

# Estimación de la severidad en incendios forestales a partir de datos LiDAR-PNOA y valores de *Composite Burn Index*

Montealegre, A. L.\*<sup>1</sup>, Lamelas, M. T.<sup>1,2</sup>, Tanase, M. A.<sup>3</sup>, de la Riva, J.<sup>1</sup>

<sup>1</sup> GEOFOREST-IUCA, Departamento de Geografía y Ordenación del Territorio, Universidad de Zaragoza, Calle Pedro Cerbuna 12, C.P. 50009, Zaragoza, España.

<sup>2</sup> Centro Universitario de la Defensa de Zaragoza, Carretera de Huesca s/n, C.P. 50090, Zaragoza, España.

<sup>3</sup> Departamento de Geología, Geografía y Medio Ambiente, Universidad de Alcalá, Pza. San Diego, s/n 28801 - Alcalá de Henares, España.

---

**Resumen:** Los pinares mediterráneos españoles se ven afectados por incendios forestales con diferente frecuencia, intensidad y severidad. Para su valoración, hay que recurrir a estimaciones lo más precisas posibles de la severidad, la cual podrá ayudar a los gestores del bosque a decidir qué estrategia es más adecuada para mitigar el efecto del fuego. El objetivo de esta investigación es la estimación de la severidad post-incendio, relacionando un conjunto de variables independientes derivadas de las nubes de puntos del vuelo LiDAR (*Light Detection And Ranging*) del Plan Nacional de Ortofotografía Aérea (PNOA), con datos de campo basados en el índice CBI (*Composite Burn Index*) y recogidos en cuatro incendios localizados en Aragón. Se ha ajustado un modelo de regresión logística, que tras la validación, ha reportado una precisión del 85,5%, siendo las variables "*canopy relief ratio*" y el porcentaje de puntos por encima de 1 m de altura sobre el terreno, las incluidas en dicho modelo. Por otro lado, se ha realizado una comparativa de los resultados con índices espectrales derivados de imágenes Landsat Thematic Mapper.

**Palabras clave:** severidad del fuego, CBI, LiDAR, bosque mediterráneo, regresión logística.

## Forest fire severity estimation based on the LiDAR-PNOA data and the values of the Composite Burn Index

**Abstract:** Mediterranean pine forests in Spain experience wildland fire events with different frequencies, intensities, and severities. An estimation of the fire severity as accurate as possible is required by forest managers to decide which strategy is most appropriate to mitigate the effect of fire. The aim of this research is to estimate the post-fire severity, relating a pool of independent variables derived from the LiDAR (*Light Detection And Ranging*) points clouds delivered by the National Plan for Aerial Orthophotography (PNOA) to field data based on Composite Burn Index collected in four fires located in Aragón (Spain). Logistic regression models were developed and statistically tested and validated to map fire severity with up to 85.5% accuracy. The canopy relief ratio and the percentage of all returns above one meter height were the most significant variables. In addition, the obtained results are compared to different spectral indices derived from Landsat Thematic Mapper.

**Key words:** fire severity, CBI, LiDAR, Mediterranean forest, logistic regression.

---

**To cite this article:** Montealegre, A. L., Lamelas, M. T., Tanase, M. A., de la Riva, J. 2017. Forest fire severity estimation based on the LiDAR-PNOA data and the values of the composite burn index. *Revista de Teledetección*, 49, 1-16. <https://doi.org/10.4995/raet.2017.7371>

\* Corresponding author: [monteale@unizar.es](mailto:monteale@unizar.es)

## 1. Introducción

La localización y la distribución espacial del impacto del fuego en el bosque es esencial para llevar a cabo tratamientos de restauración, así como el monitoreo de la regeneración de la vegetación, estudios de hábitat de especies, etc. (Chuvieco, 2009).

En este contexto, el índice CBI (*Composite Burn Index*) fue desarrollado por Key and Benson (2006) dentro del proyecto FIREMON (*Fire Effects Monitoring and Inventory Protocol*) para los bosques de pinar del oeste de Estados Unidos. Su finalidad respondía a la necesidad de muestrear los cambios ocurridos y sintetizar los efectos del fuego en un espacio concreto. La utilidad del CBI es manifiesta, ya que ha sido aplicado y ajustado en una amplia variedad de ecosistemas, desde el mediterráneo hasta el boreal (De Santis and Chuvieco, 2009).

La pérdida de vigor y humedad vegetal, el aumento de la superficie de suelo desnudo y el cambio en su composición química como resultado de los diferentes niveles de severidad, tiene su reflejo en las regiones del infrarrojo próximo y medio del espectro electromagnético que pueden ser detectadas por los sensores ópticos pasivos (Chuvieco, 2009). Teniendo en cuenta las bondades que ofrecen los productos de teledetección, la estimación de la severidad con imágenes satelitales se ha llevado a cabo tradicionalmente empleando la reflectividad de las bandas originales, pero sobre todo, generando índices espectrales derivados de la combinación de aquellas. Existen experiencias desde el uso de sensores ópticos de 1 km de resolución espacial (por ejemplo, AVHRR-*Advanced Very High Resolution Radiometer*) hasta los 2 m (por ejemplo, *Quick Bird*), aunque el programa Landsat (30 m) ha sido el más utilizado (Tanase et al., 2011a). Sin embargo, las estimaciones de severidad post-fuego a partir de sensores pasivos adolecen de la consideración de los cambios ocurridos en la estructura forestal tras el fuego (Bergen et al., 2009). A este respecto, los sensores activos, como el radar de apertura sintética (Tanase et al., 2010; Tanase et al., 2011b) y el LiDAR (*Light Detection and Ranging*) son una buena alternativa.

En el caso concreto del LiDAR, la capacidad que tienen los pulsos láser de penetrar los elementos “porosos” de la superficie (hojas y ramas) y el

registro de múltiples retornos georreferenciados, posibilita una aproximación sobre los cambios ocurridos en la vegetación tras el incendio (Vosselman and Maas, 2010). Las investigaciones centradas en el uso de esta tecnología láser aeroportada abarcan desde la validación de las mediciones del LiDAR para aplicaciones forestales, la estimación de variables estructurales continuas del bosque y el análisis de la estructura de huecos en el dosel forestal, hasta el cálculo de parámetros ligados con los combustibles forestales, entre otras.

El objetivo de esta investigación es desarrollar una metodología que combine los datos de campo derivados de estimaciones empleando el índice CBI, e información extraída de datos LiDAR, para evaluar la severidad de cuatro incendios forestales utilizando un análisis multivariante. De manera implícita, se pretende analizar la idoneidad de los datos públicos LiDAR capturados para todo el territorio español en el marco del Plan Nacional de Ortofotografía Área (PNOA), que presentan una baja resolución espacial (0,5 puntos/m<sup>2</sup>).

En esta investigación se pretende dar respuesta a las siguientes cuestiones: ¿Cuál es la relación empírica entre los valores de CBI estimados en campo y las variables LiDAR derivadas de la distribución de las alturas de los retornos láser? ¿Cuál es el modelo de regresión más adecuado para cartografiar la severidad del fuego? ¿El resultado obtenido supera a las aproximaciones basadas en la estimación de la severidad mediante índices espectrales?

## 2. Materiales y métodos

### 2.1. Área de estudio

El área de estudio se circunscribe a la Comunidad Autónoma de Aragón (noreste de España), concretamente a cuatro incendios forestales de grandes dimensiones ocurridos entre los años 2008 y 2009; dos de ellos localizados en la provincia de Zaragoza (Zuera y Jaulín, con 2200 ha y 1800 ha, respectivamente) y el resto en la provincia de Teruel (Aliaga y Los Olmos, con 9000 ha y 500 ha, respectivamente) (Figura 1). En términos generales, gran parte de los espacios forestales aragoneses se caracterizan por una considerable peligrosidad estructural, debida a la complejidad de la orografía y a la vegetación

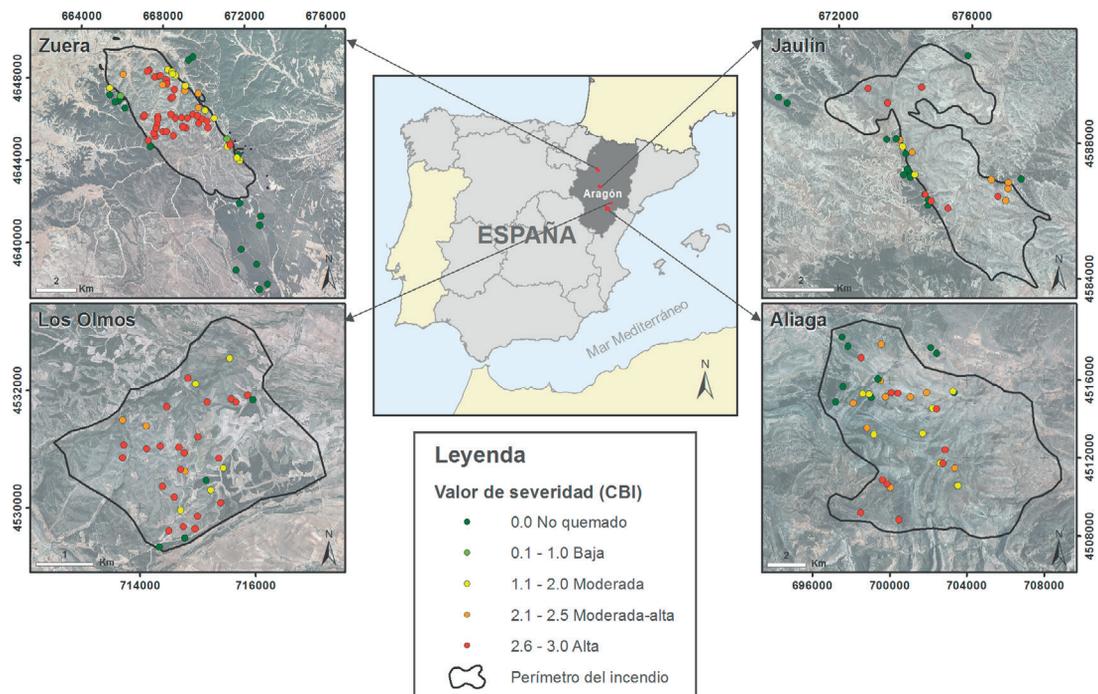
xerófila asociada a un clima mediterráneo continentalizado. En los incendios de Zuera y Jaulín se destruyeron bosques de *Pinus halepensis* con presencia de sotobosque compuesto por *Quercus coccifera* L., *Juniperus oxycedrus* L., *Rosmarinus officinalis* L. y *Genista Scorpius* L., así como pastizales y algunos campos de cultivo. En el caso de los dos incendios de Aliaga y Los Olmos, el fuego consumió exuberantes bosques de *Pinus nigra*, *P. sylvestris* y *Quercus ilex*, además de rodales de *Pinus halepensis*, formaciones de *Juniperus phoenicea*, matorrales esclerófilos, pastizales y algunas tierras de labor.

## 2.2. Parcelas de muestreo en el terreno (CBI)

La estimación de la severidad en campo evalúa el grado de pérdida o descomposición de la materia orgánica contenida en la vegetación y el suelo (Montorio *et al.*, 2014). En este trabajo se ha utilizado el índice CBI, creado por Key and Benson (1999), que permite valorar el nivel de variación de las condiciones biofísicas de un sitio tras el incendio considerando un conjunto de variables

parametrizadas para evaluar el efecto del fuego en cinco estratos verticales organizados jerárquicamente (Key and Benson, 2006): sustrato superficial del suelo; hierbas, arbustos y árboles de menos de 1 m de altura; arbustos y árboles de 1 a 5 m de altura; árboles intermedios de 10-25 cm de diámetro de tronco y 8-20 m de altura; y grandes árboles (mayores que los anteriores) que reciben luz solar directa.

El CBI está diseñado para evaluar la severidad del fuego en la primera temporada de crecimiento después de un incendio, por lo que se visitaron los cuatro incendios en los meses inmediatamente posteriores a su ocurrencia. Inicialmente, Tanase *et al.* (2011a) establecieron 247 parcelas de muestreo repartidas entre los cuatro incendios, considerando desde zonas no quemadas hasta zonas de alta severidad. Sin embargo, las tareas de restauración y gestión forestal llevadas a cabo por los servicios provinciales y la Dirección General de Gestión Forestal del Departamento de Medio Ambiente del Gobierno de Aragón, modificaron la estructura original de los elementos existentes en algunas de ellas, por lo que la muestra se redujo a 169 parcelas útiles para su asociación estadística con los datos LiDAR.



**Figura 1.** Área de estudio compuesta por cuatro incendios forestales y parcelas de muestreo de campo donde se ha estimado el valor de CBI.

**Tabla 1.** Parcelas CBI estratificadas según el incendio donde se localizan y la categoría de severidad.

Incendio	Valores de severidad CBI					N° de parcelas total
	No quemado (CBI = 0)	Baja (CBI ≤ 1)	Moderada (1 < CBI ≤ 2)	Moderada-alta (2 < CBI ≤ 2,5)	Alta (CBI > 2,5)	
Zuera	16	2	11	5	36	70
Jaulín	13	0	3	6	7	29
Aliaga	9	0	8	9	10	36
Los Olmos	4	0	5	3	22	34
N° de parcelas total	42	2	27	23	75	169
% sobre el total	24,85	1,18	15,98	13,61	44,38	100

Como se puede observar en la Tabla 1, la mayor parte de los bosques fueron afectados por severidad alta, por lo cual, las parcelas de muestreo no se distribuyen proporcionalmente por rangos de severidad.

De acuerdo con Tanase *et al.* (2011a) y las indicaciones de Key and Benson (2006), las parcelas circulares de muestreo de 30 m de diámetro se establecieron en sitios con vegetación homogénea y pendiente constante, es decir, cada sitio de muestreo representaba zonas de condiciones semejantes tanto respecto del tipo de vegetación como del nivel de severidad. En cada parcela se tomaron fotografías y el centro se georreferenció mediante un GPS centimétrico.

A la hora de llevar a cabo la estimación del estado de la vegetación tras el incendio, se examinó visualmente por estratos y de modo independiente, el grado de cambio con respecto al estado previo en una escala decimal de 0,0 (sin alteración) a 3,0 (totalmente alterada) con incrementos de 0,1. Finalmente, las puntuaciones de cada estrato fueron promediadas para obtener el valor de la severidad media (Key and Benson, 2006). Los

factores o los estratos que no se encontraron en la parcela fueron descartados (Tanase *et al.*, 2011a).

## 2.3. Datos LiDAR

### 2.3.1. Características de adquisición y pretratamiento

Los datos LiDAR utilizados, proporcionados por el PNOA, se capturaron entre los meses de agosto de 2010 y febrero de 2011, con un sensor de pulsos discretos (hasta 4 retornos), espejo oscilante y huella pequeña (Tabla 2). Se llevó a cabo un pretratamiento de los mismos, consistente en la eliminación de los retornos considerados como ruido y en el filtrado, utilizando el algoritmo de clasificación de curvatura multiescala incorporado en el software MCC-LiDAR v.2.1 (Evans y Hudak, 2007; Montealegre *et al.*, 2015). Posteriormente, los puntos de suelo fueron interpolados para crear los Modelos Digitales de Elevaciones (MDEs) de cada incendio con una resolución espacial de 1 m, empleando el método ANUDEM o Topo a ráster desarrollado por Hutchinson (1989) e implementado en ArcGIS 10.1®.

**Tabla 2.** Principales características de los datos LiDAR-PNOA utilizados.

Fecha de adquisición (dd/mm/aaaa)	Zuera (10/01/2011; 02/02/2011; 05/02/2011) Jaulín (01/08/2010) Aliaga (27/12/2010; 24/01/2011; 21/01/2011) Los Olmos (04/11/2010)
Sensor	Leica ALS-60 y ALS-50
Densidad nominal de puntos (puntos/m <sup>2</sup> )	0,5
Altura media de vuelo (m)	3355
Velocidad media del avión (km/h)	155
Ángulo de escaneo (grados)	±33
Precisión altimétrica de los puntos	≤ 0,20 m
Precisión planimétrica de los puntos	≤ 0,30 m
Superficie cubierta por los archivos LAS (km <sup>2</sup> )	244

### 2.3.2. Extracción de variables LiDAR relacionadas con los retornos láser

Los comandos “ClipData” y “CloudMetrics” incluidos en el software FUSION LDV 3.30 (McGaughey, 2009) permiten “recortar” las nubes de puntos con las dimensiones de las parcelas circulares de campo, al mismo tiempo que las alturas de los retornos láser son normalizadas empleando los MDEs. Es entonces cuando se calculan, para cada parcela, un conjunto de variables relacionadas con las alturas reales de los retornos láser y que comúnmente son utilizadas en el modelado de la estructura de la vegetación (Evans *et al.*, 2009). En la Tabla 3 se describen las variables LiDAR extraídas, susceptibles ser utilizadas en el modelo de regresión para estimar la severidad.

## 2.4. Imágenes de satélite e índices espectrales

Con objeto de contrastar el resultado del modelo de regresión que relaciona la información tridimensional de la superficie y el valor de CBI, con la información espectral que proporcionan los índices NBR (*Normalized Burn Ratio*) y dNBR (*differenced Normalized Burn Ratio*) (Key and Benson, 2006), ampliamente utilizados en la literatura científica para estimar la severidad, se han empleado ocho escenas (columna 199; fila 031 y 032) registradas por el satélite Landsat TM 5 (Tabla 4), que opera en siete bandas espectrales diferentes y tiene una resolución espacial de 30 m en todas las bandas, excepto en la 6.

Dichas imágenes fueron obtenidas a través del Plan Nacional de Teledetección (PNT) con un nivel de procesamiento mínimo. Por consiguiente, fue ineludible realizar una corrección geométrica, seguida de una corrección radiométrica.

El NBR relaciona la banda del infrarrojo próximo (entre 0,7 y 1,3  $\mu\text{m}$ ) y la banda del infrarrojo

medio de onda corta (entre 1,3 y 2,5  $\mu\text{m}$ ). Por tanto, el NBR es positivo en las zonas con actividad fotosintética intensa y negativo en zonas de baja productividad vegetal o sin vegetación (Key and Benson, 2006) (ecuación 1):

$$NBR = \frac{(R_4 - R_7)}{(R_4 + R_7)} \quad (1)$$

Donde  $R_4$  y  $R_7$  son las reflectividades de la banda 4 (infrarrojo próximo) y 7 (infrarrojo medio de onda corta) del sensor Landsat TM.

Para discriminar las zonas quemadas de las no quemadas y proporcionar una medida cuantitativa del cambio ocurrido en el área, el NBR post-incendio se resta al NBR pre-incendio, dando lugar al índice sintético dNBR (Chuvieco, 2010) (ecuación 2):

$$dNBR = NBR_{pre-incendio} - NBR_{post-incendio} \quad (2)$$

El dNBR (multiplicado por  $10^3$ ) provee un rango continuo de valores válidos que oscilan entre -550 y 1350. Los valores negativos suelen ser el resultado de la presencia de nubes en la imagen pre-fuego o de la regeneración vegetal rápida (herbáceas) en la imagen post-fuego ( $-500 < dNBR < -100$ ). Los valores positivos (entre 100 y 1300) se producen por el grado de impacto del fuego sobre la vegetación y el suelo, el cual puede discretizarse en diferentes clases de severidad: no quemado de -101 hasta +99; baja de +100 hasta +269; baja-moderada de +270 hasta +439; moderada-alta de +440 hasta +659; y alta de +660 hasta +1.300. Valores por encima de 1350 se corresponden normalmente a zonas nubosas (Key and Benson, 2006).

Por otro lado, una versión alternativa del anterior índice espectral es el *Relative dNBR* (RdNBR), propuesto por Miller and Thode (2007), para convertir el cambio absoluto medido por el dNBR en

**Tabla 4.** Imágenes Landsat utilizadas.

Zona de estudio	Fecha de inicio del incendio	Imagen pre-fuego	Imagen post-fuego	Columna/Fila
Zuera	06/08/2008	21/07/2008	22/08/2008	199/31
Jaulín	29/07/2009	22/06/2009	26/09/2009	199/31
Aliaga	22/07/2009	22/06/2009	26/09/2009	199/31
Los Olmos	22/07/2009	22/06/2009	26/09/2009	199/32

**Tabla 3.** Variables derivadas de la distribución de las alturas de los retornos láser, dónde  $x_i$  es el valor de la observación (altura del retorno),  $N$  es el número total de observaciones,  $r_i$  es el retorno, y  $pl_i$  es el pulso.

Variable	Descripción
Percentiles 1%, 5%, 10%, 20%, 25%, 30%, 40%, 50%, 60%, 70%, 75%, 80%, 90%, 95% y 99% ( $P_{01}$ , $P_{05}$ , $P_{10}$ , etc.)	Los diferentes valores de percentiles fueron calculados utilizando la siguiente metodología: $(N - 1)P = I + d \begin{cases} I \text{ es la parte entera de } (N - 1)P \\ d \text{ es la parte decimal de } (N - 1)P \end{cases}$ Donde $P$ es el percentil dividido por 100. Si $d = 0$ entonces Percentil = $x_{I+1}$ Si $d > 0$ entonces Percentil = $x_{I+1} + d(x_{I+2} - x_{I+1})$
Altura mínima	$x_{i \text{ mínima}}$
Altura máxima	$x_{i \text{ máxima}}$
Rango	$x_{i \text{ máxima}} - x_{i \text{ mínima}}$
Altura media ( $\mu$ )	$\frac{\sum_{i=1}^N x_i}{N}$
Moda de las alturas	Valor $x_i$ más frecuente en la parcela
Ratio de apertura del dosel ( <i>canopy relief ratio</i> )	$\frac{\mu - x_{i \text{ mínima}}}{x_{i \text{ máxima}} - x_{i \text{ mínima}}}$
Desviación típica ( $\sigma$ )	$\sqrt{\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}}$
Varianza ( $\sigma^2$ )	$\frac{\sum_{i=1}^N (x_i - \mu)^2}{N}$
Coefficiente de variación	$\frac{\sigma}{\mu} 100$
Desviación absoluta media	$\frac{\sum_{i=1}^N (x_i - \mu)}{N}$
Rango intercuartil	$[P_{75}(x) - P_{25}(x)]$
Asimetría	$\frac{\sum_{i=1}^N (x_i - \mu)^3}{(N - 1)\sigma^3}$
Curstosis	$\frac{\sum_{i=1}^N (x_i - \mu)^4}{(N - 1)\sigma^4}$
Porcentaje de retornos que son primeros, segundos, terceros y cuartos	$\frac{\sum_{i=1}^N r_{i \text{ primeros}}}{N} 100 ; \frac{\sum_{i=1}^N r_{i \text{ segundos}}}{N} 100 ; \text{ etc.}$
Porcentaje de retornos de suelo	$\frac{\sum_{i=1}^N r_{i \text{ suelo}}}{N} 100$
Porcentaje de retornos de vegetación	$\frac{\sum_{i=1}^N r_{i \text{ vegetación}}}{N} 100$
Porcentaje de pulsos con uno, dos o tres retornos	$\frac{\sum_{i=1}^N pl_{i \text{ con un retorno}}}{N} 100 ; \frac{\sum_{i=1}^N pl_{i \text{ con dos retorno}}}{N} 100 , \text{ etc.}$
Porcentaje de primeros retornos por encima de un umbral de altura determinado, de la altura media o de la moda (estimación de la fracción de cabida cubierta)	$\frac{\sum_{i=1}^N r_{i \text{ primeros}} > \text{umbral}}{\sum_{i=1}^N r_{i \text{ primeros}}} 100$
Porcentaje de retornos total por encima de un umbral de altura determinado, de la altura media o de la moda	$\frac{\sum_{i=1}^N r_i > \text{umbral}}{N} 100$
Porcentaje de retornos total por encima de un umbral de altura determinado, de la altura media o de la moda, sobre el total de primeros retornos	$\frac{\sum_{i=1}^N r_i > \text{umbral}}{\sum_{i=1}^N r_{i \text{ primeros}}} 100$

una medida relativa que varíe linealmente con la severidad (ecuación 3).

$$RdNBR = \frac{NBR_{pre-incendio} - NBR_{post-incendio}}{\sqrt{|NBR_{pre-incendio}|}} \quad (3)$$

## 2.5. Establecimiento del modelo de regresión

La muestra de valores de severidad fue sometida a un test de normalidad Shapiro-Wilk que reveló la falta de normalidad de la variable dependiente. Ante la imposibilidad de cumplimiento de dicho precepto, se optó por un análisis de regresión logística, que se utiliza para estimar la probabilidad de ocurrencia de una variable dependiente categórica binaria, permitiendo la inclusión de variables explicativas continuas sin que tengan que cumplir el supuesto de normalidad. El resultado es una relación multivariante con coeficientes que indican la influencia relativa de las variables independientes y que se expresa mediante el siguiente modelo (Hair *et al.*, 1999) (ecuación 4):

$$P(Y=1) = \frac{\exp(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)}{1 + \exp(\beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n)} \quad (4)$$

Donde  $P(Y=1)$  es la probabilidad de que la variable dependiente  $Y$  sea igual a 1,  $\beta_0$  es la constante y  $\beta_n$  es el coeficiente de la variable independiente  $X_n$ .

El resultado es una función continua cuyos valores de salida oscilan entre 0 y 1, de tal manera que los valores  $<0,5$  se corresponden con la no ocurrencia de la variable dependiente y los valores  $>0,5$  con la ocurrencia. No obstante, este umbral de probabilidad se modificó a 0,6 para adaptarse mejor a la asimetría de la muestra de datos de severidad (ver Tabla 1).

El método aplicado para el ajuste de los modelos logísticos fue el de búsqueda secuencial por pasos sucesivos. No obstante, también se llevó a cabo un análisis exploratorio desde el enfoque de especificación confirmatoria, empleando técnicas no paramétricas, como el coeficiente de correlación de Spearman y el test de Kruskal-Wallis. En relación a este último, se definieron dos categorías tras realizar un análisis cualitativo de los valores de severidad y su reflejo en la estructura de la nube de puntos: alta severidad (clase 1 =  $CBI > 1,5$ ) y baja o nula severidad (clase 0 =  $CBI \leq 1,5$ ). Se observó que a partir de un CBI de 1,5 las nubes de puntos correspondientes a las parcelas mostraban una clara reducción en el número de retornos procedentes de las hojas y ramas (Figura 2).

La medida global de cómo se ajusta el modelo viene dada por el valor de la verosimilitud (-2LL), de tal manera que cuanto más pequeño sea el valor de este parámetro, mejor será el ajuste (Hair *et al.*, 1999). En esta misma línea, el test de Hosmer-Lemeshow proporciona una medida final del ajuste que se basa también en la predicción real de la variable dependiente. Para ello, primeramente

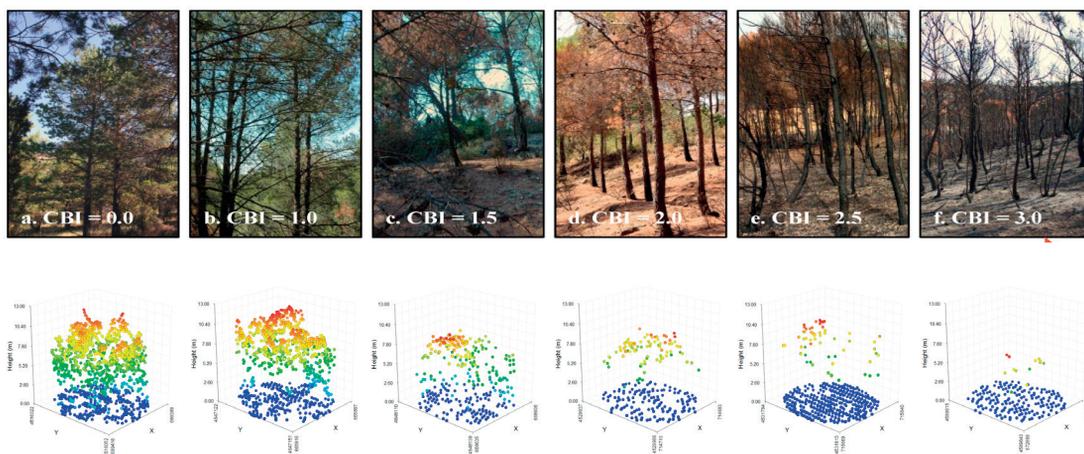


Figura 2. Ejemplos de parcelas de campo con distintos niveles de severidad.

se dividen los casos en 10 clases aproximadamente iguales, siendo comparado después el número de casos reales y predichos en cada clase con el estadístico *chi-cuadrado* ( $\chi^2$ ) (Hair et al., 1999).

Hay dos  $R^2$  (Pseudo- $R^2$ ) en la regresión logística que resumen la proporción de varianza en la variable dependiente asociada con las variables predictoras: la  $R^2$  de Cox y Snell, la  $R^2$  de Nagelkerke (Hair et al., 1999). Ambos Pseudo- $R^2$  devuelven un valor que oscila entre 0 y 1, de tal manera que se obtiene el valor máximo cuando el modelo asigna correctamente todos los casos en su respectiva categoría, y se aproxima a 0 cuando la asignación es deficiente.

La comprobación de la significación estadística del modelo de regresión logística se efectuó a nivel general, con el contraste *chi-cuadrado* (similar al estadístico *F* de la regresión lineal), y a nivel de las variables independientes incluidas, con el estadístico de Wald (similar al estadístico *t* de la regresión lineal). También se comprobó la bondad del modelo de regresión evaluando la concordancia entre lo predicho y la ocurrencia-no ocurrencia real de la variable dependiente. Para ello se dividió aleatoriamente la muestra compuesta por las parcelas de severidad en dos grupos: el 70% (118 parcelas) se utilizó para el ajuste, y el 30% (51 parcelas) restante se reservó para la validación. Mediante una matriz de confusión y el estadístico kappa se valoró la exactitud de la predicción (Pardo and Ruíz, 2005). Por otra parte, las curvas de ROC (*Receiver Operating Characteristic*), y el área bajo la curva (*AUC-Area Under the Curve*), permitieron cuantificar la capacidad discriminatoria del modelo. Esta área posee un valor comprendido entre 0,5 y 1, donde 1 representa un valor diagnóstico perfecto y 0,5 nula capacidad discriminatoria (Hanley and McNeil, 1982).

## 2.6. Cartografía de la severidad

El cálculo de las métricas LiDAR que intervienen en la ecuación del modelo se realizó con el software FUSION LDV 3.30 (McGaughey, 2009), mediante el comando “*GridMetrics*”. El tamaño del píxel seleccionado fue de 25 m de lado, lo que equivale a una superficie de 625 m<sup>2</sup>, similar a los 706,86 m<sup>2</sup> que ocupa una parcela de campo.

Finalmente, utilizando algebra de mapas en ArcGIS 10.1®, se generó una capa ráster para toda la superficie aplicando los coeficientes de la ecuación del modelo.

Con la finalidad de elaborar un mapa útil más allá de la respuesta dicotómica que ofrece el modelo (nula-baja severidad, alta severidad), se realizó una discretización de las probabilidades teniendo en cuenta la relación directa con las categorías establecidas por el protocolo CBI: no quemado (CBI=0), baja (CBI≤1), moderada (1<CBI≤2), moderada-alta (2<CBI≤2,5) y alta (CBI>2,5).

## 3. Resultados

El análisis de correlación mostró que las variables relacionadas con la distribución de las alturas de los retornos, como por ejemplo la curtosis (0,788) o el percentil 25 (-0,767), tuvieron la correlación más fuerte con los valores de CBI. Además, el porcentaje de retornos por encima de un metro (-0,757) o el porcentaje de primeros retornos sobre un metro (-0,744) también presentaron altos coeficientes de correlación (Tabla 5).

Con respecto a las diferencias entre los dos grupos de severidad, el percentil 20 y el porcentaje de retornos por encima de la altura media presentaron los valores más elevados de *chi*<sup>2</sup>, seguidos por el percentil 25 y el porcentaje de todos los retornos sobre la media divididos por todos los primeros retornos. En general, los percentiles bajos, las variables relacionadas con la variabilidad de los retornos como la asimetría, y el porcentaje de retornos por encima de un determinado umbral de altura, mostraron diferencias estadísticamente significativas entre los grupos de nula-baja severidad y alta severidad (Tabla 5).

De acuerdo con la Tabla 6, el modelo de regresión logística finalmente seleccionado fue el segundo, ya que el resto incluían variables no significativas. El  $R^2$  de Nagelkerke sugiere que este modelo explica aproximadamente el 66% de la variación y está compuesto por el porcentaje de todos los retornos por encima de 1 m de altura y la variable “*canopy relief ratio*”. El test de Hosmer y Lemeshow confirma, dado que el *chi*<sup>2</sup> no es significativo, que el segundo modelo se ajusta adecuadamente.

La tabla 7 muestra la significación estadística de los predictores individuales que ingresaron en el modelo seleccionado. Los coeficientes de ambas variables son significativos y negativos, por consiguiente indicando que una disminución de los valores de “*canopy relief ratio*” y en el porcentaje de todos los retornos por encima de 1 m está

**Tabla 5.** Coeficientes de correlación de Spearman (Rho) y valores de  $\chi^2$  resultantes del análisis de Kruskal-Wallis. Solo se muestran las correlaciones con una significación P valor  $\leq 0,01$ .

Variable	Rho	Chi <sup>2</sup>	Variable	Rho	Chi <sup>2</sup>
Kurtosis	0,788	54,169	% de primeros retornos > 3 m	-0,690	39,927
P <sub>25</sub>	-0,767	64,776	% de retornos total > 3 m sobre el total de primeros retornos	-0,690	39,797
P <sub>30</sub>	-0,764	63,550	Media	-0,684	34,138
% de retornos total > 1 m	-0,757	56,715	P <sub>60</sub>	-0,674	42,868
P <sub>20</sub>	-0,754	68,566	% de primeros retornos > de la altura media	-0,673	62,590
P <sub>40</sub>	-0,752	63,802	Canopy relief ratio	-0,671	57,964
Asimetría	0,747	64,611	% de retornos total > de la altura media sobre el total de primeros retornos	-0,661	64,776
% de primeros retornos > 1 m	-0,744	52,460	P <sub>70</sub>	-0,653	33,988
% de retornos total > 1 m sobre el total de primeros retornos	-0,742	51,915	P <sub>75</sub>	-0,649	29,533
% de retornos total > 2 m	-0,736	51,570	Rango intercuartil	-0,637	29,544
% de retornos de vegetación	-0,729	54,131	P <sub>80</sub>	-0,631	24,535
% de retornos de suelo	0,729	54,131	% de retornos total > de la media	-0,630	67,337
P <sub>50</sub>	-0,728	57,146	% de pulsos con un retorno	0,623	30,906
% de primeros retornos > 2 m	-0,723	47,116	% de pulsos con dos retornos	-0,622	31,020
% de retornos total > 2 m sobre el total de primeros retornos	-0,722	46,904	Desviación absoluta media	-0,614	16,834
% de retornos total > 3 m	-0,702	43,290	P <sub>90</sub>	-0,608	16,450

asociada con el incremento de la probabilidad de tener una severidad alta. La variable “canopy relief ratio” es un descriptor cuantitativo de la forma del dosel que oscila entre 0 y 1 y refleja si el dosel está más alto (>0,5) o más bajo (<0,5): para una alta severidad, esta variable tiende a 0, mientras que si está próxima a 0,5 es indicadora de una baja severidad. El porcentaje de todos los retornos por encima de 1 m es sensible a la cantidad de biomasa localizada sobre el sotobosque. Si el porcentaje es bajo significa que las copas han sido consumidas

por el fuego, permaneciendo tan solo los troncos y algunas ramas, lo que indica una alta severidad.

Por lo que respecta a la capacidad del modelo para identificar las parcelas con alta y nula-baja severidad, la Tabla 8 muestra el porcentaje de acuerdo entre los valores observados y predichos tanto para la muestra de entrenamiento como para la de validación. Tal como se comentó anteriormente, el valor 1 (alta severidad) fue asignado al valor predicho cuando la probabilidad obtenida es

**Tabla 6.** Modelos de regresión logística generados con sus correspondientes estadísticos.

Paso/Modelo	Test de $\chi^2$				Pseudo-R <sup>2</sup>		Test de Hosmer y Lemeshow	
	-2LL	X <sup>2</sup>	g.l.	P valor (>X <sup>2</sup> )	R <sup>2</sup> de Nagelkerke	Chi <sup>2</sup>	g.l.	P valor
1	91,871	56,429	1	0,000	0,531	31,607	8	0,000
2	73,290	75,011	2	0,000	0,658	3,663	8	0,886
3	53,845	94,456	3	0,000	0,770	3,519	8	0,898
4	42,790	105,511	4	0,000	0,826	1,139	8	0,997
5	35,507	112,794	5	0,000	0,860	0,369	8	1,000
6	29,076	119,225	6	0,000	0,889	3,088	8	0,929
7	29,681	118,620	5	0,000	0,886	3,704	8	0,883
8	21,329	126,972	6	0,000	0,921	1,552	8	0,992
9	17,315	130,986	7	0,000	0,937	1,790	7	0,971
10	10,239	138,061	8	0,000	0,964	0,185	6	1,000
11	10,995	137,306	7	0,000	0,961	0,250	6	1,000

**Tabla 7.** Coeficientes ( $\beta$ ), test de Wald y significación P valor  $\leq 0,05$  de las variables introducidas en el modelo seleccionado.

Variables explicativas	$\beta$	Error estándar	Test de Wald	g.l.	P valor
Canopy relief ratio	-12,236	3,451	12,571	1	0,000
% de todos los retornos por encima de 1 m	-0,055	0,013	17,620	1	0,000
Constante	6,925	1,566	19,546	1	0,000

mayor que la del punto de corte (0,6), cuantificado como la proporción de parcelas CBI clasificadas como 1. Como se puede apreciar, existen porcentajes de acierto similares entre ambas muestras de datos (85,6% y 84,3%). Además, el índice kappa demuestra un buen acuerdo en ambos casos (0,681 y 0,565).

La Figura 3 representa las curvas de ROC y los valores de AUC de las muestras de entrenamiento y validación del modelo. Los resultados, bastante parejos, son indicativos de la robustez del modelo y de que no hay sobreajuste.

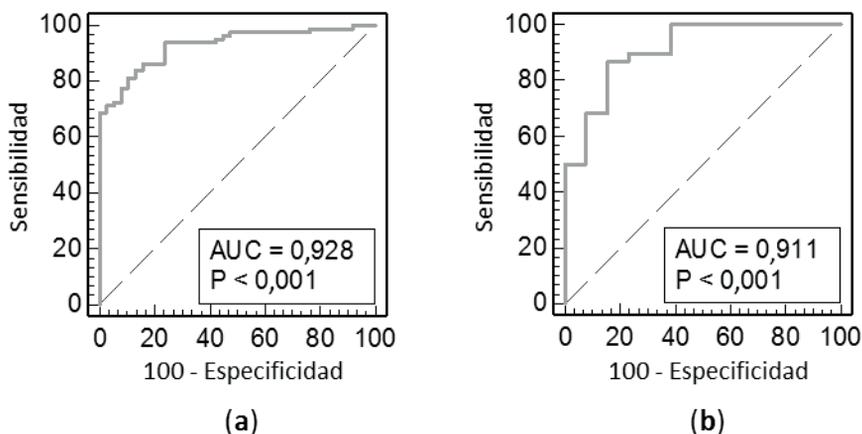
La implementación del modelo de regresión en ArcGIS 10.1® dio como resultado la cartografía que se muestra en la Figura 4. El área contenida

dentro del perímetro de los incendios fue afectada, en su mayor parte, por altos niveles de severidad (Zuera 91,16%, Jaulín 76,00%, Aliaga 80,06% y Los Olmos 77,53%). El modelo está ajustado solo para las áreas que estaban cubiertas por masas de pinar homogéneas y continuas, de ahí que se haya utilizado una máscara de este tipo de cubierta a la hora de presentar los resultados cartográficos.

Para determinar si los valores de probabilidad predichos se relacionan mejor con el CBI que los índices espectrales dNBR y RdNBR, se realizó un análisis de correlación tal y como se puede observar en la Figura 5. Aunque el R<sup>2</sup> más alto se obtuvo con la correlación entre RdNBR y el CBI (0,68), el coeficiente de determinación entre el modelo de regresión y los valores de CBI produjo un R<sup>2</sup> de

**Tabla 8.** Matrices de confusión de las muestras de entrenamiento y validación, e índice kappa.

Muestra de entrenamiento (N=118)					Muestra de validación (N=51)						
		Severidad predicha			% de acierto			Severidad predicha			% de acierto
		Nula-baja	Alta	Total				Nula-baja	Alta	Total	
Severidad observada	Nula-baja	32	6	38	84,2	Severidad observada	Nula-baja	8	5	13	61,9
	Alta	11	69	80	86,3		Alta	3	35	38	92,1
	Total	43	75	118	85,6		Total	11	40	51	84,3
Índice kappa	0,681					Índice kappa	0,565				
Error estándar	0,071					Error estándar	0,136				
P valor	0,000					P valor	0,000				



**Figura 3.** Curvas de ROC y valores de AUC de las muestras de entrenamiento (a) y validación (b).

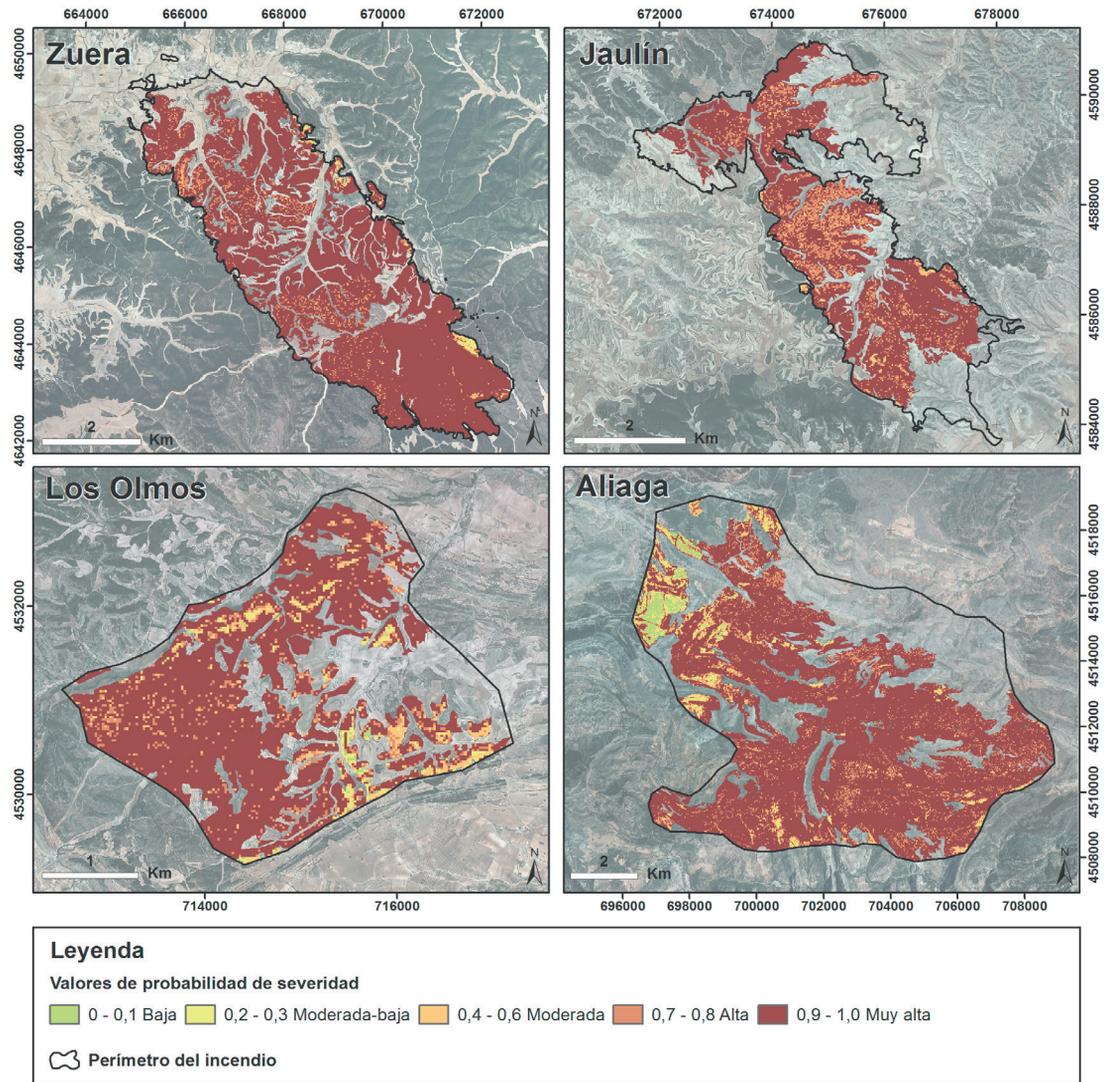
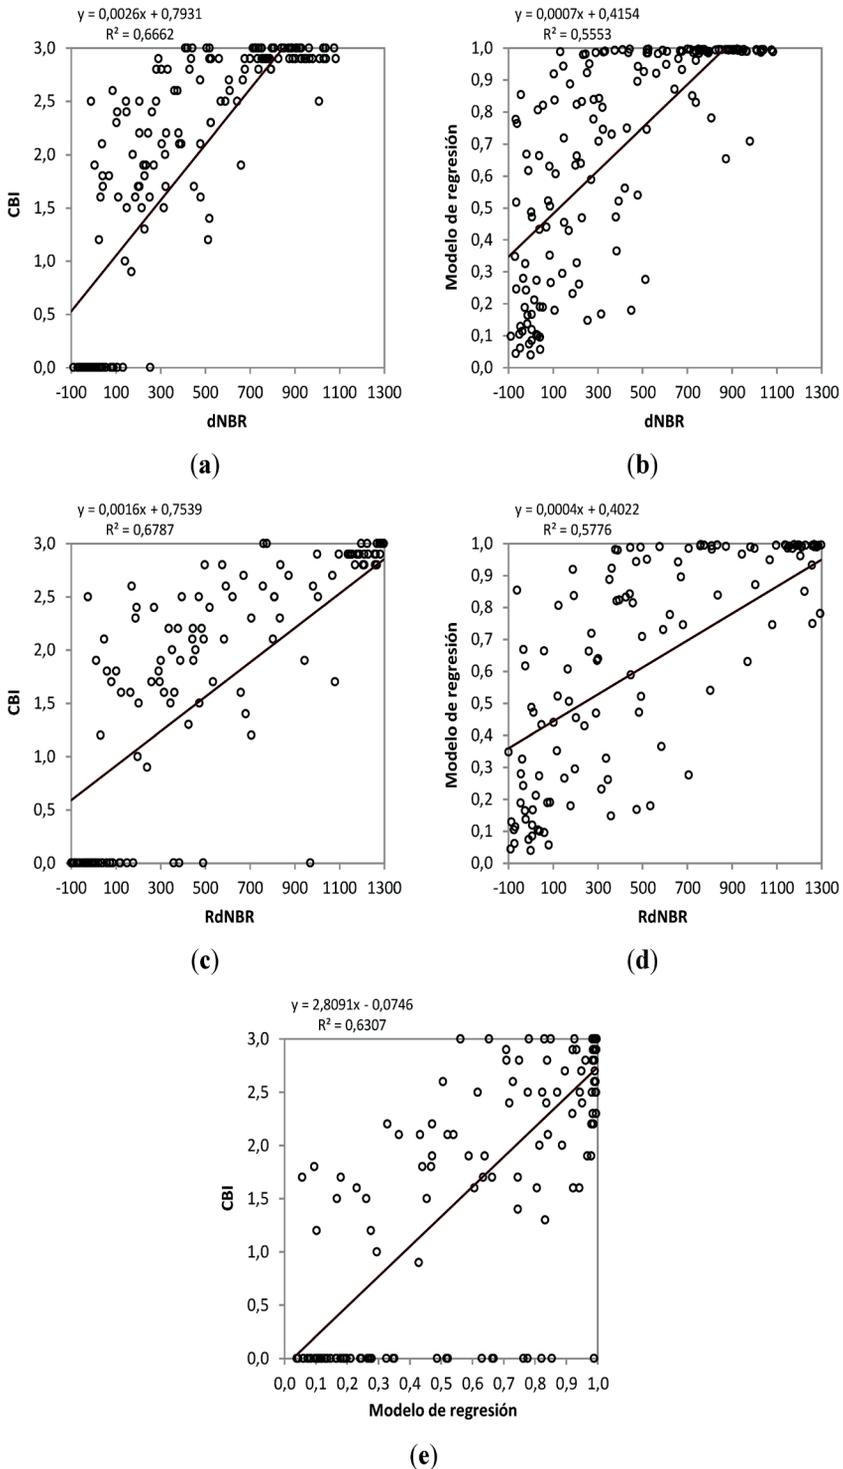


Figura 4. Mapas de severidad obtenidos a partir del modelo de regresión logística.

0,63, lo cual es aceptable teniendo en cuenta que el modelo carece de información pre-fuego, a diferencia de los índices espectrales. Por otra parte, la correlación entre el modelo de regresión y estos índices es moderada, siendo mejor con RdNBR ( $R^2$  de 0,58). Aunque todas las aproximaciones producen resultados similares, puede concluirse que todavía no hay un índice perfecto para cartografiar los efectos del fuego.

En la tabla 9 se muestran los rangos de valores de severidad en función del modelo de regresión, del RdNBR y del dNBR obtenidos para cada

parcela de muestreo. Para comprobar el grado de correspondencia entre las categorías de severidad de CBI y las categorías establecidas manualmente con los valores de probabilidad y con los índices espectrales, se calculó el índice kappa y el porcentaje de acuerdo en cada categoría. Como se puede observar, el modelo tiende a subestimar la severidad baja, la moderada y la moderada-alta, pero presenta un alto porcentaje de acierto en la categoría de alta severidad (89,33%) frente a los índices espectrales. A tenor de los resultados, parece que los índices espectrales son más sensibles



**Figura 5.** Diagramas de dispersión de los valores de dNBR, RdNBR, probabilidad del modelo de regresión y CBI. En cada diagrama se muestra la ecuación de la recta de regresión, el coeficiente de determinación ( $R^2$ ) y la línea de tendencia. (a) CBI vs. dNBR; (b) Modelo de regresión vs. dNBR; (c) CBI vs. RdNBR; (c) CBI vs. RdNBR; (e) CBI vs. Modelo de regresión.

**Tabla 9.** Rangos de valores de probabilidad, RdNBR y dNBR por categoría de severidad, y porcentajes de acuerdo entre categorías. También se muestra el índice kappa (P valor  $\leq 0,01$ ).

Rango de valores CBI	Categoría	Rangos de valores			% de acuerdo		
		Probabilidad del modelo de regresión	RdNBR	dNBR	Probabilidad del modelo de regresión (kappa = 0,42)	RdNBR (kappa = 0,60)	dNBR (kappa = 0,55)
CBI = 0	No quemado	<0,30	<118	<81	66,67	83,33	85,71
CBI $\leq 1$	Baja	0,30	297	198	0,00	100,00	100,00
1 < CBI $\leq 2$	Moderada	0,40	451	291	18,52	29,63	33,33
2 < CBI $\leq 2,5$	Moderada-alta	0,60	894	545	13,04	47,83	34,78
CBI > 2,5	Alta	>0,80	>894	>545	89,33	86,67	77,33
				Precisión global	60,95	71,60	66,86

a los niveles bajos de severidad, mientras que el modelo de regresión es más preciso a la hora de identificar las parcelas con severidad alta.

#### 4. Discusión

El objetivo principal de esta investigación ha sido evaluar la idoneidad de las variables extraídas de los datos LiDAR-PNOA para estimar la severidad en cuatro áreas quemadas de la Comunidad Autónoma de Aragón, empleando datos de referencia obtenidos directamente en el campo mediante el índice CBI.

Por un lado, este índice estima el cambio ocurrido en el ecosistema después del fuego con respecto a una situación previa utilizando parámetros cualitativos que son codificados en rangos o categorías de severidad. Por otro lado, los datos LiDAR post-incendio solo proporcionan estimaciones de la estructura de la vegetación, pero no informan sobre el cambio que ha sufrido ésta tras el fuego. Por lo tanto, se ha tenido que asumir que las parcelas de campo, y las masas de pinar afectadas en su conjunto, presentaban una vegetación homogénea y continua (Tanase *et al.*, 2011a). A pesar de este condicionante relacionado con la propia naturaleza de las variables utilizadas, los análisis de correlación y de contraste entre grupos de severidad (alta y nula-baja), revelaron relaciones intensas entre algunas de las variables derivadas de las alturas de los retornos láser. Esto permitió el establecimiento de un modelo de regresión para predecir los niveles de severidad del área contenida dentro del perímetro de los incendios, con la finalidad de obtener una cartografía de 25 m de resolución espacial.

El carácter novedoso y pionero que supone esta investigación, se une a algunos otros estudios que confirman la utilidad de los datos LiDAR para analizar la severidad (Bergen *et al.*, 2009; Angelo *et al.*, 2010; Kane *et al.*, 2013a; Kane *et al.*, 2013b). Por ejemplo, Kane *et al.* (2013b) utilizaron datos LiDAR junto con imágenes Landsat para estimar la severidad en grandes áreas, llegando a la conclusión de que a medida que la severidad del fuego aumenta, la cobertura del dosel disminuye y se incrementa el número de huecos, reflejándose en una fragmentación progresiva del bosque.

Wang and Glenn (2009) estimaron con una alta precisión (84% de acierto) la severidad en un ecosistema de pastizal utilizando datos LiDAR pre y post fuego. Su aproximación estaba basada en la evaluación de los cambios en la altura media de la vegetación utilizando estas dos fuentes de información, lo cual está relacionado con la combustión y la pérdida de biomasa. A diferencia de ésta y otras investigaciones que utilizan nubes de puntos capturadas en fechas distintas, en España sólo será posible en el marco del PNOA cuando se ponga a disposición pública la segunda cobertura, que se prevé con una densidad nominal de 1 punto/m<sup>2</sup>. En este sentido, McCarley *et al.* (2017) se sirven de dos vuelos LiDAR de 8 puntos/m<sup>2</sup> e imágenes ópticas Landsat pre y post fuego para modelar los cambios en la estructura forestal tras el incendio.

La regresión logística es una técnica que fue seleccionada debido a su capacidad para trabajar con diferentes tipos de variables, incluso cuando están autocorrelacionadas (Menard, 2010). El modelo seleccionado permitió obtener mapas con una precisión en la predicción de hasta el 85,8%, teniendo

en cuenta solo las zonas de bosque de pinar. Esta investigación contribuye a la creación de teorías sobre cuáles son las variables explicativas más importantes para la estimación de la severidad utilizando datos LiDAR de baja densidad de puntos.

Por otro lado, esta investigación, como muchas otras basadas en datos LiDAR, no cuenta con datos de campo simultáneos a la captura de las nubes de puntos (Kane *et al.*, 2013a), sin embargo, el carácter perennifolio de las especies del área de estudio compensó esta carencia. Conviene remarcar que, durante la captura de las nubes de puntos, algunos de estos bosques fueron objeto de tareas de restauración, de manera que las parcelas de campo situadas en esas zonas hubo que descartarlas del análisis. Esto produjo una reducción considerable de la muestra inicial y un reparto desigual de las parcelas en relación con las categorías de severidad. Creemos que si la muestra estuviese mejor repartida en las distintas categorías de CBI se podría mejorar la precisión del modelo. No obstante, el error fue menor en la identificación de la alta severidad, frente a la nula-baja, lo cual se considera beneficioso para el desarrollo de tareas de gestión forestal sobre las áreas que han sido quemadas severamente (Miller and Thode, 2007).

Como líneas de trabajo futuras, además de la utilización de información pre y post-fuego para la generación de índices, sería interesante aplicar otros métodos, como *random forest* y árboles de decisión, que podrían mejorar la identificación de múltiples categorías de severidad sin recurrir a la discretización de los valores continuos de probabilidad de severidad. Por otro lado, sería deseable la integración de imágenes ópticas multiespectrales, muy adecuadas para capturar la distribución horizontal de las condiciones de la vegetación, junto con variables LiDAR que capturan la estructura vertical de la vegetación, para estimar con mayor precisión la severidad (Wulder *et al.*, 2009).

## 5. Conclusiones

Este estudio presenta una nueva aproximación metodológica que combina variables derivadas de nubes de puntos LiDAR de baja densidad y datos de severidad estimada en campo mediante el protocolo CBI. Se ha demostrado que las variables LiDAR derivadas de la distribución de las alturas de los retornos a nivel de parcela proporcionan un

apoyo inicial para estimar la severidad. Variables como la curtosis o el percentil 25 de las alturas de los retornos presentaron las correlaciones más altas con los valores CBI. La diferencia entre la categoría de alta y baja severidad puede estimarse mejor utilizando el percentil 20 y el porcentaje de todos los retornos por encima de la media de acuerdo con el análisis Kruskal-Wallis. Los percentiles bajos (entre 20 y 40), la asimetría y algunos porcentajes de retornos por encima de un umbral determinado, como la altura media, también mostraron diferencias significativas entre las dos categorías de severidad. Las relaciones entre los datos CBI y las variables LiDAR fueron evaluadas por medio de un modelo de regresión logística. La capacidad de predicción del modelo fue testada utilizando una muestra de validación independiente. Los resultados muestran una precisión aceptable en su conjunto, confirmando que la regresión logística es una herramienta efectiva que permite cartografiar la severidad.

## 6. Agradecimientos

Estos trabajos han sido financiados por la beca predoctoral (FPI BOA 30, 11/02/2011) del Gobierno de Aragón y el proyecto CGL2014-57013-C2-2-R, y han contado con la ayuda de Francisco Palú, Marco Lorenzo y Emilio Pérez-Aguilar del Servicio Provincial de Agricultura, Ganadería y Medio Ambiente del Gobierno de Aragón. Los autores agradecen al Centro Nacional de Información Geográfica y al Centro de Información Territorial de Aragón por proporcionar los datos LiDAR-PNOA y al CENAD “San Gregorio” por facilitar el acceso a las parcelas de campo.

## Referencias

- Angelo, J.J., Duncan, B.W., Weishampel, J.F. 2010. Using Lidar-derived vegetation profiles to predict time since fire in an oak scrub landscape in East-Central Florida. *Remote Sens.*, 2, 514–525. <https://doi.org/10.3390/rs2020514>
- Bergen, K.M., Goetz, S.J., Dubayah, R.O., Henebry, G.M., Hunsaker, C.T., Imhoff, M.L., Nelson, R.F., Parker, G.G., Radeloff, V.C. 2009. Remote sensing of vegetation 3-D structure for biodiversity and habitat: Review and implications for lidar and radar spaceborne missions. *J. Geophys. Res. Biogeosciences*, 114, G00E06. <https://doi.org/10.1029/2008JG000883>

- Chuvieco, E. 2010. *Teledetección ambiental. La observación de la Tierra desde el espacio*. Barcelona: Ariel Ciencia.
- Chuvieco, E. 2009. *Earth Observation of Wildland Fires in Mediterranean Ecosystems*. Alcalá de Henares: Springer. <https://doi.org/10.1007/978-3-642-01754-4>
- De Santis, A., Chuvieco, E. 2009. GeoCBI: A modified version of the Composite Burn Index for the initial assessment of the short-term burn severity from remotely sensed data. *Remote Sens. Environ.*, 113, 554–562. <https://doi.org/10.1016/j.rse.2008.10.011>
- De Santis, A., Chuvieco, E. 2007. Burn severity estimation from remotely sensed data: Performance of simulation versus empirical models. *Remote Sens. Environ.*, 108, 422–435. <https://doi.org/10.1016/j.rse.2006.11.022>
- Evans, J., Hudak, A., Faux, R., Smith, A.M. 2009. Discrete Return Lidar in Natural Resources: Recommendations for Project Planning, Data Processing, and Deliverables. *Remote Sens.*, 1, 776–794. <https://doi.org/10.3390/rs1040776>
- Evans, J.S., Hudak, A.T. 2007. A Multiscale Curvature Algorithm for Classifying Discrete Return LiDAR in Forested Environments. *Geosci. Remote Sens. IEEE Trans. On*, 45, 1029–1038. <https://doi.org/10.1109/TGRS.2006.890412>
- Hair, J.F., Anderson, R.E., Tatham, R.L., Black, W.C. 1999. *Análisis multivariante*, 5a. ed. Madrid: Prentice Hall Iberia.
- Hanley, J.A., McNeil, B. 1982. The meaning and use of the área under a Receiver Operating Characteristic (ROC) curve. *Radiology*, 143, 29–36. <https://doi.org/10.1148/radiology.143.1.7063747>
- Hutchinson, M.F., 1989. A new procedure for gridding elevation and stream line data with automatic removal of spurious pits. *J. Hydrol.*, 106, 211–232. [https://doi.org/10.1016/0022-1694\(89\)90073-5](https://doi.org/10.1016/0022-1694(89)90073-5)
- Kane, V.R., Lutz, J.A., Roberts, S.L., Smith, D.F., McGaughey, R.J., Povak, N.A., Brooks, M.L. 2013a. Landscape-scale effects of fire severity on mixed-conifer and red fir forest structure in Yosemite National Park. *For. Ecol. Manag.*, 287, 17–31. <https://doi.org/10.1016/j.foreco.2012.08.044>
- Kane, V.R., North, M.P., Lutz, J.A., Churchill, D.J., Roberts, S.L., Smith, D.F., McGaughey, R.J., Kane, J.T., Brooks, M.L. 2013b. Assessing fire effects on forest spatial structure using a fusion of Landsat and airborne LiDAR data in Yosemite National Park. *Remote Sens. Environ.*, 151, 89-101. <https://doi.org/10.1016/j.rse.2013.07.041>
- Key, C.H., Benson, N. 1999. The Composite Burn Index (CBI): Field rating of burn severity. Geological Survey, U.S.
- Key, C.H., Benson, N.C. 2006. Landscape assessment (LA) sampling and analysis methods. USDA For. Serv. Rocky Mt. Res. Stn. Gen Tech Rep RMRS-GTR-164.
- McCarley, T.R., Kolden, C.A., Vaillant N.M., Hudak, A.T., Smith, A.M.S., Wing B.M., Kellogg B.S., Kreitler J. 2017. Multi-temporal LiDAR and Landsat quantification of fire-induced changes to forest structure. *Remote Sens. Environ.*, 191, 419–432. <https://doi.org/10.1016/j.rse.2016.12.022>
- McGaughey, R. 2009. FUSION/LDV: Software for LIDAR Data Analysis and Visualization. US Department of Agriculture, Forest Service, Pacific Northwest Research Station, Seattle, USA.
- Menard, S. 2010. *Logistic regression: From introductory to advanced concepts and applications*. USA: SAGE. <https://doi.org/10.4135/9781483348964>
- 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/10.1016/j.rse.2006.12.006>
- Montealegre, A.L., Lamelas, M.T., de la Riva, J. 2015. A Comparison of Open-Source LiDAR Filtering Algorithms in a Mediterranean Forest Environment. *IEEE J. Sel. Top. Appl. Earth Obs. Remote Sens.*, 8, 4072–4085. <https://doi.org/10.1109/JSTARS.2015.2436974>
- Montorio, R., Pérez-Cabello, F., García-Martín, A., Vlassova, L., Fernández, J. 2014. La severidad del fuego: revisión de conceptos, métodos y efectos ambientales, en: *Geoecología, cambio ambiental y paisaje: homenaje al profesor José María García Ruiz*, Instituto Pirenaico de Ecología, Universidad de La Rioja, 427–440.
- Pardo, A., Ruíz, M.A. 2005. *Análisis de datos con SPSS 13 Base*. Madrid: Mc Graw Hill, 600 pp
- Tanase, M., de la Riva, J., Pérez-Cabello, F. 2011a. Estimating burn severity at the regional level using optically based indices. *Can. J. For. Res.*, 41, 863–872. <https://doi.org/10.1139/x11-011>
- Tanase, M., de la Riva, J., Santoro, M., Pérez-Cabello, F., Kasischke, E., 2011b. Sensitivity of SAR data to post-fire forest regrowth in Mediterranean and boreal forests. *Remote Sens. Environ.*, 115, 2075–2085. <https://doi.org/10.1016/j.rse.2011.04.009>

- Tanase, M.A., Santoro, M., Wegmüller, U., de la Riva, J., Pérez-Cabello, F. 2010. Properties of X-, C- and L-band repeat-pass interferometric SAR coherence in Mediterranean pine forests affected by fires. *Remote Sens. Environ.*, 114, 2182–2194. <https://doi.org/10.1016/j.rse.2010.04.021>
- Vosselman, G., Maas, H.-G., 2010. *Airborne and Terrestrial Laser Scanning*. Dunbeath: Whittles Publishing.
- Wang, C., Glenn, N.F., 2009. Estimation of fire severity using pre- and post-fire LiDAR data in sagebrush steppe rangelands. *Int. J. Wildland Fire*, 18, 848–856. <https://doi.org/10.1016/j.rse.2010.04.021>
- Wulder, M.A., White, J.C., Alvarez, F., Han, T., Rogan, J., Hawkes, B. 2009. Characterizing boreal forest wildfire with multi-temporal Landsat and LIDAR data. *Remote Sens. Environ.*, 113, 1540–1555. <https://doi.org/10.1016/j.rse.2009.03.004>