinado, R., & García del Barrio, J. M. (2018). Resin-tapped pine forests in Spain: Ecological diversity and economic valuation. *Science of The Total Environment*, 625, 1146–1155. <https://doi.org/10.1016/j.scitotenv.2018.01.027>

Tian, H., Zhu, J., He, X., Chen, X., Jian, Z., Li, C., Ou, Q., Li, Q., Huang, G., Liu, C., & Xiao, W. (2022). Using machine learning algorithms to estimate stand volume growth of Larix and Quercus forests based on national-scale Forest Inventory data in China. *Forest Ecosystems*, 9, 100037. <https://doi.org/10.1016/j.fecs.2022.100037>

**Comunicación alineada con los
Objetivos de Desarrollo Sostenible**

