



2025 | **16-20**
GIJÓN | JUNIO

9º CONGRESO **FORESTAL** ESPAÑOL

9CFE-1478

Organiza





Desarrollo y validación de una herramienta de cálculo de severidad de quemado potencial (Severidad-VIS4FireApp) en grandes incendios forestales de la Comunitat Valenciana (España).

BOTELLA BOU, R. (1)(3), GONZÁLEZ ROMERO, J. (2), PEÑA MOLINA, E. (3), MOYA NAVARRO, D. (3), MARTÍNEZ GARCÍA, A. (3) y MORALES NÚÑEZ, A.I. (4), BOTELLA MARTÍNEZ, M.A. (1).

(1) Valenciana d'Estratègies i Recursos per a la Sostenibilitat Ambiental S.A. (VAERSA). Generalitat Valenciana.

(2) Universidad Politécnica de Madrid. Escuela Técnica Superior de Ingeniería de Montes, Forestal y del Medio Natural. Departamento de Ingeniería y Gestión Forestal y Ambiental.

(3) Universidad de Castilla – La Mancha. Escuela Técnica Superior de Ingeniería Agronómica y de Montes y Biotecnología. Departamento de Producción Vegetal y Tecnología Agraria.

(4) Yotta Desarrollos Tecnológicos.

Resumen

El objetivo es validar una herramienta creada a partir de inteligencia artificial, que permite el cálculo de la severidad de quemado potencial que presenta un territorio ante un incendio forestal (*SeverityApp*), en el sureste peninsular.

Para el desarrollo del presente proyecto, se ha elaborado la cartografía correspondiente a las entradas estáticas y dinámicas que requiere el modelo, así como del índice de severidad *dNBR* de 10 incendios ocurridos en la Comunitat Valenciana entre 2016-2023, mediante el uso de imágenes Landsat 8.

Con el valor de la predicción de la herramienta, y el valor de severidad *dNBR* calculado para cada incendio, se ha realizado una validación mediante comparación, que ha permitido determinar que la herramienta es capaz de predecir de forma correcta el 27,45% la severidad de un incendio en la Comunitat Valenciana, por el momento. Se ha comprobado que la herramienta tiende a subestimar las predicciones, siendo las clases de severidad más extremas las que peor porcentaje de acierto presentan. Este análisis se apoyó en el estadístico Kappa, el cual ha puesto de manifiesto que las relaciones de concordancia son leves, por lo que se plantean correcciones para mejorar el aprendizaje de la herramienta, en base a un análisis bibliográfico de trabajos similares.

Palabras clave

Modelos predictivos, *dNBR*, planificación forestal, prevención de incendios forestales, toma de decisiones.

1. Introducción

Los incendios forestales son alteraciones que producen rasgos adaptativos que evolucionan con el tiempo, dependiendo del régimen y de la intensidad del fuego (KEELEY & PAUSAS, 2022). De hecho, estas perturbaciones han configurado durante muchos años los ecosistemas a nivel global (BUDDE et al., 2014; NYLAND,



2016), e incluso muchos de estos ecosistemas forestales dependen de los incendios para mantener sus hábitats saludables, ya que ayudan a mejorar la diversidad vegetal y a eliminar los combustibles acumulados en el territorio.

A pesar de esto, los incendios también generan impactos negativos sobre las comunidades vegetales, lo que puede provocar una amenaza para la permanencia de las propias comunidades (BROTONS et al., 2013; PEREIRA et al., 2018), ya que el fuego se ha considerado como el elemento que mayor nivel de afectación es capaz de provocar sobre un sistema forestal (GONZÁLEZ-DE VEGA et al., 2016). Además, dependiendo de cuando se produzca la perturbación, va a determinar en gran medida la composición vegetal posterior (LIU et al., 2016), según el tipo de estrategias adaptativas de la vegetación (PAUSAS & KEELEY, 2014) y de la capacidad de supervivencia que tenga el banco de semillas (MOYA et al., 2008). Del mismo modo, la alta recurrencia de incendios, puede provocar que los ecosistemas pierdan su capacidad de recuperarse (DÍAZ-DELGADO et al., 2003; PEREIRA et al., 2018), sobre todo si ocurre con frecuencias cortas de tiempo (TESSLER et al., 2016).

El cambio climático, la falta de gestión de los montes, el cambio de uso en las tierras de cultivo y el aumento de la población, se está traduciendo en un incremento en el régimen natural del número de incendios, así como en la extensión y severidad de estos (DOBLAS-MIRANDA et al., 2015; CASTELLNOU, 2018; MADRIGAL et al., 2019; MARTÍNEZ, 2019). He incluso se está produciendo una descentralización de los incendios en verano, pasando a tener estos eventos de manera generalizada a lo largo de todo el año y no solo en la época estival (MORENO, 2016; MORENO, 2017; CASTELLNOU, 2018), como ha venido sucediendo hasta ahora.

Es importante tener en cuenta la intensidad que presentan los incendios, entendiéndose ésta como la energía que se desprende en el proceso de la combustión (KEELEY, 2009), así como la severidad que éstos tienen, siendo el efecto que causa la intensidad del incendio sobre el suelo y sobre la vegetación, o en cualquiera de sus características, mientras está activo (KEELEY, 2009; KEY & BENSON, 2006). Cuando se producen incendios con altas intensidades y severidades, se provocan alteraciones en los hábitats, los cuales tendrán una recuperación muy lenta, e incluso podrían convertirse en ecosistemas irreversibles, si se sobrepasaran ciertos umbrales de degradación (LENTILE et al., 2006; ROBICHAUD et al., 2016). Esto se debe a que se elimina la mayor parte de la cubierta vegetal, la cual ejerce una función de protección sobre el suelo, así como la materia orgánica que se encuentran en las capas superficiales (NEARY et al., 2005; CERTINI et al., 2011). Además, las partículas finas taponan los huecos de la superficie del suelo, disminuyendo la infiltración de agua en el mismo (NEARY et al., 1999; BEATTY & SMITH, 2013). De este modo, sin cubierta vegetal y con la tasa de infiltración mermada, aumenta la escorrentía superficial, aumentando así la tasa de erosión del suelo (SCOTT, 1993; BEATTY & SMITH, 2013).

Cuando las severidades han sido moderadas o bajas, la vegetación también queda expuesta a nuevas dificultades (GIBSON & NEGRÓN, 2009), como puede ser la aparición de insectos que se alimentan de la madera muerta y en descomposición. Ejemplo de esto son los escolítidos como *Tomicus* sp, *Orthotomicus* sp e *Ips* sp sobre pinares, que no solo atacan a aquellos ejemplares muertos tras el incendio, sino que pueden llegar a matar a ejemplares vivos que se encuentran en zonas cercanas al incendio, y que han sido debilitados tras la perturbación (SANTOLAMAZZA-CARBONE et al., 2011; FERNÁNDEZ-FERNÁNDEZ et al., 2015). Y si estas poblaciones



de insectos llegan a constituir una plaga, podrían provocar la mortalidad de masas forestales sanas cercanas a la zona que ha sido incendiada (KAUSRUD et al., 2012).

Pero no solo hay que tener en cuenta los efectos ambientales de los incendios, ya que también se generan otras perturbaciones, como pueden ser cambios a nivel socioeconómico. Por ejemplo, las materias primas que se han visto afectadas pierden su valor, ya que no se pueden aprovechar de manera total o parcial. El turismo y las actividades de tipo recreativo asociadas al lugar también se pueden resentir, lo que repercutirá en la economía local. Sin olvidar que, las inversiones destinadas a la recuperación de los ecosistemas, implican unos gastos elevados, que irían en detrimento de otras inversiones (GREENPEACE ESPAÑA, 2010).

En la Comunitat Valenciana, y como sucede en la mayoría de los ecosistemas mediterráneos, se agrava esta situación ya que el clima mediterráneo se caracteriza por presentar temperaturas altas y largos periodos de sequía, condición que se prevé que irá a peor en los escenarios previstos de cambio climático (DOBLAS-MIRANDA et al., 2017). Por lo tanto, poder determinar el grado de severidad que presenta un territorio antes de que suceda la perturbación permitiría ayudar a establecer zonas prioritarias de gestión, encaminadas a reducir el grado de afección, además de aumentar los puntos de oportunidad para los medios de extinción (FANG et al., 2018; MITSOPOULOS et al., 2019; COSTA-SAURA et al., 2022; FERNÁNDEZ-GARCÍA et al., 2022).

En esta línea, el equipo de trabajo ECOFOR de la Universidad de Castilla - La Mancha, está desarrollando un modelo predictivo que permite el cálculo de la severidad de quemado potencial que presenta un territorio (*SeverityApp*).

2. Objetivos

El principal objetivo del presente estudio ha sido validar una propuesta metodológica de cálculo de severidad de quemado potencial frente a un incendio forestal (*SeverityApp*) en el territorio de la Comunitat Valenciana (sureste peninsular). Para la consecución de dicho fin, se han establecido los siguientes objetivos secundarios:

- Cálculo de cada una de las variables que intervienen en el cálculo del modelo predictivo.
- Cálculo del índice de severidad *dnBR* de 10 incendios ocurridos en la Comunitat Valenciana, a partir de imágenes Landsat 8.
- Comparativa entre los valores obtenidos mediante la predicción y los valores obtenidos a partir del índice de teledetección *dnBR*.

3. Metodología

Para la validación de la herramienta, se han empleado 10 incendios ocurridos entre los años 2016-2023 en la Comunitat Valenciana, con una superficie total de 46.643,20 hectáreas incendiadas. Se han escogido los que mayor superficie quemada presentaban en los últimos años, así como una distribución lo más equitativa posible por todo el territorio. Además, la variedad en las altitudes y la heterogeneidad de sus ecosistemas los hacen suficientemente representativos de los incendios típicos de la zona de estudio. Su distribución por provincias es:

- Castellón: Soneja (2021), Bejís (2022), Villanueva de Viver (2023).
- Valencia: Chella (2016), Carcaixent (2016), Llutxent (2018), Venta del Moro



(2022), Montitzelvo (2023).

- Alicante: Beneixama (2019), Vall de Ebo (2022).

La herramienta de cálculo de severidad potencial (*SeverityApp*), necesita de varias capas de entrada, las cuales se dividen en dos grandes bloques: bloque estático y bloque dinámico.

Bloque Estático

Se compone de variables cuya información se considera fija en el corto plazo: Modelo Digital del Terreno (MDT), Orientaciones, Pendientes, Fracción de Cobertura Cubierta (LFCC), Altura de la vegetación, Modelos de Combustible (MC), Inflamabilidad y Erosionabilidad. Todas estas variables se han calculado con una resolución espacial de 25 metros.

Para el cálculo del MDT se empleó la cartografía MDT25, disponible en el Plan Nacional de Ortofotografía Aérea (PNOA), y a partir de ella se calcularon las Orientaciones y Pendientes, mediante el uso de Sistemas de Información Geográfica (SIG).

La LFCC y la Altura de la vegetación, se calcularon a partir del análisis de las nubes de datos LiDAR de la segunda cobertura, también disponibles en el PNOA. Para ello se determinó un modelo de elevaciones (*GridSurfaceCreate*, class: 2), y un modelo de copas (*CanopyModel*, class: 3, 4, 5), y a partir de ellos, se estimaron las métricas de las variables deseadas con el uso de la herramienta FUSION/LDV, del USDA Forest Service.

Los MC empleados, son los que ofrece el Institut Cartogràfic Valencià (ICV), que tienen una clasificación en base a los modelos de Rothermel. Éstos se clasificaron en 4 grupos, según la severidad potencial que presenta cada modelos de Rothermel, tal y como se muestra en la siguiente tabla:

Clases	Clases	Severidad Potencial
FT4, GR5(105), GR8(108), GR9(109), GS4(124), SH6(146), SH8(148), SH9(149), SB4(204)	4	Muy alta
FT7, FT6, FT2, GR4(104), GR7(107), GS3(123), SH5(145), SH7(147), SB3(203)	3	Alta
FT10, FT9, FT1, FT3, GR3(103), GR2(102), GS2(122), SH4(144), TU4(164), TL9(189), SB2(202)	2	Media
FT8, FT5, NB1(91), NB2(92), NB3(93), NB8(98), NB9(99), GR1(101), GS1(121), SH3(143), SH2(142), SH1(141), TU1(161), TU2(162), TU3(163), TU5(165), TL1(181), TL2(182), TL3(183), TL4(184), TL5(185), TL6(186), TL7(187), TL8(188), SB1(201)	1	Baja
Sin datos	0	Sin datos

Figura 1: Clasificación de la severidad según los modelos de combustible, según ROTHERMEL (1972) y SCOTT & BURGAN (2005).

La Inflamabilidad se elaboró a partir de las especies principales presentes en el territorio, según el Mapa Forestal Español de máxima actualidad (MFE50). Se clasificó también en 4 grandes grupos (Baja, Media, Alta y Muy Alta), según el nivel de severidad de quemado potencial que presenta la especie principal:



Clases	Códigos	Clases	Severidad Potencial
<i>Acacia dealbata, Ceratonia siliqua, Cupressus arizonica, Cupressus macrocarpa, Eucalyptus camaldulensis, Eucalyptus globulus, otros eucaliptos, Pinus halepensis, Quercus ilex, Sorbus aucuparia, Taxus baccata, Fraxinus ornus, Mezcla de eucaliptus, Pinus canariensis, Phoenix spp, Sorbus aria, Sorbus spp, Sorbus domestica</i>	307, 67, 236, 4 36, 62, 61, 63,24, 45, 378, 14, 355, 60, 27, 69, 278, 78, 478	4	Muy alta
<i>Cedrus atlantica, Cultivo en mosaico, Cupressus sempervirens, Ilex aquifolium, Laurus nobilis, Matorral en mosaico, Myrtus communis, Pastizal-Matorral en mosaico, Phillyrea latifolia, Pinus pinaster, Pinus pinea, Pinus radiata, Pinus uncinata, Prado en mosaico, Quercus suber, Matorral en mosaico, Herbazal en mosaico, Pastizal-matorral en mosaico, cultivo en mosaico, prado en mosaico, Tetraclinis articulata</i>	17,36,65,94,6, 8,26,23,28,22, 46, 8000, 9000, 3500, 3400, 1500, 219	3	Alta
<i>Acacia spp., Ailanthus altissima, Arbutus unedo, Cornus sanguinea, Crataegus lacinata, Crataegus monogyna, Crataegus spp., Herbazal en mosaico, Juniperus communis, Juniperus oxycedrus, Juniperus phoenicea, Juniperus thurifera, Morus spp., otras frondosas, Pinus nigra, Pinus sylvestris, Platanus hispanica, Pseudotsuga menziesii, Quercus faginea, Sambucus nigra, Ulmus minor, Ulmus pumila</i>	7,11,68,9,415, 215,15,37,237, 39,38,399,99,2 5,21,79,34,44, 97,56,356	2	Media
<i>Acer campestre, Acer monspessulanum, Acer opalus, Alnus glutinosa, Amelanchier ovalis, Betula spp., Castanea sativa, Celtis australis, Corylus avellana, Fagus sylvatica, Ficus carica, Fraxinus angustifolia, Fraxinus excelsior, Juglans nigra, Juglans regia, Larix spp., Malus sylvestris, Olea europaea, Pistacia terebinthus, Populus alba, Populus nigra, Populus tremula, Populus x canadensis, Prunus spinosa, Prunus spp., Pyrus spp., Quercus petraea, Quercus pyrenaica, Rhamnus alaternus, Robinia pseudoacacia, Salix alba, Salix atrocinerea, Salix elaeagnos, Salix fragilis, Salix purpurea, Salix spp., Tamarix spp., Tilia platyphyllos, Frangula alnus, Prunus avium, Rhus coriaria, Sophora japónica, Salix babylonica</i>	76,276,476,54, 2,73,72,13,74, 71,299,55,255, 75,275,35,12,6 6,93,51,58,52, 258,295,95,16, 42,43,4,92,257 ,357,757,857,9 57,57,53,377, 3, 395, 96, 292, 457	1	Baja
Sin datos	0	0	Sin datos

Figura 2: Clasificación de la severidad según la inflamabilidad de cada especie.

Por último, para la Erosionabilidad se utilizó la cartografía disponible del European Soil Data Centre (ESDAC), correspondiente al índice Soil Erodibility. También se clasificó en los mismos cuatro grupos, según los rangos establecidos en NÁJERA GONZÁLEZ et al. (2016), uniendo la clase Baja y Muy Baja en un mismo grupo.

Clases de erodabilidad	Rangos de erodabilidad	Principales propiedades de los suelos
Muy alta	> 0,04	Suelos de textura arenosa o franco arenosa, poco profundos y con bajo contenido en materia orgánica
Alta	0,03-0,033	Suelos de textura franco arenosa, mediano a poco profundos y bajo contenido en materia orgánica
Media	0,02-0,026	Suelos de textura franco arenosa o franca, medianamente profundos y contenido medio en materia orgánica
Baja	0,001-0,009	Suelos de textura franca o franco arcillosa, medianamente profundos y contenido medio a alto en materia orgánica
Muy baja	0,009-0	Suelos de textura franca o franco arcillosa, profundos y contenido alto en materia orgánica

Figura 3: Niveles de erosionabilidad en los suelos. Fuente: NÁJERA GONZÁLEZ et al., 2016.

Bloque Dinámico

Se compone de varias entradas cuya información se considera variable en el corto plazo: Anomalía Climática (AC), Déficit de Presión de Vapor (DPV) y Velocidad de viento media (V_{med}).

Para el cálculo de estas variables, se dispuso de datos históricos diarios de al menos 30 años, de 25 estaciones meteorológicas repartidas por toda la Comunitat, las cuales se encuentran lo suficientemente separadas entre ellas, y lo más próximas posible a los incendios estudiados, para que los valores empleados



fueran lo más ajustados a la realidad en el proceso de interpolación (*kriging*). La obtención de datos se realizó a través de la aplicación API REST, desarrollada por la Agencia Española de Meteorología (AEMET).

La AC se calculó como el promedio entre el Estrés Hídrico (EH) y el Estrés Térmico (ET), según la metodología propuesta por CHICO (2023). El EH se obtuvo de la comparación de percentiles del *Drought Code* (VAN WAGNER & PICKETT, 1985), y el ET mediante la comparación de percentiles con la media de la temperatura de los 8 días anteriores al incendio (CHICO, 2023).

Debido a la complejidad computacional de estos cálculos, para el presente proyecto se emplearon valores estándar fijos de AC, con el fin de realizar una primera validación de la herramienta. Los datos que se utilizaron fueron los valores máximo, mínimo y el percentil 50, que se habían obtenido para las provincias de Cuenca y Albacete (Castilla – La Mancha), ya que las condiciones climáticas son, en gran medida, similares a las de la Comunitat Valenciana.

El DPV se calculó según CUNILL (2019), empleando la media de la humedad relativa y de la temperatura media, y la V_{med} se obtuvo de manera directa de las mediciones de las estaciones. En ambos casos, los datos medios solo se determinaron de los días en los que el incendio estuvo activo.

SeverityApp

Previo a la ejecución de la herramienta, se realizó un preprocesamiento de las variables de entrada. Para el caso de la Elevación, Orientación, DVP y V_{med} , se estandarizaron a media 0 y desviación 1. En las Orientaciones se realizó una razón trigonométrica del ángulo, para evitar errores con los valores 0° y 360° . Las variables expresadas en porcentajes, se normalizaron en valores entre 0 y 1. Y para las variables discretas, se creó una nueva variable para cada clase, otorgándole el valor 1 en caso de que corresponda a esa clase, o valor 0 si no se correspondía.

A partir de la combinación de las entradas descritas, la herramienta de cálculo determina los niveles de severidad de quemado potencial. Inicialmente, se ejecuta un modelo (Modelo 1 *SGD*), que distingue entre dos grandes clases de severidad según si el valor obtenido es negativo (Baja) o positivo (Alta).

A continuación, y utilizando el mismo criterio negativo-positivo, para los valores clasificados como Baja, se ejecuta un modelo (Modelo 2 *Gradient Boosting*) que distingue entre severidad Baja y Media. Y, para los valores clasificados como Alta, se ejecuta un modelo (Modelo 3 *SGD*) que distingue entre severidad Alta y Muy Alta.

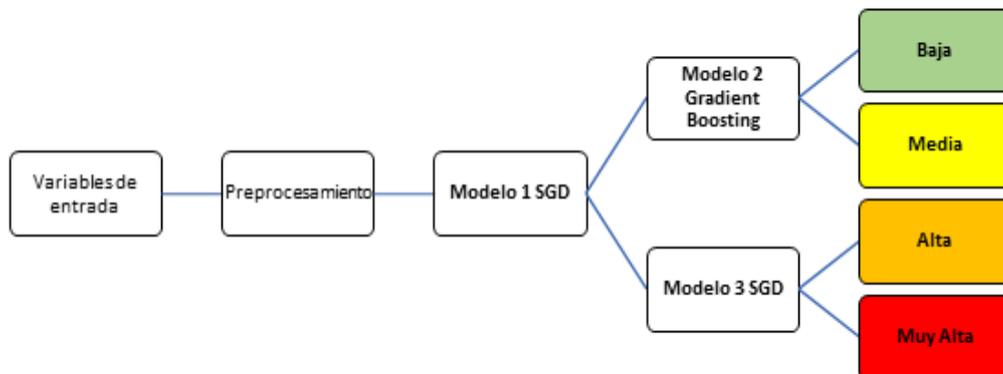


Figura 4: Esquema general de funcionamiento y cálculo de la herramienta SeverityApp.

Validación de los valores predichos

Para la validación de las predicciones obtenidas para cada uno de los incendios, se empleó la diferencia del Índice Normalizado de Área Quemada ($dNBR$) para cada uno de ellos. El cálculo de dicho índice, se realizó a partir de imágenes obtenidas del satélite Landsat 8, siendo el más actualizado con respecto a las fechas de los incendios utilizados.

$$dNBR = NBR_{pre} - NBR_{post}$$

Previo a este cálculo, se calculó el Índice Normalizado de Área Quemada (NBR) antes y después del incendio, a partir de la metodología desarrollada por KEY & BENSON (2006), en el que se combinan la banda del infrarrojo cercano (NIR) y la del infrarrojo de onda corta ($SWIR$).

$$NBR = \frac{\rho NIR - \rho SWIR}{\rho NIR + \rho SWIR}$$

Los resultados obtenidos se clasificaron según los intervalos de severidad descritos también en KEY & BENSON (2006): Baja (*Low severity*), Media (*Moderate-low severity*), Alta (*Moderate-high severity*) y Muy Alta (*High severity*).

Severity level	$dNBR$ range
Enhanced regrowth, high	-500 to -251
Enhanced regrowth, low	-250 to -101
Unburned	-100 to +99
Low severity	+100 to +269
Moderate-low severity	+270 to +439
Moderate-high severity	+440 to +659
High severity	+660 to +1300

Figura 5: Niveles de severidad descritos en KEY & BENSON (2006).

A continuación, se comprobó la concordancia píxel a píxel entre los valores reales (*dNBR*) y los predichos mediante la herramienta. Hay que tener en cuenta que ambas capas de información poseen extensiones distintas, siendo de 25 metros para la predicción y de 30 metros para el índice *dNBR* (debido a la resolución de las imágenes), por lo que los vértices y píxeles no coinciden de manera exacta. Por este motivo, se realizó una primera evaluación a partir de los valores donde coinciden los vértices superiores izquierdos de la capa de predicción, con el valor de píxel de la capa severidad *dNBR* donde se ubica dicho vértice.

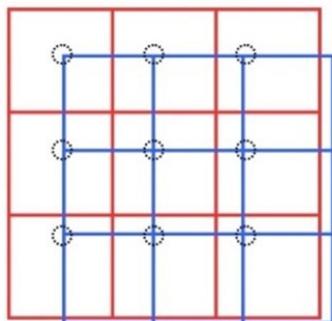


Figura 6. Metodología de evaluación entre *dNBR* (rojo) y severidad potencial (azul).

Previo a la evaluación, en las simulaciones se eliminaron los caminos, las zonas de interfaz y los 30 metros más próximos al límite del perímetro, para minimizar la distorsión que pudiese generar el efecto borde. También se eliminaron todos aquellos píxeles que tuviesen falta de información de alguna de las variables de entrada.

Análisis mediante el estadístico Kappa

Para apoyar la validación anterior, se estudió el coeficiente Kappa de Cohen (COHEN, 1960; CONGALTON & GREEN, 2009) de los incendios estudiados, como medida estadística permite obtener la relación y concordancia entre los valores obtenidos en la predicción y los de referencia (*dNBR*), teniendo en cuenta el acuerdo que se puede dar por el azar en la proporción (STRIJBOS et al., 2006).

$$K = \frac{P_0 - P_e}{1 - P_e}$$

P_0 = precisión global P_e = probabilidad esperada al azar

Para este análisis, se crearon puntos aleatorios dentro de cada uno de los perímetros de los incendios, para obtener matrices de confusión y determinar el grado de precisión y error que tiene la herramienta de cálculo. El número de puntos que se empleó se estableció a partir de su extensión, estableciendo 100 puntos por cada hectárea incendiada.

La escala de valores de Kappa, y su interpretación de la concordancia, se hizo a partir de los intervalos desarrollados por LANDIS & KOCH (1977).

También se estudió el error estándar (SE) del coeficiente Kappa de Cohen, que tiene en cuenta las proporciones totales de cada categoría que se está evaluando (FRIENDLY et al., 2015). De este modo, se puede determinar la variabilidad que tienen los resultados del valor de Kappa, si el análisis se repitiera varias veces, pero con diferentes muestras de puntos.

$$SE(k) = \sqrt{\frac{p_o(1-p_o)}{n(1-p_e)^2}}$$

n = número de valores observados totales

4. Resultados

Se realizó la comparación de los *dNBR* obtenidos con cada una de las simulaciones realizadas con la AC máxima, mínima y percentil 50. A modo de ejemplo, se presenta el incendio de Soneja (2021), con la severidad *dNBR* calculada y la simulación realizada con la AC mínima:

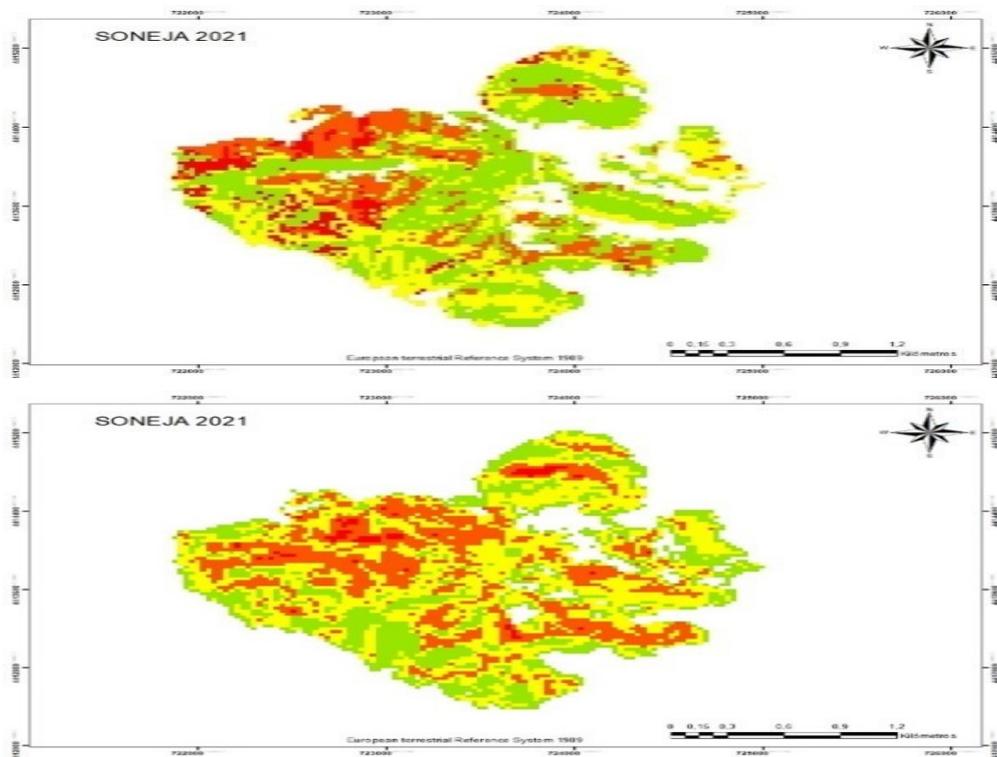


Figura 7: Severidad obtenida mediante el índice *dNBR* (izquierda) y severidad potencial calculada con la AC mínima (derecha), para el incendio de Soneja (2021).

A partir de estas imágenes ráster, se determinó el grado de concordancia que existe, estableciendo la siguiente escala: de manera exacta (valor 0), subestimados en una, dos o tres clases de severidad (-1, -2, -3) y sobrestimados en una, dos o tres clases (1, 2, 3).

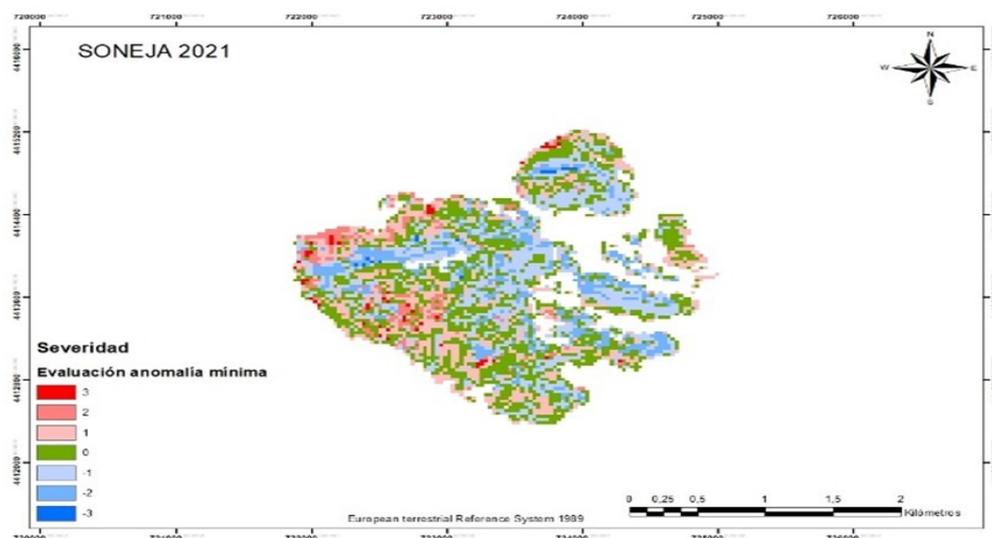


Figura 8: Evaluación entre el valor de severidad dNBR y la predicción con la AC mínima, para el incendio de Soneja (2021).

Para cada una de las simulaciones, se realiza una valoración de los porcentajes de acierto y los porcentajes de valores subestimados y sobrestimados:

Tabla 1: Porcentajes de evaluación entre el dNBR y la severidad potencial con la AC mínima, para el incendio de Soneja (2021).

Evaluación	Código	Número de píxeles	Porcentaje (%)
Sobrestima 3 clases	3	55	1,16
Sobrestima 2 clases	2	238	5,03
Sobrestima 1 clase	1	946	19,99
Acierto	1662	35,12	
Subestima 1 clase	-1	1246	26,33
Subestima 2 clases	-2	569	12,02
Subestima 3 clases	-3	17	0,36
Total	4733	100	

Para este caso, el grado de acierto o coincidencia es del 35,12%, siendo la subestimación en 1 clase el segundo valor más elevado, con un 26,33%.

Estas evaluaciones entre el valor de referencia (dNBR) y las predicciones obtenidas mediante la herramienta *SeverityApp*, se han realizado para todos los incendios y para los 3 valores de AC (valor máximo, mínimo y percentil 50). Como resumen, se presentan en las siguientes tablas los resultados de las evaluaciones realizadas:

Anomalía mínima

Tabla 2: Porcentajes de evaluación según el valor de AC mínima.

Incendio	Evaluación	dNBR					
		-3	-2	-1	1	2	3
Chella	0,13	9,19	38,28	42,82	9,32	0,17	0,08
Carcaixent	9,52	32,70	44,38	11,52	1,56	0,31	0,01
Llutxent	0,87	7,13	26,38	28,41	23,58	10,58	3,05
Beneixama	0,00	0,93	12,35	34,76	32,54	15,18	4,24
Soneja	0,36	12,02	26,33	35,12	19,99	5,03	1,16
Venta del Moro	0,00	1,00	11,38	29,17	37,14	16,98	4,32
Vall de Ebo	0,77	5,59	24,26	37,01	19,30	10,09	2,97
Bejís	0,04	1,27	8,92	21,86	30,56	23,42	13,94
Villanueva de Viver	0,66	11,20	27,00	30,93	21,44	7,93	0,83
Montitxelvo	26,79	32,70	25,37	11,95	2,04	0,85	0,29
PROMEDIO	3,91	11,37	24,47	28,36	19,75	9,05	3,09

Para el valor de AC mínima, la herramienta es capaz de acertar un 28,36% de los píxeles, en promedio.

Anomalía máxima

Tabla 3: Porcentajes de evaluación según el valor de AC máxima.

Incendio	Evaluación	dNBR					
		-3	-2	-1	1	2	3
Chella	0,11	8,35	40,00	46,56	4,74	0,16	0,08
Carcaixent	19,26	40,79	30,58	8,19	0,87	0,30	0,01
Llutxent	0,83	13,31	32,49	22,32	17,72	10,35	2,97
Beneixama	0,00	1,19	15,38	33,63	30,60	15,01	4,19
Soneja	0,53	16,44	33,64	33,40	9,91	4,92	1,16
Venta del Moro	0,00	0,73	11,35	30,47	36,64	16,55	4,25
Vall de Ebo	1,32	13,85	32,38	25,67	13,98	9,90	2,92
Bejís	0,13	3,07	11,73	19,91	28,15	23,18	13,82



Villanueva de Viver	1,44	11,32	27,47	30,80	20,47	7,72	0,80
Montitxelvo	30,75	31,69	23,45	11,02	1,97	0,84	0,28
PROMEDIO	5,44	14,07	25,85	26,20	16,51	8,89	3,05

Para la AC máxima, el 26,20% de los píxeles, en promedio, se han predicho de forma correcta.

Percentil 50

Tabla 4: Porcentajes de evaluación según el valor del percentil 50 de AC.

Incendio	Evaluación dNBR - Predicción						
	-3	-2	-1	1	2	3	
Chella	0,11	8,23	40,58	47,34	3,49	0,17	0,08
Carcaixent	22,09	43,16	26,33	7,44	0,67	0,30	0,01
Llutxent	0,71	12,08	29,97	23,46	20,40	10,41	2,98
Beneixama	0,00	0,98	14,18	34,69	30,89	15,05	4,20
Soneja	0,08	6,57	28,54	41,16	17,47	5,01	1,16
Venta del Moro	0,00	0,37	10,85	30,55	37,30	16,66	4,27
Vall de Ebo	1,06	10,62	31,05	29,29	15,10	9,95	2,93
Bejís	0,05	2,13	10,93	21,01	28,77	23,25	13,86
Villanueva de Viver	0,53	10,59	27,34	31,48	21,44	7,82	0,81
Montitxelvo	25,01	35,64	23,78	11,47	2,97	0,85	0,28
PROMEDIO	4,96	13,04	24,36	27,79	17,85	8,95	3,06

En el último caso, para el valor de percentil 50 de la AC, un 27,79% de los píxeles (en promedio) se han predicho de forma correcta.

Dado que el valor más alto de concordancia se obtuvo con el valor mínimo de la AC, el análisis estadístico mediante el coeficiente Kappa solo se realizó en las predicciones obtenidas con dicha AC. En el caso del incendio de Soneja (2021), se determinaron los puntos aleatorios de evaluación y la consecuente matriz de confusión:

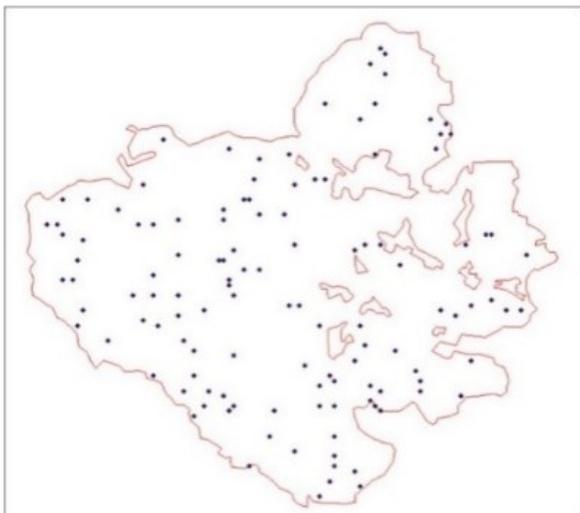


Figura 9: Distribución de los puntos de evaluación en el incendio de Soneja (2021).

Tabla 5: Matriz de confusión para el incendio de Soneja (2021), con la predicción obtenida mediante la AC mínima.

Matriz de confusión AC mínima – Soneja 2021					
1	2	3	4	Total	Error de comisión
1	10	20	10	40	30
2	7	11	5	23	12
3	1	4	13	2	20
4	1	4	1	6	6
Total	19	39	29	2	89
Error de omisión	9	28	16		2

A partir de esta matriz, se obtiene el valor del estadístico Kappa (K) y su SE (K):

Tabla 6: Resumen de la concordancia en el incendio de Soneja (2021) a partir de la matriz de confusión.

Clase	Error de omisión (%)	Error de comisión (%)	Precisión (P0)	Probabilidad al azar (Pe)	Coficiente Kappa (K)	Coficiente Kappa (%)	Error estándar (SE)
1	47,37	75,00	0,3820	0,2839	0,1370	13,70	0,0719
2	71,79				52,17		
3	55,17				35,00		
4	100,00				100,00		

Estos cálculos se han replicado para todos los incendios, presentándose un resumen en la tabla siguiente:

Tabla 7: Resumen de la evaluación de la concordancia entre las predicciones obtenidas con la AC mínima y el dNBR.



Incendio	Promedio del error de omisión (%)	Promedio del error de comisión (%)	Precisión (P ₀)	Probabilidad al azar (P _e)	Coefficiente Kappa	Coefficiente Kappa (%)	Error estándar
Chella	76,44	75,39	0,3964	0,4216	-0,0436	-4,36	0,0463
Carcaixent	68,68	80,27	0,1432	0,1506	-0,0087	-0,87	0,0191
Lutxent	67,81	72,53	0,2570	0,2289	0,0365	3,65	0,0230
Beneixama	57,33	78,95	0,4141	0,3060	0,1557	15,57	0,0627
Soneja	68,58	65,54	0,3820	0,2839	0,1370	13,70	0,0719
Venta del Moro	62,08	68,34	0,3036	0,2480	0,0738	7,38	0,0365
Vall de Ebo	64,86	66,93	0,3747	0,3111	0,0923	9,23	0,0147
Bejís	69,17	69,69	0,2203	0,1822	0,0465	4,65	0,0084
Villanueva de Viver	66,82	68,20	0,3341	0,2956	0,0547	5,47	0,0227
Montitxelvo	74,07	77,04	0,0995	0,1030	-0,0038	-0,38	0,0161

Los valores de Precisión (P₀) de la Tabla 7, se encuentran normalizados entre 0 y 1. Si estos valores se expresan en porcentaje, y se comparan con los porcentajes de acierto (valor 0) obtenidos en la evaluación mediante la anomalía mínima (Tabla 2), se puede observar que los valores de concordancia son similares en ambos casos. De esto se deduce que, la cantidad de puntos utilizados en el cálculo del coeficiente Kappa, así como su aleatoriedad, son significativos.

Por último, y partir de los valores calculados relativos al SE, se ha obtenido el intervalo de confianza del 95% (igual a 2 veces el SE) y el intervalo de confianza del 99% (igual a 3 veces el SE). Con esto, se puede comprobar cómo variaría el valor calculado de Kappa, si se repitiera el análisis varias veces, con distintos puntos aleatorios:

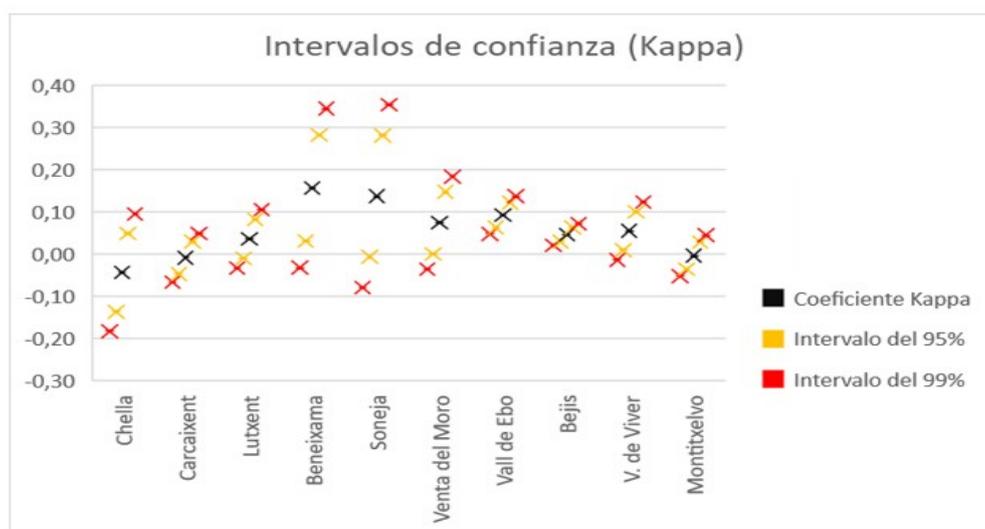


Figura 10: Intervalos de confianza para el coeficiente Kappa.

5. Discusión

En cada una de las AC estudiadas, existen diferencias en los porcentajes de acierto



para cada uno de los incendios. A pesar de esto, estas diferencias se mantienen más o menos estables en las tres anomalías, por lo que no parece tener una influencia muy significativa este parámetro sobre los resultados.

Para la anomalía correspondiente al percentil 50, los incendios cuyo valor de porcentaje de acierto es igual o mayor al 30% son: Chella, Beneixama, Soneja, Venta del Moro y Villanueva de Viver. Para la anomalía máxima, serían los incendios de: Chella, Beneixama, Soneja, Venta del Moro y Villanueva de Viver. En cambio, para la anomalía mínima, serían los incendios de: Chella, Beneixama, Soneja, Vall de Ebo y Villanueva de Viver. Por lo que se denota una gran diferencia en la predicción entre estos incendios y los de: Carcaixent, Llutxent, Bejís y Montitxelvo.

No se aprecia un patrón espacial o temporal que condicione los resultados, ni tampoco parece que las dimensiones del incendio sean un factor determinante, ya que no hay diferencias asociadas a la superficie. Los promedios de evaluación obtenidos para el conjunto de las 3 anomalías, en porcentaje serían:

Tabla 8: Porcentajes promedio de las evaluaciones.

PROMEDIOS	dNBR					
	- Predicción					
	-3	-2	-1	1	2	3
	4,77	12,78	24,89	27,45	18,04	8,97
						3,07

Observando la tabla anterior, se puede comprobar que la herramienta de cálculo de severidad de quemado potencial, ha podido determinar correctamente el 27,45% (en promedio) de los valores de severidad para los incendios de la Comunitat Valenciana. En concreto, los mayores resultados de acierto se obtienen con el valor de anomalía mínima (28,36%), y los peores resultados de acierto se obtienen con el valor de anomalía máxima (26,20%).

La herramienta también tiende a subestimar la severidad, ya que el sumatorio de los porcentajes de las subestimaciones (42,44%), es superior al porcentaje de la suma de las sobrestimaciones (30,1%). Y, más en concreto, el algoritmo tiende a subestimar sobre todo en una clase de diferencia, ya que el 59% de las subestimaciones son de este tipo. Por lo que respecta a las sobrestimaciones, la que mayor relevancia presenta también es la que se corresponde con una clase ya que, el 59,93% del total de las sobrestimaciones ha sido de este tipo. La sobrestimación y la subestimación en tres clases es lo menos habitual, siendo tan solo un 7,84% del total de las predicciones que se han realizado.

En la siguiente tabla, se analiza la matriz de confusión general, obtenida a partir de la suma de las matrices de todos los incendios:

Tabla 9: Matriz de confusión general.



MATRIZ DE CONFUSIÓN GENERAL						
	1	2	3	4	Total Predicho	Error de comisión
1	1	322	552	430	219	1523 1201
2	2	607	1584	1093	228	3512 1928
3	3	56	207	270	144	677 407
4	4	577	1216	1252	331	3376 3045
Total Real		1562	3559	3045	922	9088
Error de omisión		1240	1975	2775		591

En esta tabla, se puede comprobar que el valor de los píxeles subestimados, correspondientes a aquellas celdas inferiores a la diagonal (n = 3915), es superior al valor de los píxeles sobrestimados (n = 2666), por lo que se corrobora que el modelo subestima en los cálculos de severidad potencial.

Si estos valores totales se analizan en porcentaje sobre el total del *dNBR*, se puede ver que, para la clase 1 (Baja), la herramienta sobrestima especialmente en una y dos clases, con un 36,24% y un 28,23%. Y para la clase 2 (Media) y 3 (Alta), el cálculo también sobrestima en una clase, con un 31,12% y con un 21,27%, respectivamente.

En cambio, por lo que respecta a las subestimaciones, en la clase 3 se subestima sobre todo en una clase, con un 30,58%, y en la clase 4, se subestima tanto en una, como en dos clases con un 37,09% y un 36,02%, respectivamente.

Observando la tabla, se puede confirmar que el modelo predice con mayor precisión las clases de severidad 2 (Media) y 3 (Alta), donde los porcentajes de acierto son del 45,01% y 39,88%, para cada una de ellas.

Por el contrario, determina con dificultad la clase 1 (Baja) de severidad, donde tan solo es capaz de acertar una quinta parte de los casos (21,14%). Pero sin ninguna duda, la clase de severidad que peor determina es la 4 (Muy Alta), lo cual es coherente con el hecho de que la herramienta tiende a subestimar en los cálculos y, por lo tanto, presentaría problemas para predecir la clase más alta de severidad.

Tabla 10: Matriz de confusión general en porcentaje sobre el valor de *dNBR*.

MATRIZ DE CONFUSIÓN GENERAL (%)					
Real	Predicho				Total
	1	2	3	4	
1	21,14	36,24	28,23	14,38	100,00
2	17,28	45,10	31,12	6,49	100,00
3	8,27	30,58	39,88	21,27	100,00
4	17,09	36,02	37,09	9,80	100,00

En cuanto a los resultados obtenidos del estadístico Kappa para cada uno de los incendios, se determina que la estimación de la severidad potencial es “pobre” para los incendios de Chella, Carcaixent y Montitxelvo, ya que los resultados obtenidos son negativos. Este valor significa que, para estos incendios, la concordancia que se ha obtenido es inferior a la que cabría esperar, si el resultado de la estimación de la severidad potencial se hubiese obtenido al azar. En el caso de repetirse los análisis en estos incendios, se podría alcanzar como máximo, concordancias de nivel “leve”, ya que en los intervalos de confianza del 99%, llegan a alcanzar valores entre 0,01 – 0,20 (Figura 5).

Para el resto de incendios, el nivel de concordancia es “leve”, ya que se encuentran en rangos entre 0,01 – 0,20 del valor del coeficiente. Dentro de este grupo, tan solo en los incendios de Soneja y Beneixama, si se repitiese el análisis, podrían alcanzar fuerzas de concordancia “aceptables”, ya que sus intervalos de confianza del 99% llegan al rango de entre 0,21 – 0,40 (Figura 5).

Los valores de predicción son bajos en promedio, lo que puede deberse a que se han empleado valores de viento de estaciones cercanas, pero la aparición de vientos locales y los vientos derivados de la isla de calor que genera el incendio, podrían modificar el resultado. Del mismo modo, no se ha tenido en cuenta la dirección de los mismos, lo que modificaría el comportamiento del fuego y, por lo tanto, el grado de severidad sobre la vegetación, tal y como se describe en DILLON et al., (2011). Es importante resaltar que la mayoría de los grandes incendios que ocurren en la Comunitat Valenciana, y especialmente los utilizados en este estudio, son incendios de viento debido a las características topográficas y por su cercanía al mar, lo que es una variable que podría condicionar los resultados. Aun así, podría no ser una variable influyente, ya que no se han encontrado estudios de evaluación de la severidad en el mediterráneo, donde se incluya la variable de la dirección del viento, excepto en MITSOPOULOS et al. (2019) o COSTA-SAURA et al. (2022), donde se emplearon direcciones de viento de manera indirecta, en el cálculo de simulaciones del comportamiento del fuego, las cuales no tuvieron un alto peso explicativo en relación al cálculo de la severidad.

Además, se podrían haber utilizado distintos índices espectrales, como el Índice de Vegetación de Diferencia Normalizada (NDVI) previa al incendio, porque permitiría conocer la cantidad de combustible muerto, ya que la herramienta solo entiende que existen los modelos de combustible (estresados o no), pero no contempla la calidad y desarrollo de la vegetación, lo cual condicionaría la intensidad y, por tanto, la severidad del fuego. Estudios como el de COSTA-SAURA et al. (2022) o FERNÁNDEZ-GARCÍA et al. (2022), han demostrado que el uso de este índice presentan buenas correlaciones en la determinación del grado de severidad tras un incendio.

Es más, estos estudios han encontrado que todas aquellas variables que están relacionadas con la humedad del combustible, de manera directa o indirecta, modifican el comportamiento del fuego y, por ende, el grado de afección de este (FANG et al., 2018; FERNÁNDEZ-GUISURAGA et al., 2021). En concreto, determinaron que el Índice Diferencial de Agua Normalizado (NDWI), es de los mejores descriptores de la severidad, incluso por delante de las variables topográficas. Más en concreto, en el caso de estudio de FERNÁNDEZ-GARCÍA et al. (2022) se determinó que, variables asociadas a la humedad de los combustibles, tales como el Contenido de la Humedad Foliar (CWC) o el Índice de Estrés Hídrico



(EH), tienen una gran importancia para poder predecir la afección de quemado tras un incendio. En nuestro estudio, también se empleó el EH, pero no se han empleado valores asociados directamente a la humedad del combustible, por lo que se podría complementar el estudio con datos de campo. En este sentido, es importante destacar que el Servicio de Prevención de Incendios Forestales de la Generalitat Valenciana, posee un proyecto activo desde 2013 de seguimiento de la humedad de los combustibles vivos, con más de 40.000 datos tomados en campo sobre las principales especies vegetales, el cual se podría emplear de algún modo en futuras mejoras de la herramienta.

En el desarrollo de la herramienta *SeverityApp*, se han utilizado imágenes de Landsat 8, pudiendo haberse empleado imágenes de otros satélites como Sentinel 2, que es el más utilizado por los principales organismos públicos (y es el empleado en el estudio de FERNÁNDEZ-GARCÍA et al., 2022) para determinar el grado de severidad de un incendio. De hecho, se ha demostrado que el uso de distintas fuentes de datos de imágenes espectrales, da lugar a variaciones en los resultados de severidad *dnBR* (VIEDMA et al., 2020).

Tampoco hay que olvidar las propias limitaciones que presenta el propio índice *dnBR*, donde la toma de las imágenes está supeditada a su disponibilidad y a la no presencia de nubes o sombras en la zona de estudio, lo que ha provocado que se hayan tenido que emplear imágenes pre y post-incendio, de hasta incluso dos meses antes o después de la perturbación, aumentando así las posibilidades de error en la clasificación, por cambios leves en la vegetación no asociados al fuego.

Otras limitaciones a tener en cuenta con el *dnBR* son la resolución espacial y la poca fiabilidad para representar aquellos estratos que se encuentran por debajo del dosel arbóreo (HUDAK et al., 2007, MENG & MEENTEMEYER, 2011), así como el hecho de que el *dnBR* está creado a partir de cálculos con modelos americanos, cuya vegetación dista de la que presenta la zona de estudio.

Otro aspecto a tener en cuenta, tal y como se describe en BOTELLA & FERNÁNDEZ-MANSO (2017), es el uso de la Diferencia Relativa del Índice Normalizado de Área Quemada (*RdnBR*), en lugar del *dnBR*, ya que se trata del índice que mejor caracteriza el grado de severidad para la Comunitat Valenciana. De hecho, autores como COSTA-SAURA et al. (2022), han conseguido elaborar un modelo de predicción de la severidad potencial, basado en el aprendizaje automático a partir de incendios ocurridos en el mediterráneo (oeste de Italia y sur de Francia), con el cual han conseguido obtener predicciones con acierto de hasta un 77% de la severidad potencial de un incendio, en base al índice *RdnBR*, mediante el uso de imágenes de Landsat 7 procesadas con *Google Earth Engine* (GEE).

También, en REGO et al. (2017) se pone de manifiesto que el *dnBR* estima una mayor superficie como severidad “Media” y “Baja”, en comparación con el *RdnBR* que obtiene mejores estimaciones de severidad, sobre todo en la clase “Alta” o “Muy Alta”. Por lo que, quizá para nuestro estudio, el uso de *RdnBR* podría mejorar los resultados, sobre todo, la mala clasificación en la categoría “Muy Alta”, que ha sido la que peor predicción ha tenido.

Para apoyar los valores de *dnBR*, habría sido conveniente realizar trabajos de campo, mediante análisis visual y de fotografías, u obtener índices como el Índice Compuesto de Quemado (CBI) desarrollado por KEY & BENSON (2006), que presenta una buena correlación con el *dnBR* (MITSOPOULOS et al., 2019).



Otro aspecto a valorar, es la cantidad de entradas que presenta el modelo. Autores como FERNÁNDEZ-GARCÍA et al., (2022), determinaron que habían encontrado relaciones significativas, en mayor o menor orden, en hasta 20 variables distintas previas al incendio (principalmente climáticas, topográficas y relacionadas con los modelos de combustible), aunque muchas de estas variables eran dependientes. Así que concluyeron que con tan solo 7 de los 20 predictores se podían obtener resultados predictivos satisfactorios. Es por esto que un número elevado de variables puede influir en la calidad de la predicción, ya que se incorpora ruido al cálculo. Aunque hay que tener en cuenta que este autor centró su estudio en localidades del oeste de la península, donde las condiciones meteorológicas y de vegetación difieren a las de la Comunitat Valenciana, por lo que podría no ser extrapolable al ámbito de estudio. Ejemplo de variable que se podría valorar incluirla o no, es la de erosionabilidad, puesto que es un atributo inherente al suelo y no tiene una influencia directa sobre el fuego. De hecho, en la revisión bibliográfica realizada para el entorno mediterráneo, no se han encontrado en ningún caso el uso de esta variable predictiva, o de alguna similar que pudiese estar relacionada de manera indirecta.

Pero no solo la cantidad puede ser relevante, sino que la calidad de las variables empleadas también puede determinar la eficacia de la predicción. Un ejemplo serían las entradas correspondientes a la inflamabilidad o los modelos de combustible, ya que se hace una reclasificación de los valores, a valores de severidad potencial en base a una bibliografía de referencia. Por lo que el reorganizar estas variables, podría estar introduciendo un error en el aprendizaje y cálculo de la herramienta. Por tanto, debería plantearse un modelo con variables más sencillas, tal y como se describe en COSTA-SAURA et al., (2022) o FERNÁNDEZ-GARCÍA et al., (2022), donde en ambos casos concluyen que las variables que mejor explican la severidad de un incendio son los combustibles y la topografía, en especial esta última, ya que entienden que condiciona indirectamente la estructura y distribución espacial de la primera (D'ESTE et al., 2021). Además, tanto en COSTA-SAURA et al., (2022) como en FERNÁNDEZ-GARCÍA et al., (2022), no se emplearon los modelos de combustible de ROTHERMEL (1972) o SCOTT & BURGAN (2005), sino que se estudió la correlación que presentaba el *Corine Land Cover* (CLC), determinándose como un buen predictor.

6. **Conclusiones** Del estudio realizado, se desprenden las siguientes conclusiones:
- En general, la herramienta de cálculo es capaz de predecir de forma correcta el 27,45% de las clases de severidad, siendo la mejor predicción la que corresponde con la anomalía mínima, con un 28,36%.
 - El modelo tiende a subestimar el grado de severidad, sobre todo en una clase de diferencia. En el caso de las sobrestimaciones, también tiende a sobrestimar en una clase.
 - El modelo predice con mayor acierto la clase 2 (Media) y 3 (Alta), y presenta problemas para estimar la clase 1 (Baja) y 4 (Muy Alta) de severidad.
 - El nivel de concordancia obtenido mediante el estadístico Kappa para los incendios de Chella, Carcaixent y Montitxelvo se clasifica como “pobre” y, para el resto de incendios, el nivel de correlación es “bajo”. Por lo que el nivel de acierto de la herramienta es leve, por el momento.
 - Debido al bajo porcentaje de acierto, se propone volver a calibrar el modelo de cálculo, haciendo especial hincapié en el Modelo 2 *Gradient Boosting* y el



Modelo 3 SGD, para intentar mejorar los problemas en la clasificación de la clase Baja y Muy Alta.

- Los resultados obtenidos, plantean la necesidad de realizar trabajos de campo que acompañen a los análisis de severidad, así como valorar la opción de utilizar el índice *RdNBR* para particularizar la herramienta en el territorio de la Comunitat Valenciana.
- Se debería modificar el desarrollo y aprendizaje de la herramienta, hacia un modelo de cálculo con variables más asépticas, incluyendo índices como el NDVI o el NDWI.

7. Agradecimientos

Este estudio ha sido posible gracias al trabajo del equipo ECOFOR de la Universidad Castilla – La Mancha, con la colaboración de VAERSA (Valenciana d’Estratègies i Recursos per a la Sostenibilitat Ambiental S.A.), con especial mención a la Unidad Técnica de Análisis y Prevención de Incendios Forestales. Este estudio se enmarca dentro del proyecto “Vulnerabilidad integral de los sistemas forestales frente a incendios: implicaciones en las herramientas de gestión forestal - VIS4FIRE RTA2017-00042-C05; 2018-2020”. Agradecer también la colaboración y el apoyo por parte del proyecto "2024-TRAN-36386 00570FP416 Tecnología para la prevención, extinción y restauración de Grandes Incendios Forestales".

8. Bibliografía

- BEATTY, M. & SMITH, J. E.; 2013. Dynamic soil water repellency and infiltration in post-wildfire soils. *Geoderma*.
- BOTELLA, M.A. & FERNÁNDEZ-MANSO, A.; 2017. Study of post-fire severity in the Valencia region comparing the NBR, RdNBR and RBR indexes derived from Landsat 8 images. *Revista de Teledetección*, 49, 33-47.
- BROTONS, L., AQUILUÉ, N., DE CÁCERES, M., FORTIN, M.J. & FALL, A.; 2013 . How Fire History, Fire Suppression Practices and Climate Change Affect Wildfire Regimes in Mediterranean Landscapes. *PLoS ONE* 8(5): e62392.
- BUDDE, K.B., HEUERTZ, M., HERNÁNDEZ-SERRANO, A., PAUSAS, J.G., VENDRAMIN, G.G., VERDÚ, M. & GONZÁLEZ-MARTÍNEZ, S.C.; 2014. In situ genetic association for serotiny, a fire-related trait, in Mediterranean maritime pine (*Pinus pinaster*). *New Phytologist* 201: 230–241.
- CASTELLNOU, M. (2018). Los incendios de sexta generación son más difíciles de controlar y afectan a medio planeta. En: La Vanguardia, la actualidad del medio ambiente.
- CERTINI, G., NOCENTINI, C., KNICKER, H., ARFAIOLI, P. & RUMPEL, C.; 2011. Wild fire effects on soil organic matter quantity and quality in two fire-prone Mediterranean pine forests. *Geoderma*, 167-168, 148-155.
- CHICO, F. (2023). El Índice de Propagación Potencial (IPP) de Castilla-La Mancha. Herramienta para la predicción del peligro de incendios forestales. 8 Congreso Forestal Español.
- COHEN, J.; 1960. Un coeficiente de acuerdo para escalas nominales. *Medición Educativa y Psicológica*. Vol. 20, No. 1, 37-46.
- CONGALTON, R.G., & GREEN, K.; 2009. Assessing the accuracy of remotely sensed data. *Principles and practices* (2 edition). Boca Ratón: CRC Press. Taylor & Francis.



COSTA-SAURA, J.M., BACCIU, V., RIBOTTA, C., SPANO, D., MASSAIU, A. & SIRCA, C.; 2022. Predicting and Mapping Potential Fire Severity for Risk Analysis at Regional Level Using Google Earth Engine. *Remote Sens*, 14, 4812.

CUNILL, A.; 2019. Obtaining fuel moisture maps from meteorological variables for the prediction of fire risk on a regional scale: a new approach to the current fire danger indexes. *Cuad. Soc. Esp. Cienc. For.* 45(2): 205-214 (2019).

D'ESTE, M., ELIA, M., GIANNICO, V., SPANO, G., LAFORTEZZA, R. & SANESI, G.; 2021. Machine learning techniques for fine dead fuel load estimation using multi-source remote sensing data. *Remote Sens.*, 13, 1658.

DÍAZ-DELGADO, R., LLORET, F. & PONS, X.; 2003. Influence of fire severity on plant regeneration through remote sensing imagery. *International Journal of Remote Sensing* 24(8): 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.

DOBLAS-MIRANDA, E., MARTÍNEZ-VILALTA, J., LLORET, F., ÁLVAREZ, A., ÁVILA, A., BONET, F.J., BROTONS, L., CASTRO, J., CURIEL YUSTE, J., DÍAZ, M., FERRANDIS, P., GARCÍA-HURTADO, E., IRIONDO, J.M., KEENAN, T.F., LATRON, J., LLUSIÀ, J., LOEPFE, L., MAYOL, M., MORÉ, G., MOYA, D., PEÑUELAS, J., PONS, X., POYATOS, R., SARDANS, J., SUS, O., VALLEJO, V.R., VAYREDA, J., & RETANA, J.; 2015. Reassessing global change research priorities in Mediterranean terrestrial ecosystems: how far have we come and where do we go from here?. *Global Ecology and Biogeography*, 24, 25–43.

DOBLAS-MIRANDA, E., ALONSO, R., ARNAN, X., BERMEJO, V., BROTONS, L., DE LAS HERAS, J., ESTIARTE, M., HÓDAR, J.A., LLORENS, P., LLORET, F., LÓPEZ-SERRANO, F.R., MARTÍNEZ-VILALTA, J., MOYA, D., PEÑUELAS, J., PINO, J., RODRIGO, A., ROURA-PASCUAL, N., VALLADARES, F., VILÀ, M., ZAMORA R. & RETANA, J.; 2017. A Review of the Combination among Global Change Factors in Forests, Shrublands and Pastures of the Mediterranean Region: Beyond Drought Effects. *Global and Planetary Change*, 148, 42-54.

FANG, L., YANG, J., WHITE, M. & LIU, Z.; 2018. Predicting potential fire severity using vegetation, topography and surface moisture availability in a eurasian boreal forest landscape. *Forests* 9, 130.

FERNÁNDEZ-FERNÁNDEZ, M., NAVES, P. & FERNÁNDEZ, M.M.; 2015. Bark beetle outbreaks after fire in stands of *Pinus sylvestris*: Influence of fire severity and landscape context. *Forest Ecology and Management*, 353, 67-77.

FERNÁNDEZ-GARCÍA, V., BELTRÁN-MARCOS, D., FERNÁNDEZ-GUISURAGA, J. M., MARCOS, E. & CALVO, L.; 2022. Predicting potential wildfire severity across Southern Europe with global data sources. *Science of the total environment* 829, 154729.

FERNÁNDEZ-GUISURAGA, J.M., SUÁREZ-SEOANE, S., GARCÍA-LLAMAS, P. & CALVO, L.; 2021. Vegetation structure parameters determine high burn severity likelihood in different ecosystem types: A case study in a burned Mediterranean landscape. *Journal of Environmental Management*, 288: 112462.

FRIENDLY, M., MEYER, D., & ZEILEIS, A.; 2015. Fitting and Graphing Discrete Distributions.



GIBSON, K., & NEGRÓN, J. F.; 2009. Fire and bark beetle interactions. *The Western Bark Beetle Research Group: A Unique Collaboration With Forest Health Protection: Proceedings of a Symposium at the 2007 Society of American Foresters Conference*, 51–70.

GONZÁLEZ-DE VEGA, S., DE LAS HERAS, J. & MOYA, D.; 2016. Resilience of Mediterranean terrestrial ecosystems and fire severity in semiarid areas: Responses of Aleppo pine forests in the short, mid and long term. *Science of The Total Environment*, 573: 1171-1177.

GREENPEACE ESPAÑA; 2010. Incendios Forestales ¿Qué perdemos?. Archivo: <http://archivo-es.greenpeace.org/espana/Global/espana/report/other/incendios-forestales-que-per.pdf>

HUDAK, A.T., MORGAN, P., BOBBITT, M.J., SMITH, A.M.S., LEWIS, S.A. & LENTILE, L.B.; 2007. The relationship of multispectral satellite imagery to immediate fire effects. *Fire Ecology*, 3(1), 64-90.

KAUSRUD, K., OKLAND, B., SKARPAAS, O., GRÉGOIRE, J.C., ERBILGIN, N. & STENSETH, N.C.; 2012. Population dynamics in changing environments: The case of an eruptive forest pest species. *Biological Reviews*, 87(1), 34-51.

KEELEY, J. E.; 2009. Fire intensity, fire severity and burn severity: a brief review and suggested usage. *International Journal of Wildland Fire*, 18(1), 116- 126.

KEY, C.H. & BENSON, N.C.; 2006. Landscape Assessment (LA): Ground measure of severity, the Composite Burn Index; and Remote Sensing of severity, the Normalized Burn Ratio. In: Lutes, D.C., Keane, R.E., Caratti, J.F., Key, C.H., Benson, N.C., Sutherland, S., & Gangi, L.J. (eds.). FIREMON: Fire effects monitoring and inventory system. USDA Forest Service, Rocky Mountain Research Station. *Gen. Tech. Rep. RMRS-GTR-164-CD*, 1-55

KEELEY, J.E. & PAUSAS, J.G.; 2022. Evolutionary ecology of fire. *Annual Review of Ecology, Evolution and Systematics* 53: 203–225.

LANDIS, J.R. & KOCH, G.G.; 1977. The Measurement of Observer Agreement for Categorical Data. *Biometrics*, 33(1), 159–174.

LENTILE, L.B., HOLDEN, Z.A, SMITH, A.M.S., FALKOWKI, M.J., HUDAK, A.T., MORGAN, P., LEWIS, S. A., GESSLER, P.E. & BENSON, N.C.; 2006. Remote sensing techniques to assess active fire characteristics and post-fire effects. *Int. J. Wildland Fire*, 15, 319-345.

LIU, J.C., MICKLEY, L.J., SULPRIZIO, M.P., DOMINICI, F., YUE, X., EBISU, K., ANDERSON, G.B., KHAN, R.F.A., BRAVO, M.A. & BELL, M.L.; 2016. Particulate air pollution from wildfires in the Western US under climate change. *Clim. Change* 138 (3–4), 655–666.

MADRIGAL, J., SOUTO-GARCÍA, J., CALAMA, R., GUIJARRO, M., PICOS, J., & HERNANDO, C.; 2019. Resistance of *Pinus pinea* L. bark to fire. *International Journal of Wildland Fire*, 28(5), 342-353.

MARTÍNEZ, J.; 2019. Análisis de la evolución de los incendios forestales en España.

MENG, Q. & MEENTEMEYER, R.K.; 2011. Modeling of multi-strataforest fire severity using Landsat TM Data. *International Journal of Applied Earth Observation and Geoinformation* 13 (1), 120-126.

MITSOPOULOS, I., CHRYSAFI, I., BOUNTIS, D. & MALLINIS, G.; 2019. Assessment of factors driving high fire severity potential and classification in a Mediterranean



- pine ecosystem. *J. Environ. Manag.*, 235, 266–275.
- MORENO, J.M.; 2016. Los incendios forestales en España en un contexto de cambio climático: información y herramientas para la adaptación (INFOADAPT). Universidad de Castilla-La Mancha. Toledo.
- MORENO, J.M.; 2017. Cambio climático y riesgo de incendios forestales en España.
- MOYA, D., GONZÁLEZ-DE VEGA, S., GARCÍA-ORENES, F., MORUGÁN-CORONADO, A., ARCENEGUI, V., MATAIX-SOLERA, J., LUCAS-BORJA, M.E. & DE LAS HERAS, J.; 2018. Temporal characterization of soil-plant natural recovery related to fire severity in burned *Pinus halepensis* mill. *Forests. Sci Total Environ.*
- NÁJERA GONZÁLEZ, O., BOJÓRQUEZ SERRANO, J. I., FLORES VILCHEZ, F., MURRAY NÚÑEZ, R. M., & GONZÁLEZ GARCÍA-SANCHO, A.; 2016. Riesgo de erosión hídrica y estimación de pérdida de suelo en paisajes geomorfológicos volcánicos en México. *Cultivos Tropicales*, 37(2), 45-55.
- NEARY, D.G., KLOPATEK, C.C., DEBANO, L.F., & FFOLLIOTT, P.F.; 1999. Fire effects on belowground sustainability: A review and synthesis. *Forest Ecology and Management*, 122(1-2), 51–71.
- NEARY, D.G., RYAN, K.C. & DEBANO, L.F.; 2005. Wildland Fire in Ecosystems. Rocky Mountain Research Station General Technical Report, 4(RMRS-GTR-42).
- NYLAND, R.D.; 2016. Silviculture: concepts and applications. *Waveland Press*.
- PAUSAS, J.G. & KEELEY, J.E.; 2014. Abrupt climate-independent fire regime changes. *Ecosystems*.
- PEREIRA, P., FRANCOS, M., BREVIK, E.C., ÚBEDA, X. & BOGUNOVIC, I.; 2018. Post-fire soil management. Current Opinion in *Environmental Science & Health*. Volume 5, 26-32 pp.
- REGO, A., RUIZ GONZÁLEZ, A.D. & ARELLANO, S.; 2017. Evaluation and mapping of the severity of the maior fires that occurred in forest district XIV CVerin-Viana) between 2006-2016. *Cuad. Soc. Esp. Cienc. For.* 44(2): 169-182 (2018).
- ROBICHAUD, P.R., WAGENBRENNER, J.W., PIERSON, F.B., SPAETH, K.E., ASHMUN, L.E. & MOFFET, C.A.; 2016. Infiltration and interrill erosion rates after a wildfire in western Montana, USA. *CATENA*.
- SANTOLAMAZZA-CARBONE, S., PESTAÑA, M. & VEGA, J.A.; 2011. Response of *Ips sexdentatus* (Coleoptera: Curculionidae) to *Pinus pinaster* bolts subjected to different fire intensities: Effects of fire-induced tree weakening on host colonization and offspring performance. *Journal of Insect Science*, 11(1), 1-16.
- SCOTT, D. F.; 1993. The hydrological effects of fire in South African mountain catchments. *Journal of Hydrology*, 150(2-4), 409–432.
- STRIJBOS, J., MARTENS, R., PRINS, F. & JOCHEMS, W.; 2006. Content analysis: What are they talking about?. *Computers & Education* 46: 29-48.
- TESSLER, N., WITTENBERG, L. & GREENBAUM, N.; 2016. Vegetation cover and species richness after recurrent forest fire in the Eastern Mediterranean ecosystem of Mount Carmel, Israel. *Sci. Total Environ.*
- VAN WAGNER, C.E. & PICKETT, T.L.; 1985. Equations and FORTRAN Program for the Canadian Forest Fire Weather Index System. Ottawa: Canadian Forest Service.
- VIDMA, O., CHICO, F., FERNÁNDEZ, J. J., MADRIGAL, C., SAFFORD, H. D. & MORENO, J. M.; 2020. Disentangling the role of prefire vegetation vs. burning



conditions on fire severity in a large forest fire in SE Spain. Remote Sens. Environ., 247, 111891.