



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



Cartografía de modelos de combustible a partir de sensores remotos: el caso de Asturias

SALGADO, L.^{1,2}, COLINA, A.² y LÓPEZ-SÁNCHEZ, C.A.¹

¹ Departamento de Biología de Organismos y Sistemas y SMARTForest Group, Universidad de Oviedo.

² Instituto de Recursos Naturales y Ordenación del Territorio (INDUROT), Campus de Mieres, Universidad de Oviedo.

Resumen

Los incendios forestales son una de las principales perturbaciones del medio natural, produciendo un impacto sobre masas forestales y suelo. En este contexto, la categorización energética de la vegetación, mediante modelos de combustible, es fundamental en tareas de prevención y extinción de incendios. Uno de los principales problemas asociados a los modelos de combustible es su dinamismo y, por tanto, la disponibilidad de cartografía actualizada, debido a los constantes cambios en la cobertura vegetal y la naturaleza ardua y costosa de los inventarios de campo. Con los sensores remotos se incrementa la competitividad del sector forestal, permitiendo obtener información espacialmente continua.

Este trabajo evalúa la cartografía de modelos de combustible obtenida a partir de la primera cobertura de datos LiDAR del Plan Nacional de Ortofotografía Aérea (PNOA-LiDAR) en Asturias (2012, 0,5 puntos m⁻²) e imagen satélite Landsat-5TM (2011) en tres municipios asturianos: Colunga, Somiedo y Valdés, apoyándose en el Cuarto Inventario Forestal Nacional (IFN-4) y el algoritmo de aprendizaje automático Random Forest (RF).

El modelo presenta un buen ajuste en el conjunto de modelos combustibles con precisiones generales de 82,48% (Kappa=0.75), obteniendo ajuste perfecto (Kappa=0,80) para modelos de pastos (Modelos Rothermel 1-2) y de bosques (Modelos Rothermel 8-9).

Palabras clave

Métrica LIDAR, machine learning, Inventario Forestal Nacional, sensores remotos, Rothermel.

1. Introducción

Los incendios forestales son una de las principales perturbaciones del medio ambiente terrestre (Lin et al., 2021). Su proliferación descontrolada en los últimos años ha contribuido a agravar sus efectos, produciendo un efecto directo sobre el suelo, que se degrada a sus etapas más elementales (Chuvieco & Martín, 2004). En el Principado de Asturias, los incendios forestales no son un fenómeno nuevo, ya que el uso del fuego como herramienta tradicional de gestión del territorio está profundamente arraigado en la región (Montiel & Kraus, 2010). La dinámica de los incendios forestales en Asturias se encuentra estabilizada en su número, incluso se reduce, pero hay un aumento significativo en la intensidad, severidad y superficie, especialmente en los Grandes Incendios Forestales (Enríquez Alcalde et al., 2012). Además, el riesgo de incendios forestales y su ocurrencia se ven incrementados debido al calentamiento global (Marino et al., 2016; Moritz et al., 2012). Además de estos factores, se agregan otros, como la extensión del período de incendios (Bowman et al., 2020), la actividad humana (Chuvieco et al., 2021) y las características de la vegetación (Marino et al., 2016).

La categorización de la vegetación en modelos de combustible se convierte en una herramienta de información clave para explicar el comportamiento del fuego (Marino et al., 2016), ya que definen el suministro de energía a los incendios forestales, factor determinante en la propagación del fuego (Chandler et al., 1983). La caracterización de modelos de combustibles es

fundamental en la toma de decisiones, tanto para prevención como en extinción de incendios forestales (Arellano-Pérez et al., 2020; Lamelas-Gracia et al., 2019).

Una de las principales dificultades con referencia a la distribución de tipos de combustibles es la actualización de su cartografía debido a los constantes cambios de vegetación junto con costosas y prolongadas investigaciones de campo (Zhao et al., 2018), pudiendo ser una alternativa el uso de técnicas de teledetección. El empleo de estas técnicas están muy extendidas en estudios forestales, destacando el uso de sensores de escáner láser aerotransportado activos en estudios de la estructura forestal (Marinelli et al., 2018), y multiespectral (Novo-Fernández et al., 2018; Prada et al., 2020).

En España, los datos gratuitos de LiDAR de baja densidad están disponibles a través del Plan Nacional de Ortofotografía Aérea (PNOA). El proyecto PNOA-LiDAR nació de la necesidad de contar con Modelos Digitales de Terreno (DTM) precisos en toda el área nacional. A pesar de que ha sido creado para responder a una necesidad topográfica, existen varias investigaciones que revelan la utilidad de estos datos en aplicaciones forestales (Marino et al., 2016; Novo-Fernández et al., 2019). Por otro lado, se encuentran disponibles gratuitamente diferentes imágenes multiespectrales del programa Landsat de la NASA y el Servicio Geológico de los Estados Unidos (USGS), o la misión Sentinel del Programa Europeo de Observación de la Tierra (GMES) Copernicus. Tanto Landsat como Sentinel, son comunes en los estudios de cobertura forestal (López-Serrano et al., 2020; Novo-Fernández et al., 2018; Prada et al., 2020), que pueden integrarse con datos de campo para desarrollar modelos predictivos en el ámbito forestal.

Para escalas espaciales mayores que el rodal o el paisaje, se puede utilizar el Inventario Nacional de Bosques (IFN) español como datos de campo (Adame et al., 2020; Barrio-Anta et al., 2020), de modo que las limitaciones económicas que caracterizan a estos estudios quedarían resueltas.

Se han utilizado muchas técnicas para desarrollar modelos predictivos para caracterizar dinámicas forestales a partir de métricas LiDAR y / o datos multiespectrales con métodos paramétricos (Lin et al., 2021) o métodos no paramétricos (Fernandez-Manso et al., 2019; Quintano et al., 2020) o ambos (Adab et al., 2021; Marino et al., 2020). Los métodos paramétricos dependen de la distribución de los datos, la selección de predictores altamente correlacionados con poca justificación física requieren normalidad, homocedasticidad e independencia en los datos para ser utilizados adecuadamente (Demšar, 2006; García-Gutiérrez et al., 2015). Sin embargo, las técnicas de aprendizaje automático (ML) de los últimos años surgen como las técnicas más populares ya que permiten abordar las limitaciones de la regresión lineal múltiple (MLR) (Chen et al., 2012; García-Gutiérrez et al., 2015), siendo el algoritmo Random Forest (RF) uno de los más comúnmente utilizados en estudios forestales (Novo-Fernández et al., 2019).

2. Objetivos

El objetivo general de este trabajo es la obtención de mapas de modelos de combustible a partir de datos PNOA-ALS y Landsat-5 Thematic Mapper (TM) en tres municipios que representan la heterogeneidad del Principado de Asturias: Colunga, Somiedo y Valdés (Figura 1), apoyados en el Cuarto Inventario Forestal Nacional (IFN-4) y algoritmos de aprendizaje automático.

A su vez, este objetivo general engloba los siguientes objetivos específicos:

Objetivo 1: Validación de los datos del IFN-4 como datos de campo y su utilización en estudios de clasificación mediante métodos no paramétricos.

Objetivo 2: Validación del uso del algoritmo Random Forest.

Objetivo 3: Validación de los resultados para cada uno de los modelos de combustible propuestos por Rothermel (1972).

3. Metodología

Datos

Las fuentes de datos utilizadas en este estudio son: (i) los datos de la primera cobertura LiDAR del Plan Nacional de Ortofotografía Aérea del Ministerio de Transporte, Movilidad y Agenda Urbana, cuya densidad es de 0.5 puntos m⁻²; (ii) imagen Landsat 5 Thematic Mapper (TM) compuesta por siete bandas espectrales con una resolución de 30 m/píxel a excepción de la banda térmica que es de 120 m/píxel obtenidas por el USGS; y (iii) los datos del Cuarto Inventario Forestal Nacional de España (IFN-4) del Ministerio de Agricultura, Pesca y Alimentación.

Los datos del IFN-4 representan los datos de campo y, por lo tanto, la variable a modelizar, mientras que los datos de sensores remotos, formados por el conjunto de la primera cobertura PNOA-LiDAR e imagen Landsat 5-TM son la fuente de datos para obtener las variables dependientes en la modelización de los modelos de combustible.

Los modelos de combustible utilizados para la clasificación son los de Rothermel (1972), por ser los capturados en las bases de datos de campo del IFN-4. Los modelos de combustible 3, 10, 11, 12 y 13 no se tienen en cuenta en este estudio dada su poca representatividad en el territorio asturiano. Los modelos 1 y 2 se agrupan en un solo grupo, al igual que los modelos 8 y 9, debido a su similitud dentro de Asturias.

A partir de los datos de la primera cobertura PNOA-LiDAR se obtienen las métricas que describen la estructura vertical y horizontal de la vegetación (Tabla 1). También se utiliza el Modelo Digital del Terreno de 5 metros (MDT-5) para el cálculo de variables topográficas (Tabla 2). El MDT-5 se obtiene a partir de los datos de la 1ª cobertura PNOA-LiDAR y está a disposición de los usuarios a través del Centro de Descargas del CNIG.

A partir de los datos multiespectrales LANDSAT 5-TM se obtienen las variables asociadas a cada una de las bandas e índices espectrales calculados a partir de las mismas (

Tabla 3).

Armonización de los datos del IFN-4

Los datos del IFN-4 presentan discordancias temporales con respecto a los datos de la primera cobertura PNOA-LiDAR y los datos del sensor Landsat 5-TM por lo que requiere de una armonización temporal de los mismos. Las parcelas del IFN-4 se encuentran geolocalizadas según una cuadrícula UTM de 1 km de lado para las coberturas forestales, por lo que el tamaño de muestra de algunos modelos de combustible es escasa o nula, siendo necesario completar la base de datos de parcelas de campo.

- Armonización temporal

Uno de los principales problemas del uso de fuentes de datos públicas es la no concordancia temporal de las fechas de recogida de los datos, presentándose este problema en este estudio (Tabla 4). Para minimizar este efecto se realiza una fotointerpretación de los datos del IFN-4 al año 2011 a través de la ortofotografía aérea PNOA de septiembre de 2011.

- Completar la base de datos de parcelas de campo.

Tal y como se observa en la Tabla 5, algunos modelos de combustibles no están presentes, o bien el tamaño de muestra no es lo suficientemente representativo, debido a que las parcelas del IFN-4 se ubican en donde la cobertura del suelo es mayoritariamente forestal arbolada. Esto

provoca que no se pueda realizar el estudio para algunos modelos de combustible o que los resultados no sean confiables. Para subsanar esta limitación, se complementa la base de datos de campo con todas las parcelas definidas por cada vértice de cuadrícula UTM de 1x1 km. Para determinar el modelo de combustible se realiza una fotointerpretación de forma análoga a la armonización temporal.

Modelización

El proceso de modelización entre los datos IFN-4 armonizados, que funciona como variable independiente, y los datos de sensores remotos, variables dependientes, se basa en el ajuste del modelo predictivo.

- Ajuste del modelo predictivo

El algoritmo utilizado para la modelización es Random Forest (RF). RF es un método de clasificación y regresión no paramétrica basado en el uso de un conjunto de árboles de decisión. Se basa en el uso de múltiples árboles de decisión desarrollados con variables independientes, seleccionadas al azar del conjunto original completo de variables. Para la selección de subconjunto de variables óptimo se aplican algoritmos de búsqueda *Wrapper* (Xu & Wang, 2010).

Con el software de código abierto *R Core Team, (2013)* se implementa el algoritmo RF a la modelización. El método de selección de parámetros es *CVParameter* y su selección se realiza mediante validación cruzada k-fold, mediante un conjunto de validación cruzada de 10 iteraciones. La bondad de ajuste del modelo se evalúa mediante el estadístico *Kappa*.

4. Resultados

Armonización de los datos del IFN-4

Como resultados de la armonización de los datos correspondientes al IFN-4 se pasa de 154 a 756 parcelas (Figura 1), con tamaños de muestra mayores a 15 parcelas de todos los modelos de combustible, con excepción del modelo 05, asociado a matorral denso con porte menor a 1 metro (Tabla 6).

Modelización

Como resultado del proceso de selección de variables, se selecciona un subconjunto óptimo de 12 variables, de un total de 54, mediante el método *Wrapper* (Xu & Wang, 2010) (Figura 2).

Los resultados indicaron que las variables para estimar modelos de combustible, mediante técnicas de clasificación, se pueden dividir en tres grupos:

- Las variables topográficas derivadas del MDT-5 (PNOA; www.pnoa.ign.es), son 5; siendo el grupo de mayor importancia con un 41 % de contribución al modelo. En este grupo se encuentra la cuarta variable en importancia individual, la humedad.
- Las variables de métricas de altura y métricas de cobertura del dosel de copas derivadas de datos LiDAR son 4; siendo el segundo grupo en importancia con un 38 %. En este grupo se encuentra la primera, segunda y tercera variable en importancia de forma individual, fracción de cabida cubierta del matorral, altura máxima del matorral y fracción de cabida cubierta del arbolado.
- Las variables derivadas de la imagen Landsat 5 – TM multiespectral representan el 20 % de la importancia de las variables, siendo la categoría minoritaria.

El resultado del modelo presenta un buen ajuste en el conjunto de los modelos combustibles (Kappa=0.75), obteniendo un elevado nivel de ajuste para los modelos 01- 02 y 08-09, con Kappa de 0.80 (Tabla 7). El modelo 05 presenta una kappa=1, pero dado su reducido tamaño de muestra, presenta un resultado resulta poco representativo.

5. Discusión

Comparando con otros estudios de modelos de combustibles a partir de datos de teledetección, García et al. (2011) obtiene precisiones generales superiores al 88% (kappa=0.86) con densidades de retornos LiDAR entre 1.5 y 6 puntos m⁻² y resolución espacial de la imagen multiespectral de 2 m² y ajuste mediante el algoritmo de aprendizaje automático Support Vector Machine (SVM). Marino et al. (2016) obtiene precisiones generales similares (82%, kappa=0.77 y 70 %, kappa=0.68) con densidades de retornos LiDAR superiores (1 punto m⁻²) y resolución espacial superior (25 m²) con el mismo algoritmo de aprendizaje automático que el desarrollado en este trabajo. Revilla et al., (2021) realiza un estudio de modelos de combustible según la clasificación de Prometheus a partir de los datos PNOA LiDAR de 2011 (densidad de pulsos de 0.5 puntos m⁻²) y 2016 (densidad de pulsos de 1 punto m⁻²) con una precisión global de los modelos del 88.5 % y del 93.8 %, respectivamente, siendo valores superiores a los obtenidos en el presente estudio, estando condicionado por el método de clasificación de modelos de combustible.

6. Conclusiones

Este trabajo presenta una metodología para la armonización de los datos del IFN-4 con respecto a los datos PNOA-LiDAR de primera cobertura y datos multiespectrales del sensor Landsat-5 TM para estimar modelos de combustible en tres municipios de Asturias en el año 2012 mediante la aplicación del algoritmo de clasificación de aprendizaje automático Random Forest con un nivel de ajuste del 82,5%.

Esta metodología supone una reducción en el coste económico y de medios a la hora de realizar cartografía de modelos de combustible y la puesta en valor del uso de bases de datos públicas y datos de teledetección gratuitos, obteniendo resultados óptimos y comparables con estudios realizados con datos capturados específicamente para cada estudio, con densidad de retornos LiDAR y resoluciones espaciales superiores.

Los datos de las parcelas del IFN-4 en las áreas de estudio tienen una representatividad baja, aparte de que los datos relativos a modelos de combustibles no son homogéneos en cuanto a la metodología utilizada, siendo unas veces determinados mediante trabajo de campo y otras mediante fotointerpretación, lo que provoca una baja calidad de los mismos, pudiendo desencadenar resultados inexactos o incluso cuestionando la validez de los trabajos.

A pesar de que los resultados generales son elevados, existen diferencias entre los diferentes modelos de combustible, siendo mejores en masas arbóreas y peores en coberturas de matorral bajo.

De cara a futuros trabajos, sería interesante validar las bases de datos de análisis correspondientes a las parcelas del IFN-4 mediante visitas de campo y fotointerpretación de las coberturas vegetales, de forma que se pueda mejorar la capacidad de ajuste de los modelos obtenidos.

7. Agradecimientos

Agradecimiento al Programa de Apoyo y Promoción de la Investigación de la Universidad de Oviedo.

Agradecimiento a Eva Quintanilla y Alejandro Gayo por la ayuda prestada en el procesado de los datos PNOA-LiDAR y datos topográficos con la realización de sus trabajos fin de máster.

8. Bibliografía

ADAB, H., KANNIAH, K. D., & SOLAIMANI, K. (2021). Remote sensing-based operational modeling of fuel ignitability in Hyrcanian mixed forest, Iran. *Natural Hazards*, 1–31. <https://doi.org/10.1007/s11069-021-04678-w>

ADAME, P., CAÑELLAS, I., MORENO-FERNÁNDEZ, D., PACKALEN, T., HERNÁNDEZ, L., & ALBERDI, I. (2020). Analyzing the joint effect of forest management and wildfires on living biomass and carbon stocks in Spanish forests. *Forests*, 11(11), 1–35. <https://doi.org/10.3390/f11111219>

ARELLANO-PÉREZ, S., CASTEDO-DORADO, F., ÁLVAREZ-GONZÁLEZ, J. G., ALONSO-REGO, C., VEGA, J. A., & RUIZ-GONZÁLEZ, A. D. (2020). Mid-term effects of a thin-only treatment on fuel complex, potential fire behaviour and severity and post-fire soil erosion protection in fast-growing pine plantations. *Forest Ecology and Management*, 460, 117895. <https://doi.org/10.1016/j.foreco.2020.117895>

BARRIO-ANTA, M., CASTEDO-DORADO, F., CÁMARA-OBREGÓN, A., & LÓPEZ-SÁNCHEZ, C. A. (2020). Predicting current and future suitable habitat and productivity for Atlantic populations of maritime pine (*Pinus pinaster* Aiton) in Spain. *Annals of Forest Science*, 77(2), 1–19. <https://doi.org/10.1007/s13595-020-00941-5>

BOWMAN, D., WILLIAMSON, G., YEBRA, M., LIZUNDIA-LOIOLA, J., PETTINARI, M. L., SHAH, S., BRADSTOCK, R., & CHUVIECO, E. (2020). Wildfires: Australia needs national monitoring agency. In *Nature* (Vol. 584, Issue 7820, pp. 188–191). Nature Research. <https://doi.org/10.1038/d41586-020-02306-4>

CHANDLER, C., CHENEY, P., THOMAS, P., TRABAUD, L., & WILLIAMS, D. (1983). Fire in forestry. Volume 1. Forest fire behavior and effects. Volume 2. Forest fire management and organization. *Fire in Forestry. Volume 1. Forest Fire Behavior and Effects. Volume 2. Forest Fire Management and Organization*.

CHEN, G., HAY, G. J., & ST-ONGE, B. (2012). A GEOBIA framework to estimate forest parameters from lidar transects, Quickbird imagery and machine learning: A case study in Quebec, Canada. *International Journal of Applied Earth Observation and Geoinformation*, 15(1), 28–37. <https://doi.org/10.1016/j.jag.2011.05.010>

CHUVIECO, E., & MARTÍN, M. DEL P. (2004). *Nuevas tecnologías para la estimación del riesgo de incendios forestales: Librería Agrícola Jerez* (1st ed.). CSIC.

CHUVIECO, E., PETTINARI, M. L., KOUTSIAS, N., FORKEL, M., HANTSON, S., & TURCO, M. (2021). Human and climate drivers of global biomass burning variability. *Science of the*

Total Environment, 779, 146361. <https://doi.org/10.1016/j.scitotenv.2021.146361>

DEMŠAR, J. (2006). Statistical Comparisons of Classifiers over Multiple Data Sets. In *Journal of Machine Learning Research* (Vol. 7).

ENRÍQUEZ ALCALDE, E., DEL MORAL VARGAS, L., CUBO MARÍA, J. E., GALLAR PÉREZ-PASTOR, J. J., JEMES DÍAZ, V., LÓPEZ GARCÍA, M., MATEO DÍEZ, M. L., MUÑOZ CORREAL, A., & PARRA ORGAZ, P. JA. (2012). *Los Incendios Forestales en España*.

FERNANDEZ-MANSO, A., QUINTANO, C., & ROBERTS, D. A. (2019). Burn severity analysis in Mediterranean forests using maximum entropy model trained with EO-1 Hyperion and LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 155, 102–118. <https://doi.org/10.1016/j.isprsjprs.2019.07.003>

GARCÍA-GUTIÉRREZ, J., MARTÍNEZ-ÁLVAREZ, F., TRONCOSO, A., & RIQUELME, J. C. (2015). A comparison of machine learning regression techniques for LiDAR-derived estimation of forest variables. *Neurocomputing*, 167, 24–31. <https://doi.org/10.1016/j.neucom.2014.09.091>

GARCÍA, M., RIAÑO, D., CHUVIECO, E., SALAS, J., & DANSON, F. M. (2011). Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules. *Remote Sensing of Environment*, 115(6), 1369–1379. <https://doi.org/10.1016/j.rse.2011.01.017>

LAMELAS-GRACIA, M. T., RIAÑO, D., & USTIN, S. (2019). A LiDAR signature library simulated from 3-dimensional Discrete Anisotropic Radiative Transfer (DART) model to classify fuel types using spectral matching algorithms. *GIScience and Remote Sensing*, 56(7), 988–1023. <https://doi.org/10.1080/15481603.2019.1601805>

LIN, C., MA, S.-E., HUANG, L.-P., CHEN, C.-I., LIN, P.-T., YANG, Z.-K., & LIN, K.-T. (2021). Generating a Baseline Map of Surface Fuel Loading Using Stratified Random Sampling Inventory Data through Cokriging and Multiple Linear Regression Methods. *Remote Sensing*, 13(8), 1561. <https://doi.org/10.3390/rs13081561>

LÓPEZ-SERRANO, P. M., DOMÍNGUEZ, J. L. C., CORRAL-RIVAS, J. J., JIMÉNEZ, E., LÓPEZ-SÁNCHEZ, C. A., & VEGA-NIEVA, D. J. (2020). Modeling of aboveground biomass with landsat 8 oli and machine learning in temperate forests. *Forests*, 11(1), 11. <https://doi.org/10.3390/f11010011>

MARINELLI, D., PARIS, C., & BRUZZONE, L. (2018). A Novel Approach to 3-D Change Detection in Multitemporal LiDAR Data Acquired in Forest Areas. *IEEE Transactions on Geoscience and Remote Sensing*, 56(6), 3030–3046. <https://doi.org/10.1109/TGRS.2018.2789660>

MARINO, E., RANZ, P., TOMÉ, J. L., NORIEGA, M. Á., ESTEBAN, J., & MADRIGAL, J. (2016). Generation of high-resolution fuel model maps from discrete airborne laser scanner and Landsat-8 OLI: A low-cost and highly updated methodology for large areas. *Remote Sensing of Environment*, 187, 267–280. <https://doi.org/10.1016/j.rse.2016.10.020>

MARINO, E., YEBRA, M., GUILLÉN-CLIMENT, M., ALGEET, N., TOMÉ, J. L., MADRIGAL, J., GUIJARRO, M., & HERNANDO, C. (2020). Investigating live fuel moisture content estimation in fire-prone shrubland from remote sensing using empirical modelling and RTM simulations. *Remote Sensing*, 12(14), 2251. <https://doi.org/10.3390/rs12142251>

MONTIEL, C., & KRAUS, D. (2010). *Best Practices of Fire Use-Prescribed Burning and Suppression Fire Programmes in Selected Case-Study Regions in Europe* (Vol. 24). www.efi.int

MORITZ, M. A., PARIEN, M.-A., BATLLORI, E., KRAWCHUK, M. A., VAN DORN, J., GANZ, D. J., & HAYHOE, K. (2012). Climate change and disruptions to global fire activity. *Ecosphere*, 3(6), art49. <https://doi.org/10.1890/ES11-00345.1>

NOVO-FERNÁNDEZ, A., BARRIO-ANTA, M., RECONDO, C., CÁMARA-OBREGÓN, A., & LÓPEZ-SÁNCHEZ, C. A. (2019). Integration of National Forest Inventory and Nationwide Airborne Laser Scanning Data to Improve Forest Yield Predictions in North-Western Spain. *Remote Sensing*, 11(14), 1693. <https://doi.org/10.3390/rs11141693>

NOVO-FERNÁNDEZ, A., FRANKS, S., WEHENKEL, C., LÓPEZ-SERRANO, P. M., MOLINIER, M., & LÓPEZ-SÁNCHEZ, C. A. (2018). Landsat time series analysis for temperate forest cover change detection in the Sierra Madre Occidental, Durango, Mexico. *International Journal of Applied Earth Observation and Geoinformation*, 73, 230–244. <https://doi.org/10.1016/j.jag.2018.06.015>

PRADA, M., CABO, C., HERNÁNDEZ-CLEMENTE, R., HORNERO, A., MAJADA, J., & MARTÍNEZ-ALONSO, C. (2020). Assessing canopy responses to thinnings for sweet chestnut coppice with time-series vegetation indices derived from Landsat-8 and Sentinel-2 imagery. *Remote Sensing*, 12(18), 3068. <https://doi.org/10.3390/rs12183068>

QUINTANO, C., FERNÁNDEZ-MANSO, A., & ROBERTS, D. A. (2020). Enhanced burn severity estimation using fine resolution ET and MESMA fraction images with machine learning algorithm. *Remote Sensing of Environment*, 244, 111815. <https://doi.org/10.1016/j.rse.2020.111815>

R CORE TEAM. (2013). *R: a language and environment for statistical computing*. R Foundation for Statistical Computing. <http://www.r-project.org/>

REVILLA, S., LAMELAS, M. T., DOMINGO, D., DE LA RIVA, J., MONTORIO, R., MONTEALEGRE, A. L., & GARCÍA-MARTÍN, A. (2021). Assessing the potential of the dart model to discrete return lidar simulation—application to fuel type mapping. *Remote Sensing*, 13(3), 1–21. <https://doi.org/10.3390/rs13030342>

XU, Z., & WANG, X. (2010). Research for information extraction based on wrapper model algorithm. *2nd International Conference on Computer Research and Development, ICCRD 2010*, 652–655. <https://doi.org/10.1109/ICCRD.2010.141>

ZHAO, K., SUAREZ, J. C., GARCIA, M., HU, T., WANG, C., & LONDO, A. (2018). Utility of

multitemporal lidar for forest and carbon monitoring: Tree growth, biomass dynamics, and carbon flux. *Remote Sensing of Environment*, 204, 883–897. <https://doi.org/10.1016/j.rse.2017.09.007>

Tabla 1. Métricas PNOA-LiDAR calculadas por estrato.

Estrato	Variable	Codificación
Matorral	Fracción cabida cubierta	FccMat
	Percentiles de altura 90 y 95	H90M y H95M
	Altura máxima	HMaxM
	Altura mínima	HMinM
	Altura media	HMM
	Desviación estándar	StdM
Arbóreo	Fracción cabida cubierta	FccArb
	Percentiles de altura 90 y 95	H90Arb y H95Arb
	Altura máxima	HMaxArb
	Altura mínima	HMinArb
	Altura media	HMArb
	Desviación estándar	StdArb
Arbóreo + matorral	Continuidad vertical	CRRArbT
	Altura media	HMArbT
	Altura máxima	HMaxArbT
	Altura mínima	HMinArbT

Tabla 2. Variables topográficas calculadas a partir del MDT05 – IGN.

Variable	Codificación
Modelo de alturas	ALTITUD
Modelo de sombras	SOMBRAS
Modelo de pendientes en %	PEND %
Modelo de pendientes en °	PEND °
Modelo de orientaciones	ORI
Modelo de curvatura	CURVATURA
Índice de rugosidad	RUGOSIDAD
Modelo de irradiación día 81 del año (22/03/2012)	IRRA D81
Modelo de irradiación día 250 del año (septiembre)	IRRA D250
Modelo de irradiación día 171 del año (solsticio de verano)	IRRA D171
Índice de humedad	HUMEDAD

Tabla 3. Variables multispectrales (LANDSAT5 TM).

Tipo variable	Variable	Codificación
Bandas	Banda azul (0.450 – 0.515 μm)	BANDA AZUL
	Banda verde (0.525 – 0.605 μm)	BANDA VERDE
	Banda roja (0.630 – 0.690 μm)	BANDA ROJA
	Banda infrarrojo cercano (0.775 – 0.900 μm)	BANDA NIR
	Banda infrarrojo medio (1.550 – 1.750 μm)	BANDA SWIR1
	Banda infrarrojo medio (2.090 – 2.350 μm)	BANDA SWIR2
Índices espectrales	Anthocyanin Reflectance Index	ARI1
	Chlorophyll IndexRedEdge	CHL RE
	Enhanced Vegetation Index	EVI
	Green Normalized Difference Vegetation Index	GNDVI
	Modified anthocyanin reflectance index	mARI
	Modified Chlorophyll Absorption in Reflectance Index	MCARI
	Modified Soil Adjusted Vegetation Index	MSAVI
	Moisture Stress Index	MSI
	Normalized Difference NDII	NDII
	Normalized Burn Ratio	NBR
	Normalized Burn Ratio	NBR2
	Normalized Difference Moisture Index	NDMI
	Normalized Difference Vegetation Index	NDVI
	Pigment specific simple ratio	PSSR
	Soil Adjusted Vegetation Index	SAVI
	Tasseled cap brightness	TCB
	Tasseled cap greenness	TCG
	Tasseled cap wetness	TCW
Tasseled cap angle	TCA	

Tabla 4. Fechas de captura de las diferentes fuentes de datos.

Datos	Landsat 5 - TM	IFN-4	1ª cobertura PNOA-LiDAR
Fecha	12/09/2011	2009 - 2010	05-10/2012

Tabla 5. Número de parcelas por modelo de combustible (Rothermel, 1972).

Modelo de combustible	01	02	04	05	06	07	08	09
Nº de parcelas	0	1	4	38	54	21	26	6

Tabla 6. Número de parcelas por modelo de combustibles (R.C. Rothermel, 1972) armonizados.

Modelo de combustible	No comb	01 - 02	04	05	06	07	08 - 09	Total comb	Total
Nº de parcelas	134	293	19	4	60	117	129	622	756

Tabla 7. Matriz de confusión clasificación de Modelos de Combustible.

Modelo combustible	01-02	04	05	06	07	08-09	Total clasificado	kappa
01-02	258	1	0	8	2	0	269	0.79
04	6	10	0	9	3	3	31	0.50
05	8	0	4	1	0	0	13	1.00
06	17	5	0	42	5	0	69	0.66
07	2	2	0	0	90	17	111	0.72
08-09	2	1	0	0	17	109	129	0.80
Total referencia	293	19	4	60	117	129	622	0.75
							Precisión general	82.48%

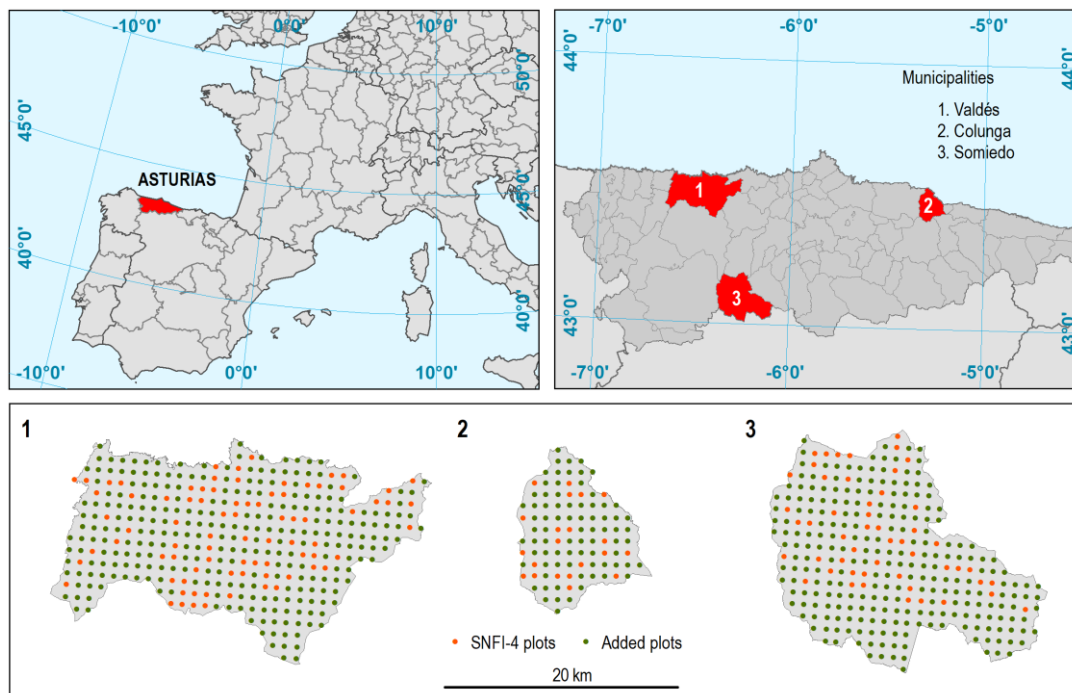


Figura 1. Localización área de estudio.




Figura 2. Variables incluidas en el modelo de importancia de variables (MIV), para las mejores técnicas, incluido el tipo y la importancia de variable para los modelos de combustible.

Importancia normalizada calculada a partir de importancia relativa como $(MIV - MIV_{min}) / (MIV_{max} - MIV_{min})$.