



2025 | **16-20**
GIJÓN | **JUNIO**

9º CONGRESO FORESTAL ESPAÑOL

9CFE-1249

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

Organiza





Predicción espacial de la severidad del fuego en el suelo

NOVO GÓMEZ, A. (1) y FERNÁNDEZ FILGUEIRA, C. (1)

(1) Misión Biológica de Galicia- Centro Superior de Investigaciones Científicas (CSIC)

Resumen

La severidad del fuego en el suelo es un predictor del riesgo de erosión del suelo después de incendio, aunque no se conoce bien qué factores determinan su distribución espacial. La metodología propuesta combina técnicas GIS y de Machine Learning con datos de campo que permiten predecir patrones de severidad del fuego en el suelo, en el incendio de Folgoso do Courel (Lugo) de 2022. Los parámetros analizados potencialmente influyentes en la severidad del fuego en el suelo fueron: los índices (NDVI, NDWI, NBR, dNBR y RdNBR), datos LiDAR (alturas, coberturas, asimetría, kurtosis, FCC, modelos de combustible y número de retornos), y, topográficos (MDT, exposición y orientación). Los resultados de este estudio revelaron que existe una notable relación entre los datos LiDAR analizados y la predicción de severidad del fuego en el suelo. Concretamente, la altura máxima, la orientación y la kurtosis son los parámetros más correlacionados en la predicción de la severidad antes de incendio. Mientras que la altura máxima, índice dNBR, kurtosis y la orientación son determinantes en el modelo de severidad después de incendio.

Palabras clave

Incendios forestales, erosión, teledetección, análisis espacial.

Introducción

Los incendios forestales son un fenómeno común en España. Según los datos registrados en el Sistema de Información de Incendios Forestal Europeo (EFFIS), el área quemada anual media es de 79.570,11 ha con una media de 203,58 incendios en el período 2006-2024 (EFFIS, 2025). En concreto, la temporada de 2022 ha sido extrema para España, siendo el país que registró mayor superficie quemada (315.705 ha) de la Unión Europea (UE) (SAN-MIGUEL-AYANZ, J., et al., 2023), donde se produjeron 57 grandes incendios forestales (> 500 ha). El desarrollo de los grandes incendios se ha correlacionado directamente con la situación meteorológica (SAN-MIGUEL-AYANZ et al., 2022), siendo el año más cálido desde 1961 (AEMET, 2022) y el más seco desde 1950 (SERRANO-NOTIVOLI et al., 2023).

Generalmente, la severidad de un incendio se determina mediante técnicas de teledetección, en concreto a través del uso de índices espectrales como el de diferencia normalizada de área quemada (dNBR) (LLORENS et al., 2021; MILLER



and THODE, 2007; SOVEREL et al., 2010). Esta metodología implica un uso ambiguo del término severidad al no distinguir adecuadamente entre la severidad de la vegetación y la severidad del suelo. El término severidad engloba los impactos causados por el fuego sobre los ecosistemas, clasificándose en severidad de la vegetación en referencia a la estructura y recuperación de la vegetación y, severidad del suelo que tiene en cuenta la respuesta a la erosión (KEELEY, 2009). Por lo tanto, los mapas convencionales de alta severidad pueden no coincidir con la severidad alta en el suelo, o viceversa. Por ejemplo, un incendio de superficie que no haya afectado a una cubierta de copas puede no clasificarse como de alta severidad utilizando imágenes satélites, lo que hace necesario llevar a cabo la verificación de los mapas producidos mediante datos de campo (PARSONS et al., 2010). Las investigaciones actuales centradas en la estimación de la severidad del suelo y la generación de cartografía son escasas (BELTRÁN-MARCOS et al., 2021; KADAKCI KOCA et al., 2024; LLORENS et al., 2024; SOBRINO et al., 2019) debido a la necesidad de recalibración de los datos obtenidos por satélite sobre el terreno, que es costosa y requiere de mucho tiempo. Asimismo, la bibliografía es reducida si el objetivo es la predicción espacial de la severidad del suelo (BELTRÁN-MARCOS et al., 2021; FERNÁNDEZ-ALONSO et al., 2019; KADAKCI KOCA, 2023; SEYDI et al., 2024).

En resumen, la capacidad de predicción y la cartografía de la severidad del suelo podría ser muy útil en la gestión estratégica del combustible de manera preventiva y para la planificación de las actividades de mitigación después de incendio (ROBICHAUD et al., 2007). De hecho, el aumento de la severidad del suelo podría dar lugar a un aumento de la escorrentía y la erosión después de incendio, por lo que la gestión para mitigar los posibles impactos depende de una evaluación precisa de la severidad del suelo (WAGENBRENNER et al. 2023).

En este trabajo se describe una metodología para predecir patrones espaciales influyentes en la severidad del suelo y generar mapas de severidad del suelo en el incendio que tuvo lugar en Folgoso do Courel en el año 2022.

1. Objetivos

El objetivo principal es la modelización de la predicción espacial de la severidad del suelo. Los objetivos específicos son los siguientes:

- Describir las variables explicativas más influyentes en la severidad del suelo.
- Evaluar la importancia de los factores espaciales de predicción.
- Cartografiar la severidad del suelo antes y después de incendio forestal.

2. Metodología

3.1 Área de estudio

El área de estudio se corresponde con el perímetro del incendio forestal que tuvo

lugar en Folgoso do Courel, en la provincia de Lugo (Figura 1), se trata de uno de los incendios de mayor tamaño registrados durante el año 2022 con un total de 13.536 ha calcinadas. El incendio comenzó debido a la caída de rayos durante una tormenta el 15 de julio y se extinguió el 30 de julio (Figura 1). El clima del Courel es oceánico caracterizado por veranos frescos e inviernos fríos y húmedos. Los datos climáticos registrados en el día del incendio, indican que la humedad relativa máxima alcanzó el 80%, con una velocidad del viento a 10 m de 15,4 km/h. La temperatura máxima registrada fue de 36,1 °C mientras que la mínima fue de 22,3°C. El 38,42% del área del incendio de Folgoso presentó una severidad moderada-alta (NOVO et al., 2024).

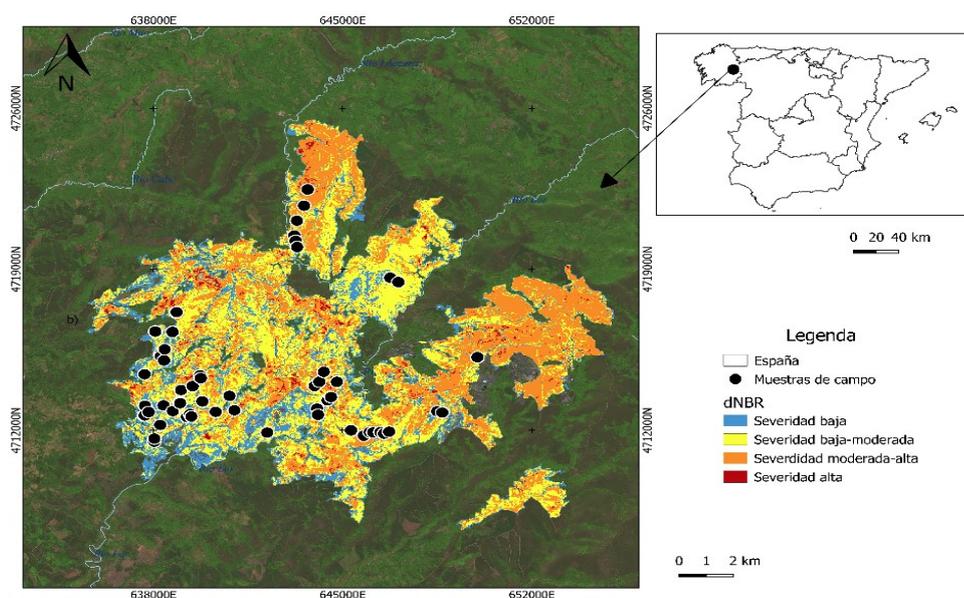


Figura 1. Localización de la zona de estudio, incendio Folgoso do Courel 2022.

3.2 Muestras de campo

La toma de datos de campo se realizó en cuanto fue posible acceder a las zonas quemada, del 28 de julio al 4 de agosto. Se establecieron parcelas de muestreo siguiendo a FERNÁNDEZ, et al., (2021) en una cuadrícula geométrica. Primero se localizó el centro de la parcela y se establecieron dos transectos de 40 m cuyos puntos medios coincidían con el centro de la parcela. A continuación, para evaluar la severidad del suelo, se colocó un cuadrado de 30 cm de lado cada 2 m para determinar los indicadores visuales dominantes de la severidad del incendio. La clasificación de los niveles de severidad del suelo se basa en indicadores visuales de la cubierta orgánica del suelo y de la alteración mineral. La clasificación oscila entre 1 (muy bajo) y 6 (extremo) tal y como especifican FERNÁNDEZ AND VEGA (2016). Sin embargo, en este trabajo se han agrupado en dos categorías baja/moderada y alta/extrema, para diferenciar las áreas que presentan erosión potencial (severidad mayor de 3,5, que engloba las clases alta, muy alta y extrema) de aquellas áreas que no suponen un riesgo alto. Se establecieron un total de 46 parcelas.



2.

3.3.

3.

La metodología seguida para alcanzar el objetivo de este trabajo utilizó el software QGIS (QGIS, 2024) y el software R v 4.3.1. (R CORE TEAM, 2024). En primer lugar, se crearon las capas de cada variable explicativa con las que se construyó la base de datos utilizada en el análisis estadístico, que ha sido analizada mediante la técnica no paramétrica Random Forest (RF) para modelizar el patrón espacial de la severidad del suelo y evaluar la importancia de cada variable explicativa.

2.

Variables explicativas

Los principales factores que influyen en el control y la duración de un incendio son la topografía, el clima y los combustibles (DILLON et al., 2011). La topografía influye indirectamente en la variabilidad espacial de los combustibles (WHITTAKER, 1970), así como sobre las condiciones biofísicas que pueden afectar a la intensidad y duración de los incendios. Por lo tanto, la disponibilidad de datos espaciales que permitan evaluar dichos parámetros son determinantes en la predicción de la severidad del suelo.

Para cada parcela, se extrajo la información de cada variable explicativa utilizada con lo que se construyó la base de datos utilizada en el análisis. A continuación, se describe cada una de las variables explicativas utilizada.

2.

a.

i. Topografía

Las propiedades morfométricas (elevación, pendiente y orientación) se obtuvieron a partir del Modelo Digital de Terreno (MDT) de 25 m de resolución disponible en el Centro Nacional de Información Geográfica (CNIG) (CNIG, 2024) utilizando la biblioteca de análisis topográfico (GDAL) del software QGIS para cada parcela de estudio.

2.

a.

i. Vegetación

Las características de la estructura del combustible que se han considerado en el análisis fueron derivadas de los datos LiDAR (Light Detection and Ranging) adquiridos del Plan Nacional de Ortofotografía Aérea (PNOA) a través del CNIG. El objetivo de la clasificación de la estructura es dividir la vegetación en tres grandes grupos (herbáceas, matorral y árboles) siguiendo el sistema Prometheus (PROMETHEUS, 1999) que adapta la clasificación NFFL (Northern Forest Fire Laboratory) (ALBINI, 1976) a las condiciones mediterráneas.



La nube de puntos LiDAR corresponde al vuelo realizado en el año 2016. El procesamiento de los datos LiDAR se ha realizado con LASTools (LASTOOLS, 2024). El primer paso fue normalizar la nube de puntos que, consiste en transformar el valor de la coordenada Z de cada punto con respecto a la altura del suelo, para ello se utilizó la herramienta lasground. A continuación, se eliminaron los puntos de ruido y se filtraron los puntos pertenecientes a la vegetación, mediante las herramientas lasheight y lasclassify.

Los puntos fueron segmentados en dos grupos: puntos de suelo y puntos de vegetación. Los puntos de vegetación se clasificaron en: herbáceas (alturas < 0,20 m) (aunque no se han considerado en el análisis), matorral (alturas entre 0,20 m y 4 m) y árboles (alturas > 4 m) (PRICE and GORDON, 2016). La nube de puntos de vegetación normalizada correspondiente a cada parcela se utilizó para estimar las métricas estadísticas que representan la estructura de la vegetación. Las métricas consideradas de los retornos LiDAR han sido las siguientes: altura media, mediana, desviación típica, varianza, altura mínima, altura máxima, asimetría, kurtosis, percentil 10, percentil 90, coeficiente de variación. Además, se generó un código en el software R que permitió clasificar los modelos de combustibles siguiendo el modelo de clasificación Prometheus presentes en cada parcela y calcular la cobertura (%) de cada estrato arbóreo, siguiendo la Ecuación 1. Para llevar a cabo el cálculo de las variables se ha utilizado el paquete lidR (ROUSSEL et al., 2020).

$$(1) \text{Cobertura (\%)} = (Pv/At) \times 100$$

La Ecuación 1 compara los píxeles de vegetación (Pv) detectados en el área de estudio, con el área total de estudio (At).

2.

a.

i. Índices espectrales

Las imágenes Sentinel-2 fueron seleccionadas en dos fechas diferentes: antes del incendio (28 de junio) y después del incendio (21 de septiembre) procesadas mediante el software QGIS. Las imágenes se descargaron de la página web Copernicus (<https://dataspace.copernicus.eu/>). El proceso de selección garantizó una nubosidad limitada (< 1%) de las imágenes adquiridas, y el sensor seleccionado fue el Instrumento Multiespectral (MSI), con un procesado de Nivel-2A. Las bandas utilizadas en este estudio fueron las de 10 m y 20 m de resolución por lo que se remuestrearon a 10 m utilizando el algoritmo K-NN de vecinos cercanos.

Se calcularon los siguientes índices directamente relacionados con la severidad del suelo: el índice de vegetación de diferencia normalizada (NDVI) (DÍAZ-DELGADO et al., 2003), el índice humedad de diferencia normalizada (NDWI) (GAO, 1996), el índice normalizado de área quemada (NBR) (KEY and BENSON, 2006), diferencia normalizada de área quemada (dNBR) (MILLER and THODE, 2007) y el índice de diferencia relativa de área quemada (RdNBR) (MILLER and THODE, 2007). Las ecuaciones para calcularlos se muestran en las fórmulas 2-6 respectivamente:



$$(2)NDVI=(NIR+RED)(NIR-RED)$$

$$(3)NDWI=(GREEN-NIR)(GREEN+NIR)$$

$$(4)NBR=(NIR-SWIR)(NIR+SWIR)$$

$$(5)dNBR=NBR_{prefire}-NBR_{posfire}$$

$$(6)RdNBR=(dNBR)(NBR_{prefire})0,5$$

Donde GREEN se corresponde con la banda 3, RED con la banda 4, NIR con la banda 8 y SWIR con la banda 12 del satélite Sentinel-2.

2.

a.

i. Análisis estadístico

Se ha utilizado la técnica no paramétrica RF debido a su eficacia de procesamiento, robustez y fácil aplicación (TALUKDAR et al., 2020). El RF es un método de aprendizaje profundo que utiliza datos de entrenamiento para construir múltiples árboles de decisión e indicar su clase modal. El análisis RF corrige el sobreajuste de la base de datos de entrenamiento aleatoriamente mientras que el resto de los datos se utilizan en el proceso de validación cruzada para producir una estimación de la tasa de error. El algoritmo de aprendizaje automático RF permite modelizar la distribución espacial de la severidad del suelo y evaluar la importancia de cada variable explicativa en cada nivel.

Para la modelización se utilizaron dos conjuntos de datos correspondientes a las condiciones del suelo, el primero antes de incendio forestal en el que se incluyen todas las variables explicativas excepto los índices calculados post incendio y el segundo modelo que incluye todas las variables y los índices dNBR y RdNBR. De este modo, los modelos generados permiten estimar la capacidad del método para predecir la severidad del suelo clasificada previamente en dos niveles: Baja/moderada y Alta/extrema, ajustando las variables explicativas propuestas. Se han evaluado la multicolinealidad de las variables predictoras mediante un análisis de correlación de Pearson, considerando un umbral de 0,75 (OLIVEIRA et al., 2012), y un factor de inflación de la varianza (VIF), considerando los valores inferiores a 5 (colinealidad baja) . Además, se utiliza un modelo logístico binomial como una herramienta exploratoria y explicativa, que determina la influencia de las variables predictoras sobre la severidad del suelo. El modelo logístico binomial permite optimizar el conjunto de datos, eliminando las variables altamente correlacionadas y asegurando que el rendimiento de los modelos RF sea máximo. Por último, utilizando las variables seleccionadas se entrenan los modelos RF para cada conjunto de datos basados en el ajuste de 4.000 árboles de clasificación.



Finalmente se ha elaborado el mapa de predicción de la severidad del suelo utilizando el software QGIS. Primeramente, se generaron las capas ráster de las variables predictivas con mayor importancia, identificadas previamente. A continuación, se normalizaron los valores de Mean Decrease Accuracy asignando pesos proporcionales a cada variable en función de su importancia en la predicción. Posteriormente, se combinaron las variables para obtener el mapa de predicción de severidad con una resolución de 2 m, que es posteriormente es reclasificado en los niveles de severidad baja/moderada y alta/extrema.

3. Resultados

El modelo RF basado en las variables explicativas antes de incendio predice severidad del suelo con una precisión del 69,57% (Tabla 1). Mientras que el modelo después de incendio predice la severidad del suelo con una precisión del 82,61% (Tabla 2).

Tabla 1. Capacidad predictiva del modelo de severidad del suelo antes de incendio (Estimación de error OOB)

Predichos			
Observados		Error (%)	
Baja/moderada	15	8	34,78
Alta/extrema	6	17	26,08
		OOB	30,43

La matriz de confusión muestra errores equilibrados entre las dos clases, con tasas de clasificación errónea idénticas para las clases Alta/extrema y Baja/moderada. El rendimiento predictivo del modelo fue mayor para los niveles de severidad Alta/extrema en el modelo antes de incendio, con una precisión del 74%.

Tabla 2. Capacidad predictiva del modelo de severidad del suelo después de incendio (Estimación de error OOB)

Predichos			
Observados		Error (%)	
Baja/moderada	18	5	21,74
Alta/extrema	3	20	13,04
		OOB	17,39

El modelo después de incendio muestra una tasa de error de predicción menor que el modelo antes de incendio. La matriz de confusión muestra una tasa de error más baja para la clase Alta/extrema (13,04%) que para la clase Baja/moderada (21,74%).

En ambos modelos se determinó la importancia de las variables utilizando el criterio de disminución media de precisión (MDA) que mide el impacto de cada variable en la precisión del modelo. En la Figura 2 se muestra la importancia de las variables explicativas en el modelo antes de incendio.

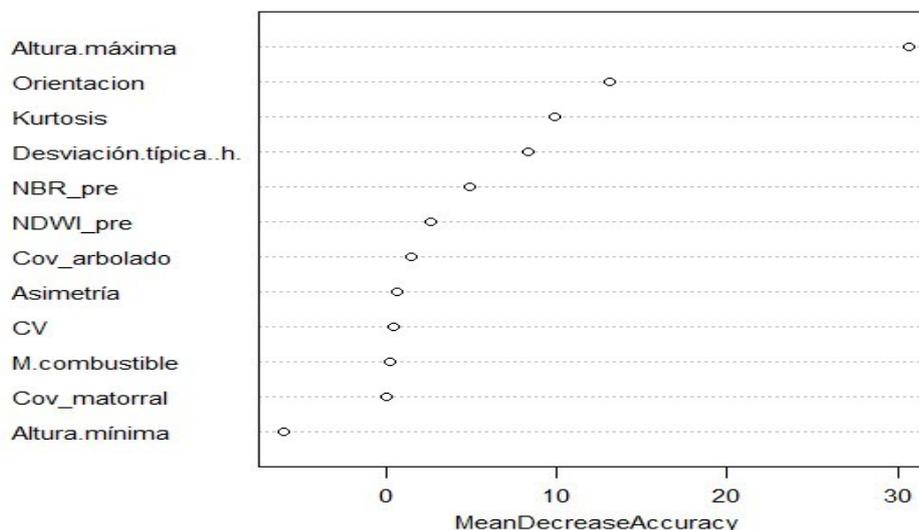


Figura 2. Gráfica de disminución de la precisión media de las variables del modelo antes de incendio Folgoso do Courel, $n=4.000$, $m=3$.

Las variables con mayor importancia para predecir las clases de severidad después de incendio forestal, con MDA superior al 10 %, han sido la altura máxima, la orientación y la curtosis. En la evaluación previa de multicolinealidad se han eliminado del entrenamiento las variables altamente correlacionadas ($> 0,75$) lo que ha mejorado el resultado del modelo de entrenamiento pasando de un OOB de tasa de error del 36,95% al 30,43% con las variables filtradas antes de incendio.

La variable de mayor importancia ha sido la altura máxima en el modelo RF antes de incendio, en la que se ha obtenido un valor 20,46 m en las zonas de alta/extrema severidad y de 14,85 m en las zonas de baja/moderada severidad (Krustall-Wallis, $X^2 = 4,5881$, $p\text{-value} = 0,03219$). Sin embargo, las mayores diferencias significativas según la severidad corresponden a los valores correspondientes a la desviación típica en la altura de los datos LiDAR (Krustall-Wallis, $X^2 = 2,8989$, $p\text{-value} = 0,008114$ con valores de 2,59 m en zonas de severidad baja/moderada y 5,05 m en zonas de severidad alta/extrema). La severidad varía según la orientación (Krustall-Wallis, $X^2 = 7,0081$, $p\text{-value} = 0,0886$), con orientación Sureste en las zonas de severidad baja/moderada y Suroeste en zonas de severidad alta/extrema. Por otro lado, el índice NDWI calculado antes de incendio no muestra cambios significativos según las clases de severidad (Krustall-Wallis, $X^2 = 0,087967$, $p\text{-value} = 0,7668$).

En la Figura 3 se muestra la importancia de las variables explicativas en el modelo después de incendio.

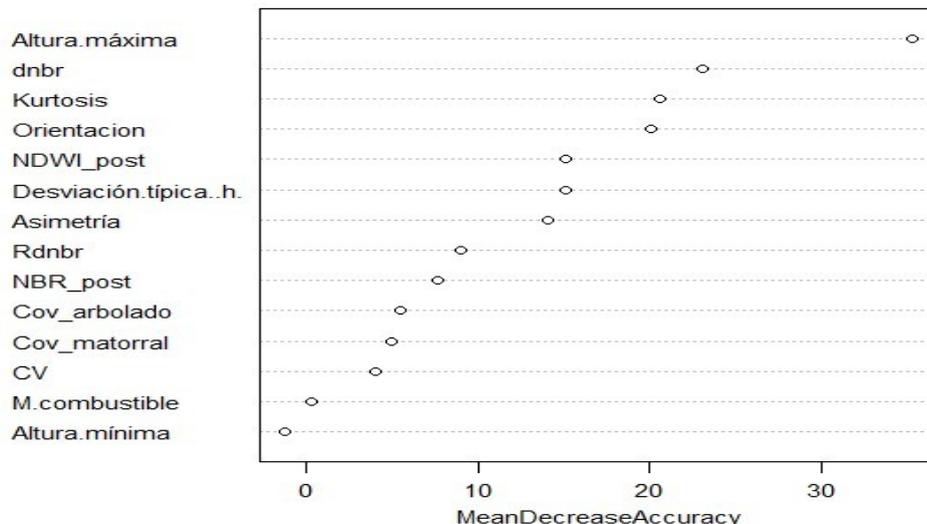


Figura 3. Gráfica disminución de la precisión media después de incendio Folgoso do Courel, n=4.000, m=3.

Las variables con mayor importancia para predecir las clases de severidad después de incendio forestal, con MDA superior al 20%, son la altura máxima, el índice dNBR, la curtosis, y la orientación, además el índice NDWI, desviación típica y asimetría han mostrado una importancia mayor al 10% en la precisión después de incendio.

La variable de mayor importancia ha sido la altura máxima en el modelo RF después de incendio, en la que se ha obtenido un valor 20,39 m en las zonas de alta/extrema severidad y de 15,71 m en las zonas de baja/moderada severidad (Kruskal-Wallis, $X^2 = 4,1296$ p-value =0,04214). Los valores de dNBR han sido más altos en zonas de baja/moderada severidad (0,40) que en zonas alta/extrema severidad (0,33) (Kruskal-Wallis, $X^2 = 6,0004$ p-value =0,0143). Los cambios más significativos entre las diferentes clases de severidad se observan en el índice NDWI calculado después de incendio (Kruskal-Wallis, $X^2 = 10,359$, p-value =0,001289). Por otro lado, la orientación no muestra cambios significativos en este modelo según el tipo de severidad (Kruskal-Wallis, $X^2 = 0,26654$, p-value =0,6057). Por último, los valores de curtosis obtenidos en zonas de severidad alta/extrema (2,75) también difieren de los obtenidos en zonas de severidad baja/moderada (4,80).

La metodología presentada permite generar el mapa de predicción de severidad del suelo basado en el modelo RF después de incendio forestal. En el mapa (Figura 4) se representan las áreas clasificadas en dos niveles de severidad baja/moderada y alta/extrema. Para su elaboración, se seleccionaron las variables predictivas que tuvieron mayor contribución significativa en el modelo (Mean Decrease Accuracy > 20), concretamente: altura máxima, dNBR, curtosis y orientación. La clasificación binaria se realizó utilizando como umbral el valor medio del ráster, lo que permitió distinguir objetivamente las zonas con mayor severidad.

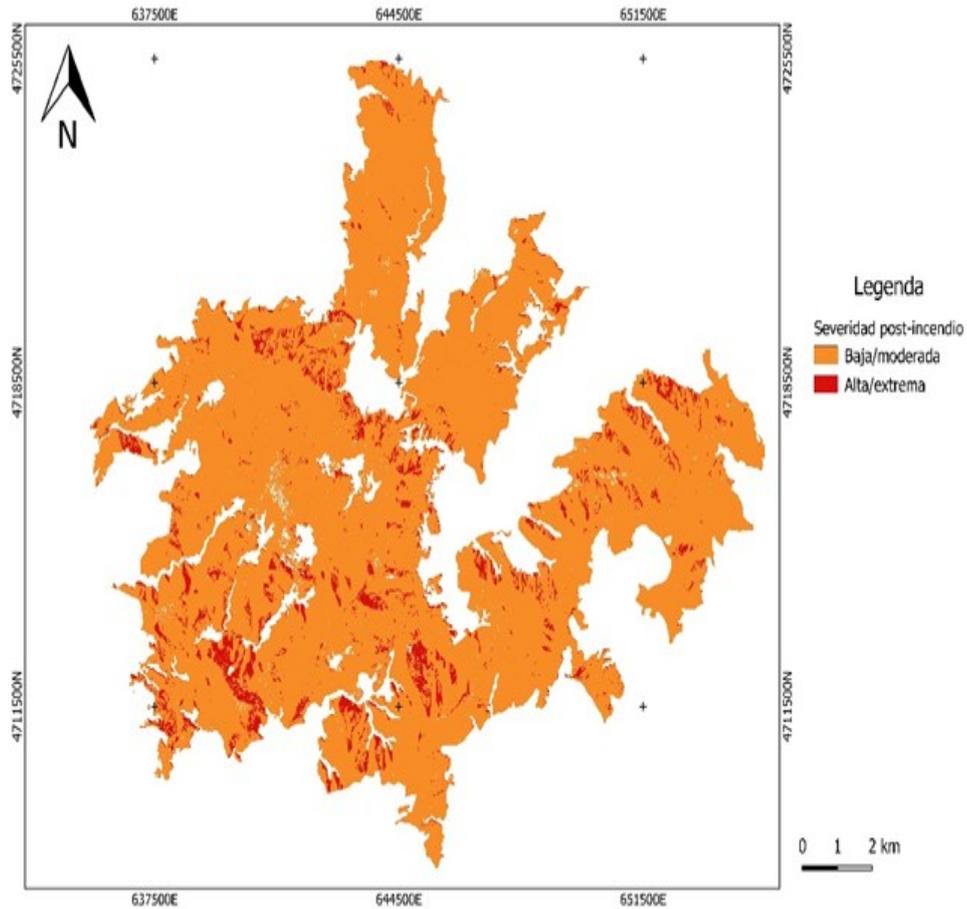


Figura 4. Mapa predictivo de la severidad del suelo en el modelo RF después de incendio forestal.

En la matriz de confusión (Tabla 3) muestra una evaluación detallada de la precisión de la cartografía generada, con una precisión del 58%. La clase alta/extrema fue clasificada incorrectamente aproximadamente el 52% de las veces, mientras que en la clase baja/moderada el error de clasificación fue del 31%. Estos resultados sugieren que el modelo predice con mayor exactitud la clase baja/moderada (69%), aunque presenta tendencia a subestimar la clase alta/extrema. Por otro lado, los valores de precisión del usuario (57% para la clase baja/moderada y 61% para la clase alta/extrema) reflejan una capacidad moderada del modelo para asignar correctamente las clases predichas en la cartografía generada.

Tabla 3. Matriz de confusión mapa predictivo severidad del suelo.

Predichos			
Observados	Error de omisión		
Baja/moderada	16	7	0.31
Alta/extrema	12	11	0.52

Los resultados obtenidos, sugieren que el modelo tiene un desempeño desigual para las dos clases, con mejor precisión para la clase alta/extrema

4. **Discusión**

La elaboración de un mapa de severidad del suelo es un paso importante en el proceso de evaluación de los daños ocasionado después de incendio forestal (PARSONS et al., 2010). Los mapas de severidad del suelo permiten, identificar las zonas que puedan suponer un riesgo de erosión del suelo dentro del área quemada, reflejando los efectos del incendio sobre el terreno, además de identificar las áreas prioritarias de intervención. Por lo tanto, es crucial elaborar mapas de severidad del suelo lo antes posible o incluso determinar una metodología que permita predecir la severidad del suelo antes de incendio forestal. El objetivo principal de este trabajo fue desarrollar una metodología que permita predecir la distribución espacial de la severidad del suelo. Mediante el uso combinado de datos LiDAR, satelitales y topográficos y su posterior modelado, se han obtenido resultados prometedores en cuanto a la predicción de la severidad del suelo con una precisión del 80% en el modelo después de incendio forestal.

La altura máxima de la vegetación, la orientación del terreno y la curtosis han sido las variables explicativas con mayor influencia en ambos modelos desarrollados. En concreto se han obtenido valores de altura de vegetación entorno a los 15 m para las áreas con severidad el suelo baja/moderada y entorno a los 20 m para las áreas de severidad alta/moderada en ambos modelos. La curtosis de los datos LiDAR muestra información relevante en cuanto a las características estructurales de la vegetación, obteniendo valores más bajos (2,75) para las zonas de severidad alta/moderada lo que indica la pérdida de vegetación y un perfil de altura más disperso después de incendio. La orientación ha demostrado ser una variable importante en ambos modelos, sin embargo, no se han observado cambios significativos en las clases de severidad después de incendio forestal.

Los resultados muestran una mejora considerable en la precisión del modelo después de incendio en concordancia con (FERNÁNDEZ-ALONSO et al., 2019). La predicción después de incendio puede mejorar el rendimiento de clasificación debido a los cambios sufridos en la vegetación. Del mismo modo que FERNÁNDEZ



ALONSO et al., (2019) la predicción de la clase Alta/extrema muestra mejores resultados que la predicción de la clase Baja/moderada, con errores del 21,74% para después de incendio y 34,78% antes de incendio forestal. En cuanto a la importancia de las variables explicativas, se obtienen diferencias importantes con respecto del trabajo actual. Las variables con mayor importancia predictiva en el presente trabajo después de incendio han sido: la altura máxima de la vegetación, el índice dNBR, la orientación y la curtosis, frente a la asimetría, índice RdNBR, CV de las alturas y la altura mínima obtenido por FERNÁNDEZ-ALONSO et al., (2019).

Los índices multiespectrales mostraron ser útiles en la evaluación de la severidad del suelo (BELTRÁN-MARCOS et al., 2021). En concreto, estos autores indican que el índice NDWI es el que mejores resultados obtiene en su investigación ya que se relaciona fuertemente con el índice de quema de suelo compuesto (CBSI), mostrando una capacidad de predicción global de 0,83. En nuestro estudio el índice NDWI también forma parte de las variables explicativas propuestas, mostrando mejor capacidad predictiva en el modelo después de incendio forestal, siendo la variable en la que se muestran los cambios más significativos entre las diferentes clases de severidad.

TÜMAY et al., (2024) determinaron los parámetros edáficos más representativos en la severidad del suelo mediante el uso de índices espectrales y la temperatura de la superficie del terreno, con temperaturas de 300 °C en zonas de severidades altas. Se trata de un trabajo experimental en laboratorio que subraya la importancia de combinar el índice dNBR con las observaciones del terreno. Al igual que en la investigación actual, el índice dNBR es la segunda variable con mayor importancia en el modelo predictivo después de incendio forestal, con valores más altos en zonas de baja/moderada severidad (0,40) que en zonas alta/extrema severidad (0,33).

5. Conclusiones

La cartografía de la severidad del suelo es crucial de cara a la gestión estratégica del combustible de manera preventiva y para la planificación de las actividades de mitigación después de incendio. Por otro lado, es necesario establecer una metodología que permita discriminar entre la severidad de la vegetación y la severidad del suelo espacialmente ya que existe poca bibliografía sobre la modelización de la predicción espacial de la severidad en el suelo.

En este trabajo se presenta una metodología que permite predecir la severidad del suelo mediante el uso de los sistemas de información geográfica (QGIS) y el software estadístico R. Se determinan dos modelos mediante el uso del algoritmo RF antes de incendio forestal y después de incendio forestal para predecir la distribución de las categorías de severidad previamente examinadas en campo. La importancia relativa de las variables explicativas proporciona información útil sobre los factores determinantes en la clasificación de la severidad del suelo, siendo la altura de la vegetación la variable con mayor importancia en ambos modelos predictivos en el caso del incendio de estudio localizado en Folgoso do



Courel en 2022 . El resultado final es la cartografía espacial de la severidad del suelo.

6. Agradecimientos

Ana Novo quiere dar las gracias al Ministerio de Ciencia e Innovación de España a través de la subvención JDC2022-049758-I. Este trabajo ha sido financiado por el proyecto ENFIRES-NW, PID2020-116494RR-C42. Los autores quieren dar las gracias al personal del Centro de Investigación Forestal de Lourizán por su apoyo en los trabajos de campo. En especial a J. Pardo, I. Losada y P. López y J. Gómez.

7. Bibliografía

AEMET, 2022. España ha vivido el verano más caluroso de su serie de datos. Agencia Estatal de Meteorología. URL <https://cutt.ly/L1XeeDk>
ALBINI, F. A. (1976). Estimating wildfire behavior and effects (Vol. 30). Department of Agriculture, Forest Service, Intermountain Forest and Range Experiment Station.

BELTRÁN-MARCOS, D., SUÁREZ-SEOANE, S., FERNÁNDEZ-GUISURAGA, J.M., FERNÁNDEZ-GARCÍA, V., PINTO, R., GARCÍA-LLAMAS, P., CALVO, L., 2021. Mapping soil burn severity at very high spatial resolution from unmanned aerial vehicles. *Forests* 12, 179.

CNIG, 2024. Centro Nacional de Información Geográfica. Available online: <https://www.cnig.es/home> (accessed on 11 December 2024).
A European Forest Fire Information System (EFFIS). Available online: <https://forest-fire.emergency.copernicus.eu/apps/effis.statistics/> (accessed on 13 January 2025).

DÍAZ-DELGADO, R., LLORET, F., PONS, X., 2003. Influence of fire severity on plant regeneration by means of remote sensing imagery. *Int. J. Remote Sens.* 24, 1751–1763.

DILLON, G.K., HOLDEN, Z.A., MORGAN, P., CRIMMINS, M.A., HEYERDAHL, E.K., LUCE, C.H., 2011. Both topography and climate affected forest and woodland burn severity in two regions of the western US, 1984 to 2006. *Ecosphere* 2, 1–33.

FERNÁNDEZ-ALONSO, J.M., FERNÁNDEZ, C., ARELLANO, S., VEGA, J.A., 2019. Modeling soil burn severity prediction for planning measures to mitigate post wildfire soil erosion in NW Spain, in: *Spatial Modeling in GIS and R for Earth and Environmental Sciences*. Elsevier, pp. 589–606.

CRISTINA FERNÁNDEZ, JOSÉ M FERNÁNDEZ-ALONSO, JACOB KEIZER, A. GIRONA-GARCÍA. Guía Para la Evaluación de Campo de la Severidad del Fuego en el Suelo. Xunta de Galicia (2021)

FERNÁNDEZ, C., VEGA, J.A., 2016. Modelling the effect of soil burn severity on soil erosion at hillslope scale in the first year following wildfire in NW Spain. *Earth Surf. Process. Landforms* 41, 928–935.

GAO, B.-C., 1996. NDWI—A normalized difference water index for remote sensing of vegetation liquid water from space. *Remote Sens. Environ.* 58, 257–266.

KADAKCI KOCA, T., 2023. A statistical approach to site-specific thresholding for burn severity maps using bi-temporal Landsat-8 images. *Earth Sci. Informatics* 16,



1313–1327.

KADAKCI KOCA, T., KÜÇÜKUYSAL, C., GÜL, M., ESETLILI, T., 2024. A comprehensive approach to soil burn severity mapping for erosion susceptibility assessment. *CATENA* 245, 108302. <https://doi.org/https://doi.org/10.1016/j.catena.2024.108302>

KEELEY, J.E., 2009. Fire intensity, fire severity and burn severity: a brief review and suggested usage. *Int. J. Wildl. fire* 18, 116–126.

KEY, C.H., BENSON, N.C., 2006. Landscape assessment (LA). *FIREMON Fire Eff. Monit. Invent. Syst.* 164, LA-1.

LASTOOLS, 2024. Rapidlasso GmbH “LAStools—Efficient LiDAR Processing Software” (Academic) . URL <https://rapidlasso.com/lastools/> (accessed 4.12.24).

LLORENS, R., SOBRINO, J.A., FERNÁNDEZ, C., FERNÁNDEZ-ALONSO, J.M., VEGA, J.A., 2024. Soil Burn Severity Assessment Using Sentinel-2 and Radiometric Measurements. *Fire* 7. <https://doi.org/10.3390/fire7120487>

LLORENS, R., SOBRINO, J.A., FERNÁNDEZ, C., FERNÁNDEZ-ALONSO, J.M., VEGA, J.A., 2021. A methodology to estimate forest fires burned areas and burn severity degrees using Sentinel-2 data. Application to the October 2017 fires in the Iberian Peninsula. *Int. J. Appl. Earth Obs. Geoinf.* 95, 102243.

MILLER, J.D., THODE, A.E., 2007. Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR). *Remote Sens. Environ.* 109, 66–80. <https://doi.org/https://doi.org/10.1016/j.rse.2006.12.006>

NOVO, A., FERNÁNDEZ, C., MÍGUEZ, C., SUÁREZ-VIDAL, E., 2024. Analysing the capacity of multispectral indices to map the spatial distribution of potential post-fire soil losses based on soil burn severity. *Ecol. Inform.* 83, 102793. <https://doi.org/https://doi.org/10.1016/j.ecoinf.2024.102793>

OLIVEIRA, S., OEHLER, F., SAN-MIGUEL-AYANZ, J., CAMIA, A., PEREIRA, J.M.C., 2012. Modeling spatial patterns of fire occurrence in Mediterranean Europe using Multiple Regression and Random Forest. *For. Ecol. Manage.* 275, 117–129.

PARSONS, A., ROBICHAUD, P.R., LEWIS, S.A., NAPPER, C., CLARK, J.T., 2010. Field guide for mapping post-fire soil burn severity. Gen. Tech. Rep. RMRS-GTR-243. Fort Collins, CO: US Department of Agriculture, Forest Service, Rocky Mountain Research Station. 49 p.,243.

PRICE, O.F., GORDON, C.E., 2016. The potential for LiDAR technology to map fire fuel hazard over large areas of Australian forest. *J. Environ. Manage.* 181, 663–673.

PROMETHEUS, S. V, 1999. Project (Management techniques for optimization of suppression and minimization of wildfire effects. System Validation). Eur. Comm. number ENV4-CT98-0716.

QGIS, 2024. Geographic Information System. Development Team Open Source Geospatial Foundation Project. . URL <https://qgis.org>

R CORE TEAM, 2024. The R Project for Statistical Computing. URL <https://www.r-project.org/> (accessed on 11 November 2024).

ROBICHAUD, P.R., LEWIS, S.A., LAES, D.Y.M., HUDAK, A.T., KOKALY, R.F., ZAMUDIO, J.A., 2007. Postfire soil burn severity mapping with hyperspectral image unmixing. *Remote Sens. Environ.* 108, 467–480.

ROUSSEL, J.-R., AUTY, D., COOPS, N.C., TOMPALSKI, P., GOODBODY, T.R.H.,



MEADOR, A.S., BOURDON, J.-F., DE BOISSIEU, F., ACHIM, A., 2020. lidar: An R package for analysis of Airborne Laser Scanning (ALS) data. *Remote Sens. Environ.* 251, 112061.

SAN-MIGUEL-AYANZ, J., DURRANT, T., BOCA, R., MAIANTI, P., LIBERTA`, G., JACOME FELIX OOM, D., BRANCO, A., DE RIGO, D., SUAREZ-MORENO, M., FERRARI, D., ROGLIA, E., SCIONTI, N., BROGLIA, M., ONIDA, M., TISTAN, A. AND LOFFLER, P., 2023. Forest Fires in Europe, Middle East and North Africa 2022. Luxembourg (Luxembourg). <https://doi.org/10.2760/348120>

SERRANO-NOTIVOLI, R., TEJEDOR, E., SARRICOLEA, P., MESEGUER-RUIZ, O., DE LUIS, M., SAZ, M.Á., LONGARES, L.A., OLCINA, J., 2023. Unprecedented warmth: A look at Spain's exceptional summer of 2022. *Atmos. Res.* 106931.

SEYDI, S.T., ABATZOGLOU, J.T., AGHAKOUCHAK, A., POURMOHAMAD, Y., MISHRA, A., SADEGH, M., 2024. Predictive Understanding of Links Between Vegetation and Soil Burn Severities Using Physics-Informed Machine Learning. *Earth's Futur.* 12. <https://doi.org/10.1029/2024EF004873>

SOBRINO, J.A., LLORENS, R., FERNÁNDEZ, C., FERNÁNDEZ-ALONSO, J.M., VEGA, J.A., 2019. Relationship between soil burn severity in forest fires measured in situ and through spectral indices of remote detection. *Forests* 10, 457.

SOVEREL, N.O., PERRAKIS, D.D.B., COOPS, N.C., 2010. Estimating burn severity from Landsat dNBR and RdNBR indices across western Canada. *Remote Sens. Environ.* 114, 1896–1909.

TALUKDAR, S., SINGHA, P., MAHATO, S., SHAHFAHAD, PAL, S., LIOU, Y.-A., RAHMAN, A., 2020. Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review. *Remote Sens.* <https://doi.org/10.3390/rs12071135>

WAGENBRENNER, JOE COE, DREW OLSEN, W., 2023. Mitigating potential sediment delivery from post-fire salvage logging. State of California, The Natural Resources Agency, Department of Forestry & Fire Protection. 32 p.

WHITTAKER, R.H., 1970. *Communities and ecosystems.*