

Potencial de las imágenes UAV como datos de verdad terreno para la clasificación de la severidad de quema de imágenes Landsat: aproximaciones a un producto útil para la gestión post incendio

Pla, M.^{1*}, Duane, A.^{1,2}, Brotons, L.^{1,2,3}

¹Centre Tecnològic Forestal de Catalunya (CTFC-INFOREST), Ctra. de Sant Llorenç de Morunys, km 2, 25280 Solsona, Lleida, España.

²Centre de Recerca Ecològica i Aplicacions Forestals (CREAF), 08193 Cerdanyola del Vallès, España.

³Consejo Superior de Investigaciones Científicas (CSIC), 08193 Cerdanyola del Vallès, España.

Resumen: La cuantificación de la severidad de los incendios forestales es determinante para conocer la evolución del paisaje después de un incendio forestal y provee información de gran utilidad frente a la toma de decisiones en la gestión post incendio. La cartografía cuantitativa de severidad de incendios a partir de cambios relativos del índice *Normalized Burn Ratio* (RdNBR) no está siendo realmente incorporada en los procesos de toma de decisiones, siendo más utilizada la categorización en niveles de severidad (alta, mediana y baja). Sin embargo, las clasificaciones de severidad más comunes, basadas en la definición de umbrales de corte de RdNBR a partir de información de campo, no son siempre posibles por falta de datos de campo o bien porque los umbrales publicados resultan poco satisfactorios en localizaciones distintas a las de su calibración. El auge del uso de UAVs (*Unmanned Aerial Vehicle*) ha planteado estas plataformas como posible herramienta para la validación de información de satélite. En el presente trabajo se presenta la potencialidad de los UAV como información de verdad terreno en incendios forestales. A partir de la foteointerpretación de imágenes RGB de alta resolución se ha creado el índice ASPI (*Aerial Severity Proportion Index*), el cual, a partir de modelos de regresión no lineales con el índice RdNBR, permite delimitar umbrales para la clasificación de las imágenes Landsat y obtener un mapa cualitativo de severidad. La validación de los modelos de regresión entre RdNBR y ASPI a partir de puntos al azar muestra un índice kappa de 0,5 con un acierto relativo del 70,8%. Por lo tanto, las imágenes UAV son una herramienta muy útil para la clasificación de la severidad de incendios forestales y para rellenar la brecha existente entre la información proveniente de imágenes de satélite y las costosas campañas de campo.

Palabras clave: severidad, incendios forestales, Landsat, UAV, RdNBR.

Potential of UAV images as ground-truth data for burn severity classification of Landsat imagery: approaches to an useful product for post-fire management

Abstract: Mapping fire severity is determinant to understand landscape evolution after a wildfire and provides useful information for decision making during post fire management. Quantitative fire severity mapping from relative changes in Normalized Burn Ratio index (RdNBR) is not actually being incorporated into decision making processes, being more

To cite this article: Pla, M., Duane, A., Brotons, L. 2017. Potential of UAV images as ground-truth data for burn severity classification of Landsat imagery: approaches to an useful product for post-fire management. *Revista de Teledetección*, 49, 91-102. <https://doi.org/10.4995/raet.2017.7140>

* Corresponding author: magda.pla@ctfc.cat

useful the categorization in severity levels (high, moderate and low). However, the most common mapping severity methodologies based on the definition of RdNBR thresholds from field information are not always possible due to lack of field data or because the published thresholds are unsatisfactory in new regions. The boom in the use of UAVs (Unmanned Aerial Vehicle) has raised these platforms as potential tools for validation of remote sensing data. This paper presents the potential of UAVs as ground truth information in forest fires. From the photointerpretation of high resolution RGB images, the Aerial Severity Proportion Index (ASPI) has been created. Non-linear regression models between RdNBR and ASPI allows to delimitate of thresholds for the classification of Landsat images and to obtain qualitative severity maps. Validation with random points presents a kappa index of 0,5 and a relative accuracy of 70,8%. Therefore, UAV images become a very useful tool for wildfire severity mapping and for fill the gap between remote sensing information and expensive field ground campaigns.

Key words: severity, wildfires, Landsat, UAV, RdNBR.

1. Introducción

En los ecosistemas forestales Mediterráneos los efectos de los incendios sobre la cubierta vegetal pueden variar en función de la intensidad con la que se producen, las características de las propias especies y los rasgos topoclimáticos de la zona quemada. En este contexto, profundizar en el conocimiento de la severidad, entendiéndola como el nivel de afectación sobre la cubierta forestal justo después de un incendio (White *et al.*, 1996; Díaz-Delgado *et al.*, 2003), y el seguimiento de la regeneración de la cubierta vegetal a medio plazo se convierten en elementos clave para la gestión del paisaje (Chen *et al.*, 2011; Lentile *et al.*, 2006).

Actualmente, en Cataluña, los entes gestores del territorio utilizan y generan cartografía del perímetro de los incendios. Pero lo que ocurre y cómo ocurre dentro del perímetro del incendio no es actualmente recogida de manera regular y es información realmente útil para la gestión post-incendio: cómo y cuánto se ha quemado un bosque, qué superficie ha sido más o menos afectada, cuánto y cuándo se recuperará, etc. Dicha información a menudo se estima de manera subjetiva, hecho que puede llevar a distintas interpretaciones de un mismo evento según el punto de vista y el objetivo concreto de la información recogida.

Durante los últimos años se ha visto la necesidad de disponer de cartografía del nivel de afectación de los incendios forestales en Cataluña; es decir, cartografía de severidad de incendio. Existen distintos trabajos científicos que cuantifican con gran rigor la severidad de algunos incendios forestales a través de índices como el *Normalized Difference Vegetation Index*, en adelante NDVI

(Díaz-Delgado *et al.*, 2003; Escuin *et al.*, 2008; White *et al.*, 1996), o más recientemente utilizando el índice dNBR (*differenced Normalized Burnt Ratio*) o RdNBR (*Relative differenced Normalized Burnt Ratio*), que difieren del NDVI en que ambos utilizan el infrarrojo cercano y el medio, en lugar del rojo y el infrarrojo cercano, los cuales se ha demostrado que captan mejor la complejidad espacial de la severidad dentro del perímetro del incendio (Cansler y McKenzie 2012; Miller y Thode 2007; Parks *et al.*, 2014). Dicha información es de gran utilidad para el ámbito científico, pero es habitual que no llegue a traspasar al ámbito de gestión y planificación territorial. En 2013 se creó la web SEVERICAT (<http://severicat.ctfc.cat/>), la cual tenía el objetivo de ofrecer cartografía de severidad de libre acceso generada a partir de metodología estándar y acercar así los productos generados hasta el momento desde el ámbito científico a usuarios finales de esta cartografía. SEVERICAT tenía como referencia el MTBS (*Monitoring Trends in Burn Severity*, www.mtbs.gov), llevado a cabo en EUA por el *USDA Forest Service* y el *USGS*, en el cual se ha cartografiado un gran número de incendios históricos de EUA y calculado la severidad a partir de imágenes Landsat a través de los índices dNBR y RdNBR. En 2015 el Servicio de Prevención de Incendios Forestales de la Generalitat de Catalunya se interesó por los productos de SEVERICAT y se inició un proyecto de transferencia cuyo objetivo era generar productos útiles para la gestión habitual post-incendio. Este acercamiento entre una aproximación académica y la Administración ha puesto de relieve la necesidad de “traducir” y adaptar conceptualmente los productos generados de severidad a nuevos

productos más comprensibles y fácilmente integrables en el día a día de las tareas de los gestores.

Una de las necesidades básicas detectadas durante dicho proyecto fue la clasificación de los mapas continuos de severidad en mapas categóricos que clasifiquen la severidad en baja, moderada y alta, más allá de un índice cuantitativo difícil de interpretar. Las metodologías existentes para llevar a cabo esta clasificación se basan en la aplicación de puntos de corte o umbrales sobre la cartografía continua de dNBR o RdNBR, apoyándose en las relaciones encontradas entre estos valores e información de campo recogida para tal finalidad (Miller y Thode 2007; Parks *et al.*, 2014). Actualmente no se dispone de esta información para los incendios históricos de Cataluña, por lo tanto es necesario recurrir a métodos validados en otros ámbitos geográficos. En el contexto del proyecto de transferencia se ensayaron diferentes metodologías: la determinación de umbrales a través de métodos estadísticos de los incendios históricos analizados, considerando los cuartiles de cada incendio o los cuartiles de todos los incendios; también, se aplicaron los umbrales publicados por Miller and Thode (2007) calibrados en incendios de EUA con la ayuda del índice *Composite Burn Index* (CBI), descrito por Key and Benson (2006), calculado a partir de información recogida en el campo justo después de un incendio. Los resultados fueron pocos satisfactorios según el conocimiento experto de los gestores del territorio. Por un lado, los umbrales definidos por técnicas meramente estadísticas son difíciles de extrapolar a otros contextos y carecen de validación de campo para su interpretación. Por otro lado, los umbrales definidos por Miller and Thode (2007) para los incendios de EUA, en el contexto Mediterráneo sobreestiman las zonas con severidad alta. Por lo tanto, en el contexto del proyecto de transferencia, surgió la necesidad de obtener un método de clasificación de la severidad mejor adaptado y validado al contexto Catalán-Mediterráneo.

En Cataluña no se recoge habitualmente información de campo después de un incendio que permita calcular el CBI, ni hay previsión de realizarlo de manera sistemática en un futuro. Por lo tanto, ha sido necesario recurrir a otras metodologías que permitan realizar el procedimiento de manera

sencilla, económica, repetible y adaptable a las necesidades de los gestores del territorio.

El reciente auge de los UAV (*Unmanned Aerial Vehicle*) ha hecho crecer el abanico de escalas y aplicaciones de estos vehículos en la teledetección ambiental. Los UAV presentan ventajas respecto a las imágenes de satélite (resolución espacial típicamente inferior a 2,5 cm y resolución temporal a medida del usuario), pero también algunas desventajas como la baja resolución espectral, la dificultad radiométrica asociada al momento de captura de las imágenes o una cobertura espacial limitada por la autonomía de vuelo. No obstante, son muchos los ámbitos relacionados con la gestión del medio natural donde se han usado los UAV: desde el seguimiento de biodiversidad (Sardà-Palomera *et al.*, 2012), al monitoreo del estado forestal de una zona (Dunford *et al.*, 2009; Puliti *et al.*, 2015). Las principales potencialidades de estas plataformas han apuntado a un uso económico en relación al espacio muestreado en estudios donde las campañas de campo pueden ser muy costosas. Es por lo tanto un reto actual afrontar la capacidad de utilización de los UAV como herramienta de validación de campo en estudios a gran escala.

El presente trabajo presenta una aproximación a la potencialidad de uso de los UAV como información equivalente a la verdad-terreno para la clasificación de severidad calculada a partir imágenes Landsat en el ámbito de Cataluña.

2. Área de Estudio

El presente trabajo se basa en el incendio de Ódena (1273 ha), en el centro de Catalunya (Figura 1), el día 26 de julio del 2015. En la zona media de la cuenca del Llobregat. La vegetación previa al incendio estaba formada mayoritariamente por *Pinus halepensis* Mill y matorral. Según la 4ª edición del Mapa de Cubiertas del Suelo de Cataluña (MCSC), correspondiente al año 2009, editado por el CREAM (<http://www.cream.uab.es/mcsc/esp/index.htm>), la mayor parte de la superficie del *P. halepensis* en 2009 era de regenerado de un incendio ocurrido en 1986. El resto de zonas arboladas de *P. halepensis* tenía un recubrimiento superior al 20%. El resto de cubiertas eran minoritarias y correspondían principalmente a cultivos y, en menor superficie, encinares u otros bosques.

La altitud sobre el nivel del mar de la zona del incendio está entre 300 m y 600 m. El terreno es bastante heterogéneo con un predominio de las zonas llanas y una pendiente promedio del 20%, con presencia de todas las orientaciones.



Figura 1. Mapa de situación del incendio de Ódena en Cataluña, en color marrón. En color azul se muestran los ríos principales y en color blanco las cuencas hidrográficas principales de Cataluña.

3. Metodología

3.1. Imágenes UAV

En el presente trabajo se ha utilizado un cuadricóptero ligero (1160 g) comercial Phantom 2 vision+ (Banu *et al.*, 2016; Chen *et al.*, 2016; Aguirre-Gómez *et al.*, 2017; Yi *et al.*, 2017). Se ha utilizado la cámara incorporada (Phantom vision FC200) en la plataforma: cámara RGB de alta definición (14 MP) con un sensor 1/2,3", una lente con una distancia focal de 5 mm y tres campos de visión (FOV) posibles: de 85°, 110° y 120°.

Se realizaron tres vuelos dentro del perímetro del incendio (Figura 2) en zonas de fácil acceso durante los meses de agosto y septiembre de 2015. Los vuelos se realizaron entre las 12:00 y las 14:00 horas, en condiciones atmosféricas óptimas en términos de iluminación y viento en los tres vuelos. La altitud promedio de los tres vuelos fue de 167 m sobre el suelo, proporcionando una distancia entre centros de pixel consecutivos (más conocido como GSD, *Ground Sample Distance*) entre 1,5 cm y 2,5 cm. Las tres áreas de vuelo fueron de aproximadamente unas 24 ha cada una

y en cada vuelo se capturaron un promedio de 68 imágenes.




Figura 2. Situación de los tres ortomosaicos de las fotografías UAV dentro del perímetro del incendio (en marrón). En azul se muestran los ríos.

Se utilizó el software comercial Agisoft PhotoScan Professional 1.2.6 (<http://www.agisoft.com/>) para pre-procesar las imágenes RGB. Agisoft incorpora algoritmos basados en los trabajos de Puliti *et al.*, (2015) y Näsri *et al.*, (2015) que permiten ordenar las imágenes en el espacio a partir de las localizaciones del UAV en la captura de cada imagen con el GPS de a bordo. También orienta las imágenes y busca puntos geométrica y radiométricamente similares entre ellas para enlazar las imágenes vecinas. En consecuencia, la geolocalización a través del GPS, la nube de puntos de solape y la información de alturas de cada imagen permiten obtener un ortomosaico final de la zona volada. En el proceso se descartaron algunas imágenes por falta de puntos de enlace. Posteriormente, también con Agisoft PhotoScan, se georeferenciaron los mosaicos con un total de 6 puntos de control, obteniendo un RMSE (*Root-Mean-Square-Error*) en X e Y de 0,8 m y de 1,4 m en Z. La resolución sobre el terreno (GSD) del mosaico final es de 4,93 cm, aunque buscando un compromiso entre manejabilidad y calidad visual se ha remuestreado a 10 cm. Cabe destacar que el ortomosaico final presenta deformación en los bordes, por lo cual se utilizará la zona central.

3.2. Imágenes de satélite

Se han utilizado dos imágenes del satélite Landsat 8 de fechas lo más cercanas posible a la fecha del incendio y libres de nubes, que corresponden a las fechas 18/07/2015 y 03/08/2015, descargadas del servidor GLOVIS (USGS; <http://glovis.usgs.gov/>)

con un nivel de procesamiento 1T, rectificadas geoméricamente. A continuación se han corregido radiométricamente siguiendo la metodología desarrollada por Pons y Solé-Sugrañes (1994), con el objetivo de reducir el ruido debido a efectos de la atmósfera, iluminación diferencial provocada por la hora del día, el lugar de la Tierra y el relieve y, asimismo, poder comparar las imágenes captadas en fechas distintas. Se ha escogido un modelo de atmósfera homogénea y se ha utilizado un modelo digital de elevaciones de 30 m de resolución. Asimismo, se ha determinado un ángulo límite lambertiano de 73° a partir del cual no se aplica la corrección, ya que la reflectancia puede no estar difusa homogéneamente.

Se ha calculado el índice de severidad relativa RdNBR siguiendo la metodología descrita por Cansler y McKenzie (2012) y utilizada también por el MTBS y SEVERICAT, que incorpora información sobre el estado de la cubierta vegetal de zonas similares no quemadas cercanas al perímetro del incendio y denominadas como *offset*. Por lo tanto, dicho índice cuantifica el cambio en el verdor en relación al estado inicial y a las características de la cubierta vegetal en comparación con zonas similares no quemadas con la finalidad de tener en cuenta diferencias debidas a cambios fenológicos. Se ha creído oportuno utilizar directamente el índice RdNBR porque ofrece mejores resultados en incendios individuales que el dNBR u otros índices (Cansler y McKenzie, 2012; Parks *et al.*, 2014).

3.3. Análisis de la severidad de incendios en las imágenes UAV

En las tres imágenes UAV se han seleccionado las zonas de cubierta forestal según la versión 4 del MCSC y en estas zonas forestales se han situado 48 parcelas al azar (Figura 3). El tamaño de las parcelas ha sido de 30×30 m, corregistradas con los píxeles de las imágenes Landsat.

En cada una de las parcelas, mediante digitalización en pantalla, se han fotointerpretado hasta tres clases de severidad: baja, moderada o alta en función de tres grandes tipos de tonalidades cromáticas encontradas en la zona forestal del incendio. Se ha tenido en cuenta que los incendios provocan en la vegetación un mosaico de colores ampliamente identificables en el espectro del

visible y especialmente identificables desde un UAV (Figura 4).

Las zonas con vegetación verde muestran zonas sin quemar o poco quemadas, que se considerarían de severidad baja. Las zonas con vegetación de color marrón suelen mostrar zonas quemadas donde se ha mantenido la hoja quemada en el árbol, por lo tanto sin una afectación muy alta, que correspondería a una severidad moderada. Las zonas con tonalidades negras evidencian áreas quemadas en alta intensidad donde se ha eliminado toda la vegetación fina y se muestra vegetación gruesa ennegrecida. Las zonas gris claro suelen mostrar terreno desnudo con cenizas, seguramente de áreas de matorral y sotobosque totalmente quemado. Estas dos últimas zonas correspondían a zonas de severidad alta. La escala de digitalización sobre pantalla es de 1:500 y la unidad mínima de digitalización aproximadamente 5 m^2 , la cual corresponde a zonas de bosque homogéneas con los portes arbóreos de un mismo color: verde, marrón, negro/gris. Esto significa que en las zonas donde existen árboles aislados con un mismo nivel de afectación se ha considerado toda la zona del mismo color que se ve en los árboles, no se han digitalizado las copas de los árboles con una categoría y el suelo como otra. Se podría destacar algún caso en el cual, dentro de una zona con un color de los portes arbóreos homogéneo, se ha diferenciado y digitalizado la copa de un árbol de




Figura 3. Situación de las parcelas de muestreo (en azul) para una de las zonas sobrevoladas con la plataforma UAV.




Figura 4. Ejemplos de parcelas fotointerpretadas. En la izquierda vemos una parcela mayoritariamente de tonalidad negra y gris con dos polígonos diferenciados de tonalidad marrón. En la parcela de la derecha se muestran de abajo a arriba zonas de tonalidad verde, marrón y negro/gris.

otro color. Los tres colores fotointerpretados se han traducido a niveles de severidad tal y como se ha descrito anteriormente: el verde corresponde a severidad baja, el marrón a moderada y el negro y el gris a alta.

Con el objetivo de poder comparar la diversidad de información fotointerpretada de las imágenes de UAV en cada parcela con la información de RdNBR de un único píxel de Landsat ha sido necesario resumir la información. En el presente trabajo se ha propuesto un índice cuantitativo que resuma la severidad total de una parcela: *Aerial Severity Proportion Index* (ASPI), el cual tiene en cuenta información cualitativa del tipo de severidad fotointerpretada desde el UAV clasificada en baja, moderada y alta e información de la superficie ocupada por cada categoría dentro de la parcela:

$$ASPI = \sum_{n=1} (severidad_{(i)} \times \% \text{ recubrimiento}_{(i)}) / 100$$

donde la *severidad*_(i) es el tipo de severidad 1, 2 o 3 correspondiente a baja, moderada o alta, respectivamente. El *% de recubrimiento*_(i) es el porcentaje de recubrimiento de la categoría de severidad (i) respecto a la superficie total de la parcela. Para cada parcela se suma la proporción de cada tipo de severidad presente en una misma parcela y el total se divide entre 100 para ponderar el resultado entre 1 y 3.

A continuación el índice ASPI se ha clasificado en tres niveles de severidad (Tabla 1) a partir del

análisis estadístico de la severidad de las parcelas, teniendo en cuenta la categoría que ocupa mayor superficie en cada parcela y la interpretación ecológica de los datos. Se considera severidad baja cuando el ASPI toma valores entre 1 y 1,99, severidad moderada entre 1,99 y 2,75 y severidad alta entre 2,75 y 3. El número de parcelas con severidad baja es significativamente menor al número de parcelas de severidad moderada y alta. La selección de parcelas al azar y la disponibilidad de parcelas en las distintas clases de severidad han dificultado enormemente tener el mismo número de muestras de cada tipo de severidad.

3.4. Delimitación de umbrales de severidad sobre las imágenes Landsat y validación

Se han utilizado las clases de severidad definidas en la sección anterior para calibrar los umbrales de cambio de nivel de severidad aplicables al índice RdNBR obtenido de las imágenes Landsat. Se ha ajustado un modelo multinomial ordinal en el que la variable independiente son los valores de RdNBR de los píxeles Landsat y la variable a predecir son las clases de severidad según ASPI de estos mismos píxeles. Se escoge un modelo ordinal porque las clases de severidad son valores finitos y discretos que contienen información ordenada (de menos a más severidad). El modelo ajusta la probabilidad de pertenecer a cada una de las tres clases en función de los valores RdNBR

y, por lo tanto, se obtienen tres curvas de probabilidad. Estos modelos permiten ajustarse para un tamaño de muestra diferente para cada categoría, como pasa en el presente trabajo (Tabla 1).

Tabla 1. Definición de las clases de severidad del ASPI y número de parcelas utilizadas para la calibración del modelo.

Categoría de severidad	Rangos ASPI	Número de parcelas de calibración
Baja	1 - 1,99	5
Moderada	1,99 - 2,75	18
Alta	2,75 - 3	25

El resultado de la modelización proporciona el indicador de la parsimonia del modelo AIC (*Akaike Information Criteria*; Burnham y Anderson, 2002) para el mejor ajuste obtenido mediante optimización de la máxima verosimilitud. Para este tipo de modelización no existe un análogo al pseudo-R² (Long y Freese, 2005). Para obtener los umbrales de cambio se ha calculado el punto de intersección entre las curvas de probabilidad de cada categoría. Así, se mantiene máxima la probabilidad de pertenecer a cada grupo. Los cálculos se han hecho mediante el paquete ‘ordinal’ del software R.

Los modelos se han ajustado sólo en zonas dentro del perímetro del incendio. El perímetro del incendio utilizado procede de la cartografía generada por el Departamento de Medio Ambiente de la Generalitat de Catalunya y el Instituto Geológico y Cartográfico de Catalunya, a partir de detección de cambios en imágenes satélite, y se considera que las zonas dentro del perímetro han sido afectadas en mayor o menor grado por el incendio. En el presente incendio se ha observado que, en algunas zonas, no sobrevoladas con el UAV, los valores de RdNBR son realmente bajos y corresponden a zonas que prácticamente no han sufrido cambios y por este motivo no están bien representados por la categoría de “baja severidad” definida a partir de las imágenes UAV. Esto ha llevado a la necesidad de definir una nueva categoría denominada “sin cambios”. El umbral que delimita esta categoría se determina a partir de la observación cualitativa de la distribución de valores de RdNBR, pues no se han encontrado parcelas en las imágenes UAV lo suficientemente grandes dentro del perímetro del incendio para incorporar dicha categoría en el proceso de modelización.

Los umbrales resultantes del proceso de modelización se han utilizado para clasificar el mapa de RdNBR de Landsat y obtener así una cartografía categórica de severidad para todo el perímetro del incendio. Posteriormente se ha validado dicho mapa categórico seleccionando 31 píxeles de Landsat al azar dentro de las imágenes UAV, distintos a los utilizados para la calibración de los modelos. Se ha cartografiado la parcela correspondiente al contorno de cada píxel y el nivel de afectación de la vegetación, se ha calculado el índice ASPI para cada una de las parcelas asignando un valor de severidad a cada una siguiendo el mismo proceso que en las parcelas de calibración y, finalmente, se ha comparado el valor de severidad obtenido a partir del proceso de clasificación con el valor observado a través de las imágenes UAV. La Tabla 2 muestra el número de parcelas de validación pertenecientes a cada categoría de severidad según el índice ASPI. Del mismo modo que ocurre en la disposición de parcelas para la calibración del modelo, la selección de parcelas al azar y la disponibilidad de parcelas en las distintas clases de severidad dentro de las zonas sobrevoladas han dificultado tener el mismo número de muestras de cada tipo de severidad. Cabe destacar que para validar los píxeles clasificados como “sin cambios” se ha recurrido a parcelas de validación fuera del perímetro del incendio, pues las imágenes UAV no contenían zonas lo suficientemente homogéneas de la categoría “sin cambios”. Se ha generado una matriz de confusión y calculado el coeficiente Kappa para cuantificar el ajuste.

Tabla 2. Número de parcelas seleccionadas al azar para la validación en cada categoría de severidad.

Categoría de severidad	Número parcelas de validación
Sin cambios	3
Baja	4
Moderada	17
Alta	7

4. Resultados

El modelo que presenta mejor capacidad para clasificar los tres niveles de severidad a partir del índice RdNBR posee un valor de coeficiente del RdNBR significativo ($P < 0,001$). En la Tabla 3 se muestran los resultados del mejor ajuste del modelo ordinal. Previamente se ha requerido eliminar dos parcelas de severidad alta consideradas *outliers*. En los

modelos multinomiales ordinales, el coeficiente de la variable predictora informa de la posibilidad de cambiar de grupo (*odds ratio*) (Kleinbaum y Klein 2010). En este caso, la probabilidad de pasar a un nivel superior de severidad dado una unidad de aumento de la variable independiente RdNBR es de 1,04 veces, ($\exp(0,04093) = 1,04$). Los valores de los umbrales que diferencian los tres grupos y que maximizan las funciones de probabilidad son un RdNBR de 561 para el límite entre severidad baja y moderada, y un RdNBR de 776 para el límite entre severidad moderada y alta. La Figura 5 muestra las funciones de probabilidad de cada una de las tres clases en función de los valores de RdNBR y los valores originales clasificados en las tres clases. El 83% de las parcelas están correctamente clasificadas entre los respectivos umbrales.

Tabla 3. Resultados de ajuste del modelo ordinal.

Parámetro	Valor
Log(Likelihood)	-17,75
Desviación residual	35,5
Grados de libertad residuales	43
AIC	41,51
Coefficiente de la variable RdNBR y significación	0,04093 (P<0.001***)
Umbral Baja Moderada	561
Umbral Moderada Alta	776

Los resultados anteriores permiten clasificar el mapa continuo de RdNBR en tres niveles de severidad: baja, media y alta. Tal como se detalla en la sección de ‘Métodos’, se han considerado los valores de RdNBR por debajo de 370 como zonas sin cambio (Tabla 4).

Tabla 4. Umbrales resultantes del proceso de modelización para la clasificación del índice cuantitativo RdNBR en clases de severidad.

Severidad	RdNBR
Sin cambios	< 370
Baja	370 - 561
Moderada	561 - 776
Alta	>776

El mapa categórico de severidad del incendio de Ódena (Figura 6) muestra mayor proporción de severidad alta en la mitad oriental del incendio y zonas con mayor proporción de severidad moderada y baja –e incluso zonas de no cambio– en la mitad occidental. Las zonas que han sufrido una severidad más elevada corresponden a las zonas de bosque más uniforme, mientras que las zonas con severidad moderada, baja o sin cambio corresponden a zonas mosaico de cultivos y bosque u otras cubiertas.




Figura 5. Las líneas continuas muestran las funciones de probabilidad (eje izquierdo) ajustadas del modelo ordinal según el rango de valores de RdNBR. Los puntos muestran la clasificación original (eje derecho) de los píxeles según sus valores de RdNBR. Estas dos informaciones están coloreadas según las clases de severidad. Por último, las dos líneas discontinuas muestran los umbrales de cambio de categoría que maximizan las funciones de probabilidad para todos los grupos.




Figura 6. Mapa clasificado de severidad a partir de los umbrales definidos con las imágenes UAV.

La clasificación tiene una exactitud moderada con un $\kappa=0.5$ y una varianza de 0,014. De las 31 parcelas utilizadas en la validación ha habido un acierto global del 64,5% y el acierto es del 70,8% si lo ponderamos por la superficie de las áreas de verdad-terreno; son valores ligeramente mejores a los trabajos realizados por Miller y Thode (2007) con el índice CBI. Las zonas de severidad alta y sin cambios son las mejor clasificadas, seguidas de las zonas de severidad baja. Este resultado sugiere un modelo no balanceado, probablemente debido a la diferencia entre el número de parcelas de validación y calibración de cada categoría de severidad.

5. Discusión

En el presente trabajo se demuestra que con la ayuda de UAVs es posible definir unos umbrales de severidad para los datos procedentes de imágenes Landsat. Las imágenes de alta resolución de UAVs ofrecen información muy cercana a la tomada en campo, que puede ser usada para validar la información de plataformas satelitales. La demanda de información regular sobre la evolución de las cubiertas vegetales hace imprescindible el uso de imágenes de teledetección, las cuales proveen imágenes amplias, regulares y de fácil acceso, pero a la vez es importante validar estos datos para dotarlos de sentido en la gestión. Mediante el presente trabajo se demuestra así la idoneidad

de las plataformas UAV para calibrar y validar la información satelital sin recurrir al terreno.

El pre-procesamiento de las imágenes UAV con los algoritmos utilizados para la generación del ortomosaico (incorporados en el software Agisoft) facilita mucho el coste del procesado de las imágenes de alta resolución, ofreciendo un resultado óptimo para alcanzar los objetivos planteados. La posibilidad de fotointerpretar el fenómeno de la severidad mediante el espectro del visible a escalas intermedias ha confirmado la posibilidad de usar estas imágenes en los procesos de calibración y validación.

El índice ASPI –propuesto como análogo al índice CBI medido en campo– ha demostrado ser una metodología apropiada para cuantificar la severidad a partir de la fotointerpretación de las imágenes procedentes de UAVs. Las dos parcelas fotointerpretadas que se han excluido del modelo final indican que es necesario aportar mejoras en el proceso de fotointerpretación: se podría tener en cuenta más clases visuales de vegetación que las tres (vegetación verde, marrón y negra o gris) utilizadas en el presente trabajo, especialmente dentro de las zonas con severidad moderada y alta. La utilización de plataformas UAV con sensores de mayor riqueza espectral permitirían realizar procesos de clasificación más allá de la interpretación visual de las imágenes.

La metodología presentada se muestra también como una metodología adaptable a otros sensores remotos de resolución espacial distinta a la de Landsat, adaptando el tamaño de las parcelas. También se podría adaptar la misma metodología al uso de otra información espectral.

No obstante, cabe destacar algunos aspectos importantes en la interrelación entre los datos RdNBR y los datos ASPI. Los dos índices proporcionan información sobre la severidad pero en rangos espectrales distintos. El índice ASPI cuantifica la severidad a partir de la interpretación de la respuesta espectral en el visible y puede quedar algo limitada por la respuesta de la vegetación en estas bandas. El RdNBR se basa en las bandas del infrarrojo cercano y el infrarrojo medio, cuya respuesta tras un incendio capta mejor algunas de las características de la vegetación como cantidad de humedad, actividad fotosintética, presencia de cenizas, etc. (Escuin *et al.*, 2008). Esto puede llevar a un desajuste en la calibración de los dos tipos de información. Por este motivo sería interesante tomar en consideración el uso de sensores multispectrales e hiperespectrales a bordo de plataformas UAV. Muy probablemente la mayor riqueza espectral podría aportar mejoras en el cálculo del índice ASPI, permitiendo obtener una información más detallada sobre el nivel de afectación de la vegetación y más cercana a la información captada desde los sensores remotos multispectrales como Landsat u otros.

Por otro lado, el índice ASPI muestra la severidad únicamente usando imágenes después del incendio, mientras que el RdNBR tiene en cuenta el estado relativo antes del incendio. Aunque los trabajos que han relacionado el RdNBR con información de campo justo después del incendio han encontrado mejores ajustes con el RdNBR que sólo con imágenes post-incendio (Miller y Thode 2007), y es por este motivo que en el presente estudio se ha usado una metodología similar, esta diferencia podría dar lugar a algún resultado controvertido. Por ejemplo, parcelas con un índice ASPI de severidad alta pueden presentar valores de RdNBR altos y otras con el mismo valor de ASPI presentar valores de RdNBR más cercanos a la severidad moderada. Se ha observado que las parcelas afectadas por severidad alta según las imágenes UAV que muestran un menor número de árboles quemados en pie y permiten ver un suelo

desnudo de colores claros (tierra marrón o cenizas grises) tienen un valor de RdNBR inferior que las parcelas que contienen muchos árboles quemados en pie y un suelo desnudo con cenizas negras. Esto puede tener relación con una mayor fracción de cubierta antes del incendio de la zona quemada y la cantidad de sotobosque quemado, que produce mayor cantidad de cenizas negras, mientras que en las zonas también quemadas con un índice ASPI elevado pero con valores más bajos de RdNBR hubiera menos cantidad de biomasa disponible. Sería interesante incorporar en el cálculo del índice ASPI información relacionada con la cantidad de biomasa disponible antes del incendio.

El modelo de regresión ordinal ha permitido obtener unos umbrales de cambio de severidad para la zona del incendio de Ódena. Los valores no distan mucho de los propuestos por Miller y Thode (2007), hecho que valida cualitativamente los resultados obtenidos. No obstante, estas pequeñas diferencias son importantes para adaptarse a la idiosincrasia de la zona y obtener así clasificaciones más acordes con los objetivos de gestión planteados.

El modelo de relación presentado ha mostrado ajustes óptimos; no obstante, sería necesario aumentar la muestra de píxeles y de incendios para dotar de mayor robustez a la calibración. Sería necesario también que los vuelos UAV se distribuyeran de forma más homogénea dentro del perímetro del incendio con el objetivo de mejorar la representatividad de la muestra de parcelas y obtener un modelo más equilibrado o balanceado. Cabe destacar que la muestra de parcelas de cada tipo de severidad es distinto, teniendo más parcelas a mayor severidad. Es lógico que se haya dado esta situación debido a que, justo después del incendio y dentro del perímetro de la zona quemada, es más probable encontrar zonas con un nivel de afectación mayor que zonas con poca severidad; pero futuras investigaciones tendrían que compensar este efecto. Además, tal como se ha comentado, sería interesante automatizar los procesos de clasificación de imágenes UAV para disminuir la subjetividad en la determinación de la severidad a partir de fotointerpretación.

6. Conclusiones

En el presente trabajo se demuestra que con la ayuda de UAVs es posible definir unos umbrales de severidad para los datos procedentes de imágenes Landsat. A pesar de que se han detectado algunos pasos donde cabría mejorar el proceso de modelización, especialmente centrados en procurar una mayor representatividad de zonas sobrevoladas dentro del perímetro del incendio e incorporar información que permita definir un gradiente de severidad más amplio en la calibración, los resultados demuestran que el uso de plataformas UAV genera umbrales que están dentro del rango de valores esperados según trabajos parecidos. Por lo tanto, la metodología propuesta puede ser replicada en futuros incendios permitiendo obtener unos umbrales de clasificación propios de cada zona sin los costes asociados a un trabajo de campo más intenso. Así mismo, la metodología puede también adaptarse a sensores de resolución espacial y espectral distintos a los de los satélites Landsat.

7. Agradecimientos

A José Ángel Terés y Xavier Castro, del Servicio de Prevención de Incendios Forestales (SPIF) de la Generalitat de Catalunya, por su apoyo y transferencia de conocimiento experto a través del proyecto SEVERICAT.

Referencias

- Aguirre-Gómez, R., Salmerón-García, O., Gómez-Rodríguez, G., Peralta-Higuera, A. 2017. Use of unmanned aerial vehicles and remote sensors in urban lakes studies in Mexico. *International Journal of Remote Sensing*, 38(8-10). <https://doi.org/10.1080/01431161.2016.1264031>
- Banu, T.P., Borlea, G.F., Banu, C. 2016. The Use of Drones in Forestry. *Journal of Environmental Science and Engineering*, B5, 557-562. <https://doi.org/10.17265/2162-5263/2016.11.007>
- Burnham, K.P., Anderson, D.R. 2002. *Model Selection and Multimodel Inference: A Practical Information-Theoretical Approach*. New York: Springer-Verlag.
- Cansler, C.A., McKenzie, D. 2012. How Robust Are Burn Severity Indices When Applied in a New Region? Evaluation of Alternate Field-Based and Remote-Sensing Methods. *Remote Sensing*, 4(2), 456–83. <https://doi.org/10.3390/rs4020456>
- Chen, X., Vogelmann, J.E., Rollins, M., Ohlen, D., Key, C. H., Yang, L., Huang, C., Shi, H. 2011. Detecting post-fire burn severity and vegetation recovery using multitemporal remote sensing spectral indices and field-collected composite burn index data in a ponderosa pine forest. *International Journal of Remote Sensing*, 32(23). <https://doi.org/10.1080/01431161.2010.524678>
- Díaz-Delgado, R., Lloret, F. and Pons, X. 2003. Influence of Fire Severity on Plant Regeneration by Means of Remote Sensing Imagery. *International Journal of Remote Sensing*, 24(8), 1751–1763. <https://doi.org/10.1080/01431160210144732>
- Dunford, R., K. Michel, M. Gagnage, Piégay, H., Trémelo, M. L. 2009. Potential and Constraints of Unmanned Aerial Vehicle Technology for the Characterization of Mediterranean Riparian Forest. *International Journal of Remote Sensing*, 30(19), 4915–4935. <https://doi.org/10.1080/01431160903023025>
- Escuin, S., Navarro, R., Fernández, P. 2008. Fire Severity Assessment by Using NBR (Normalized Burn Ratio) and NDVI (Normalized Difference Vegetation Index) Derived from LANDSAT TM/ETM Images. *International Journal of Remote Sensing*, 29(4), 1053–1073. <https://doi.org/10.1080/01431160701281072>
- Lentile, L.B., Holden, Z.A., Smith, A.M.S., Falkowski, 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. *International Journal of Wildland Fire*, 15, 319–345. <https://doi.org/10.1071/WF05097>
- Long, J.S., Freese, J. 2005. *Regression Models for Categorical Dependent Variables Using Stata*. College Station, TX: Stata Press, Second Edition.
- 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 Sensing of Environment*, 109(1), 66–80. <https://doi.org/10.1016/j.rse.2006.12.006>
- Näsi, R., Honkavaara, E., Lyytikäinen-Saarenmaa, P., Blomqvist, M., Litkey, P., Hakala, T., Viljanen, N., Kantola, T., Tanhuanpää, T., Holopainen, M. 2015. Using UAV-based photogrammetry and hyperspectral imaging for mapping bark beetle damage at tree-level. *Remote Sensing*, 7(11), 15467–15493. <https://doi.org/10.3390/rs71115467>
- Palomo, I., Martín-López, B., Potschin, M. Haines-Young, R., Montes, C. 2013. National Parks, Buffer Zones and Surrounding Lands: Mapping Ecosystem Service Flows. *Ecosystem Services*, 4, 104–116. <https://doi.org/10.1016/j.ecoser.2012.09.001>

- Parks, S.A., Gregory K. D., Miller, C. 2014. A New Metric for Quantifying Burn Severity: The Relativized Burn Ratio. *Remote Sensing*, 6(3), 1827–1844. <https://doi.org/10.3390/rs6031827>
- Pons, X., Solé-Sugrañes, L. 1994. A Simple Radiometric Correction Model to Improve Automatic Mapping of Vegetation from Multispectral Satellite Data. *Remote Sensing of Environment*, 48(2), 191–204. [https://doi.org/10.1016/0034-4257\(94\)90141-4](https://doi.org/10.1016/0034-4257(94)90141-4)
- Puliti, S., Olerka, H., Gobakken, T., Næsset, E. 2015. Inventory of Small Forest Areas Using an Unmanned Aerial System. *Remote Sensing*, 7(8), 9632–9654. <https://doi.org/10.3390/rs70809632>
- Sardà-Palomera, F., Bota, G., Viñolo, C., Pallarés, O., Sazatornil, V., Brotons, L., Sardà, F. 2012. Fine-Scale Bird Monitoring from Light Unmanned Aircraft Systems. *Ibis*, 154(1), 177–183. <https://doi.org/10.1111/j.1474-919X.2011.01177.x>
- White, J. D., Ryan, K.C., Key, C. C., Running, S.W. 1996. Remote Sensing of Forest Fire Severity and Vegetation Recovery, *International Journal of Wildland Fire*, 6(3), 125–36. <https://doi.org/10.1071/WF9960125>
- Yi, S. 2017. FragMAP: a tool for long-term and cooperative monitoring and analysis of small-scale habitat fragmentation using an unmanned aerial vehicle. *International Journal of Remote Sensing*, 38, Iss. 8-10. <https://doi.org/10.1080/01431161.2016.1253898>