



Seguimiento semi-automático de la cobertura del suelo tras quema prescrita mediante clasificación de imagen basada en redes neuronales convolucionales

Alberto Mir Sabaté^{1,*} , Carmen Castañeda² , Borja Latorre² , Rafael Rodríguez-Ochoa³ , José Ramón Olarieta³

(1) Departamento de Agricultura, Ganadería y Medio Ambiente del Gobierno de Aragón, Servicio Provincial de Zaragoza, Paseo María Agustín 36, 50071, Zaragoza, España.

(2) Departamento de Suelo y Agua. Estación Experimental de Aula Dei. Carretera de Montañana, 1005, 50059, Zaragoza, España.

(3) Departament de Medi Ambient i Ciències del Sòl. Universitat de Lleida. Rovira Roure, 191, 25918, Lleida, España.

*Autor de correspondencia: Alberto Mir [a.mir.sabate@hotmail.com]

> Recibido el 29 de noviembre de 2021 - Aceptado el 24 de febrero de 2022

Como citar: Mir Sabaté, A., Castañeda del Álamo, C., Latorre, B., Rodríguez-Ochoa, R., Olarieta Alberdi, J.R. 2022. Seguimiento semi-automático de la cobertura del suelo tras quema prescrita mediante clasificación de imagen basada en redes neuronales convolucionales. *Ecosistemas* 31(1): 2323. <https://doi.org/10.7818/ECOS.2323>

Seguimiento semi-automático de la cobertura del suelo tras quema prescrita mediante clasificación de imagen basada en redes neuronales convolucionales

Resumen: Se ha llevado a cabo un estudio basado en el análisis digital de imágenes para el seguimiento de los efectos causados por una quema prescrita sobre la superficie del suelo susceptible de verse afectada por procesos erosivos. Se analizaron fotografías de la superficie del suelo tomadas verticalmente a una altura de 138 cm en 330 puntos de muestreo dispuestos en las diagonales de 15 subparcelas de 200 m² (tres de ellas testigos) en una superficie aproximada de 10 ha en una repoblación de *Pinus pinaster* Ait quemada bajo prescripción. Durante el proceso de análisis de imagen se ha identificado manualmente en la superficie del suelo las coberturas de acículas, piñas, madera, musgo, restos quemados, biomasa seca, biomasa verde, gravas, y horizonte orgánico y horizonte mineral del suelo. Los resultados muestran que la clasificación automática de imágenes mediante redes neuronales convolucionales describe de forma precisa la realidad de las superficies analizadas. Esto permite reducir la duración de la toma de datos en campo, así como la identificación de las coberturas del suelo y, en especial, la discriminación del suelo mineral desnudo susceptible a la erosión. Por ello, se considera que ampliar y estandarizar esta metodología puede proporcionar importantes beneficios en el seguimiento de la superficie del suelo para cuantificar su erosividad.

Palabras clave: erosión del suelo; gestión forestal; neural network analysis; Sistema Ibérico

Semi-automatic monitoring of soil cover after prescribed burning by image classification using convolutional neural networks

Abstract: We developed a monitoring procedure of the effects of prescribed fire on the soil surface vulnerable to erosion processes based on digital image analysis. We took vertical pictures of the soil surface from a height of 138 cm in 330 sampling points distributed in the diagonals of fifteen 200 m²- plots, including 3 control plots, within 10 ha of a prescribed burnt *Pinus pinaster* Ait plantation. During the analysis of the images we manually discriminated the surface cover of needles, cones, wood, moss, burnt material, dry and green biomass, rock fragments, and mineral and organic soil. The results showed that the automatic classification of images through convolutional neural networks provides a precise classification of the soil surface and reduces the time required for field data collection and for the identification of the different soil covers, particularly the discrimination of the exposed mineral soil susceptible to erosion. We therefore suggest that broadening and standardizing this methodology may provide significant benefits for monitoring soil surface conditions and erodibility.

Keywords: forest management; neural network analysis; Sistema Ibérico; soil erosion

Introducción

El fuego, como elemento natural, ha modelado los ecosistemas mediterráneos de forma recurrente, y aunque en multitud de ocasiones ha sido calificado como destructivo, desde el punto de vista ecológico, y a pesar de la desaprobación social, el fuego sólo es un factor de cambio en estos ecosistemas (Molina 1993; Pausas 2012). Sin embargo, los cambios que produce el fuego pueden producir la degradación del ecosistema si su frecuencia, intensidad, y severidad son excesivas.

La formación y evolución del suelo, como componente de estos ecosistemas, depende, entre otros factores, de la acumulación de materia orgánica (Gallardo et al. 1982; González-Vila et al. 2009), de manera que la estructura del suelo y la estabilidad de los agregados que lo constituyen se ven favorecidas por la abundancia de aquella. Muchos procesos de degradación del suelo están sujetos a modificaciones físico-químicas producidas en esta matriz orgánica (Olarieta et al. 2008; González-Vila et al. 2009; Mataix-Solera y Cerdá 2009; Aznar et al. 2013) que, si es consumida o modificada por el fuego, puede no ofrecer la protección suficiente frente a pro-

cesos de degradación. Los procesos erosivos producen pérdida de masa, materia orgánica, y nutrientes del suelo, y su magnitud dependerá del clima, condiciones topográficas, tipo de incendio, tipo de suelo, y cubierta del suelo que queda tras el incendio (Benito et al. 2009), pudiendo alcanzar valores desde $1 \text{ Mg ha}^{-1} \text{ año}^{-1}$ hasta $100 \text{ Mg ha}^{-1} \text{ año}^{-1}$ (Vega et al. 2005; Soto y Díaz-Fierros 1998; Díaz-Fierros 2006). En cambio, la presencia de piedras, acículas, ramas o partes del arbolado acumuladas sobre el suelo constituye un acolchado que protege el suelo de los procesos erosivos (Fernández et al. 2006, 2016; Fernández y Vega 2016a, 2016b; Vega 2016; Vega et al. 2013).

Las quemas prescritas pueden considerarse una herramienta útil para la gestión de los sistemas forestales (Espinosa et al. 2017; Pausas 2004, 2012). Aunque su uso en el siglo XXI no es totalmente aceptado por gestores de los recursos forestales y por gran parte de la sociedad, se ha comprobado que los efectos de un fuego prescrito de baja o moderada intensidad no tienen por qué ser perjudiciales para el suelo (Fontúrbel et al. 2017). Mostrar resultados que evidencien las ventajas del uso de quemas prescritas puede representar el punto de inflexión para que se materialice un cambio a favor de su aplicación en la gestión forestal.

Uno de los efectos más significativos del fuego es el incremento de superficie de suelo mineral desnudo. Este efecto tiene la ventaja de que es observable en campo. Sin embargo, el método tradicional para contabilizar *in situ* la superficie de suelo sujeto a posible erosión tras la quema prescrita consiste en una estimación de *visu*. Esta estimación requiere invertir dilatadas jornadas de campo y, en ocasiones, los resultados pueden albergar imprecisiones y errores en la toma de datos. Los efectos de quemas prescritas se han estudiado de forma clásica mediante imágenes de satélite (Malone et al. 2011; Efthimiou et al. 2020), generalmente con objetivos de cartografía territorial. Pérez-Cabello et al. (2012) utilizaron fotografía de alta resolución espacial para definir diferentes clases de cubierta del suelo tras un incendio forestal (vegetación, suelo mineral expuesto, piedras, cenizas, y carbón) y poder relacionar los cambios temporales en la frecuencia de estas clases con los procesos de erosión y regeneración vegetal. La clasificación de imagen basada en redes neuronales se ha aplicado a imágenes de satélite para clasificar coberturas del suelo también a escala territorial (Peltiak et al. 2019; Pérez-Rodríguez et al. 2020) y en especial para estudiar los efectos del fuego (Fernández-Manso et al. 2016). En este trabajo se propone un método de análisis digital de imagen basado en redes neuronales convolucionales profundas (CNN, Deep Convolutional Neural Networks) para identificar y cuantificar de forma semiautomática las coberturas de la superficie del suelo a escala

de parcela tras la aplicación de fuego prescrito. La estimación de la superficie de suelo desnudo a escala de detalle, como indicador del riesgo de erosión, mediante tratamiento digital de la imagen se propone como un método más rápido y concluyente, suponiendo, por tanto, una mejora respecto al método tradicional de estimación visual.

Metodología

Diseño experimental

El experimento se llevó a cabo en un Área de Baja Carga de Combustible (ABCC) de una densidad media de 600 pies ha^{-1} , confeccionada en el pinar de repoblación del Monte de Utilidad Pública nº 7, ubicada en la Sierra de La Virgen, cadena montañosa perteneciente al Sistema Ibérico Central, en la provincia de Zaragoza. La masa, de unos 75 años aproximadamente y en estado de fustal bajo, estaba compuesta predominantemente por pies de *Pinus pinaster* Ait. y *P. nigra* Arnol. acompañados por individuos aislados de *Quercus ilex* L. subsp. *ballota* y *Q. faginea* Lam. En el matorral predominaban *Cytisus scoparius* (L.) Link, *Cistus laurifolius* L., *Cistus albidus* L., y *Genista scorpius* (L.) DC.

Se delimitaron 3 parcelas de quema en el interior del ABCC con una superficie media de 3 ha cada una y con similares condiciones de pendiente, orientación y densidad del arbolado. Las quemas prescritas se realizaron bajo un patrón de quema a favor por fajas y pretendieron eliminar la vegetación del estrato arbustivo y herbáceo.

Se dispuso una red de 12 subparcelas y 3 testigos distribuidos aleatoriamente sobre las 3 parcelas de quema. Su dimensión, de $10 \text{ m} \times 20 \text{ m}$, albergó en las dos diagonales y cada 2 m de distancia los puntos donde se tomaron las fotografías, iniciando la prospección a 1 m del vértice de cada parcela. Las diagonales presentaron una longitud de 21-22 m según la pendiente del terreno, resultando en cada diagonal 11 puntos de toma de imágenes.

Las imágenes se tomaron bajo condiciones uniformes de luz, en día nublado o procurando la sombra, y en un mismo periodo anual (invierno) y franja horaria (entre las 9:00 y las 14:00 horas). Se sistematizó la toma de la imagen mediante el uso de trípode con altura fija de 138 cm y adquisición de fotografía cenital con cámara Olympus Tough TG-310, y los parámetros ISO (modo automático de 80 a 200), f3.5 y velocidad 1/60 segundos. La resolución de las fotografías fue de 14 megapíxeles (4288×3216 píxeles), y en el campo de visión se incluyó una referencia métrica de 50 cm para confrontar longitudes y superficies de los objetos presentes (Fig. 1).



Figura 1. Fotografías correspondientes a las subparcelas PA_SP3 (A) y PA_SP8 (B).

Figure 1. Photographs of the subplots PA_SP3 (A) y PA_SP8 (B).

Procesamiento de las imágenes

En primer lugar, el objetivo consistió en identificar y delimitar manualmente las coberturas del suelo. Dichas clases (**Tabla 1**) se plantearon por su función en el sistema suelo-forestal independientemente de su posible discriminación por análisis digital de imagen. Se etiquetaron manualmente 207 fotografías, obteniendo una base de datos de 1157 objetos distribuidos en 10 clases diferentes, con una media de 115 objetos por clase y 6 clases diferentes en cada fotografía.

En segundo lugar, se aplicó un análisis de color sobre cada una de las clases planteadas usando el modelo cromático CIELAB para estudiar las características cromáticas de cada clase y su posible discriminación y separabilidad (CIE 2004). El análisis de color consistió en elaborar gráficos de densidad de color y su ajuste a una distribución normal usando los canales de color a^* y b^* de los píxeles correspondientes a cada clase.

En tercer lugar, se aplicó un análisis textural de la imagen aprovechando las diferencias de textura/estructura que muestran los objetos de las diferentes clases a esta escala de detalle. Este análisis textural permitió complementar el análisis el color para discriminar objetos diferentes de color similar.

Siguiendo las pautas anteriores se clasificaron las imágenes mediante una clasificación supervisada que utilizó color, textura y

morfología. Se empleó para ello una red neuronal convolucional profunda con una arquitectura de red del tipo VGG-19 (Krizhevsky et al. 2012; Simonyan y Zisserman 2015). La red constó de 19 capas, siendo la primera una matriz de 32×32 números (**Fig. 2**), coincidiendo con el tamaño de las imágenes, y la última un vector de 10 números que correspondió con la predicción de las 10 clases definitivas.

A continuación, en el procesado digital se dividieron las fotografías en cuadros de 32×32 píxeles aplicando una estrategia de “divide y vencerás” (DYV) para obtener un mayor número de muestras. Se asoció a cada cuadro una etiqueta numérica para representar la clase a la que pertenecía. Las zonas mixtas o sin una clase asignada se descartaron, y se seleccionaron al azar, de forma definitiva, 1000 cuadros de cada una de las 10 clases.

La clasificación de las imágenes se desarrolló en dos etapas: la de entrenamiento o aprendizaje, que agrupó el 80% de los cuadros, y la de validación, con el 20% restante. Se escogió una función de pérdida de entropía cruzada para la optimización de los parámetros de la red, minimizando su valor durante la fase de entrenamiento. La optimización se desarrolló en una serie de etapas o iteraciones, escogiendo en cada una un subconjunto de los recortes de entrenamiento y validación. Se realizaron un total de 500 iteraciones, obteniendo un valor final de la función de pérdida de 0.15.

Tabla 1. Base de datos obtenida para las 10 clases o etiquetas consideradas.

Table 1. Data base for each of the 10 classes defined.

Nº de Clase	Etiqueta	Nº de objetos	Nº de imágenes	Área total (nº de píxeles)	Área media (nº de píxeles por objeto)
1	Acícula	255	61	4154823	16293
2	Madera	140	42	9109980	65071
3	Musgo	51	21	961258	18848
4	Piedra	46	14	3029194	65852
5	Piña natural	95	52	2572429	27078
6	Restos quemados	82	47	2227155	27160
7	Suelo mineral	112	44	921323	8226
8	Suelo orgánico	69	38	776964	11260
9	Vegetación seca	120	48	1320981	11008
10	Vegetación verde	187	72	1868583	9992

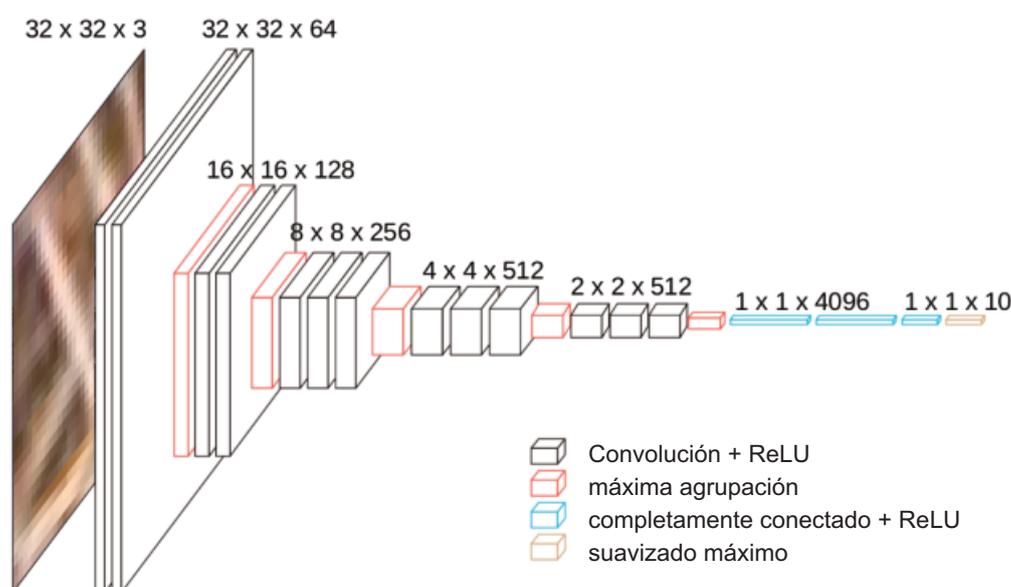


Figura 2. Arquitectura de la red empleada en la clasificación de las imágenes (modificado de Arachchilage e Izquierdo 2020) (reproducida con permiso de Springer Nature).

Figure 2. Network architecture used in the classification of the images (modified from Arachchilage and Izquierdo 2020) (reproduced with permission from Springer Nature).

Resultados y discusión

Clases objeto de estudio

La **Tabla 1** recoge las diez clases de coberturas de suelo definitivas empleadas en el análisis digital como etiquetas de la imagen, así como sus datos asociados a las imágenes empleadas. La definición de las clases y las fotografías empleadas se aportan en el Material Suplementario. Además, se tiene como resultado la base de datos generada con estas etiquetas, que puede ser útil para otros tratamientos de imagen y para otros ambientes a analizar.

Clasificar detenidamente los objetos en cada imagen, aunque supuso una inversión significativa de tiempo, proporcionó resultados que permitieron agrupar las clases consideradas en las imágenes. En principio se identificaron un mayor número de objetos (hasta 30) para evitar la pérdida de detalle en las diferentes imágenes. Sin embargo, se adecuó el análisis al objetivo del estudio, resultando en 10 clases definitivas.

Discriminación de objetos por color

En los gráficos de color o distribuciones de densidad (**Fig. 3**) se representaron las coordenadas de color CIELAB (a^* , b^*) de los píxeles clasificados dentro de cada una de las clases. Se observó la variabilidad de color de algunas de las clases y las similitudes y diferencias entre clases. Caracterizar detenidamente cada clase permitió analizar las diferencias y similitudes del suelo desnudo (clase “suelo mineral”), principal objeto de estudio, con las otras coberturas del suelo.

Así, las clases “suelo mineral” y “piedra” compartieron una distribución similar en el gráfico de densidad de color, pues ambas mostraron una relativa concentración de valores en el centro del gráfico, con la máxima densidad en torno al valor $a^*=0$ y $b^*=5$, es decir, hacia el amarillo, aunque el “suelo mineral” se extendió más hacia el azul, con valores negativos de b^* . La clase “piedras” convenía que quedara bien clasificada y separada de la clase “suelo mineral” por ser ésta la clase con mayor relevancia, evitando así no sobreestimar los resultados finales. El solapamiento de la clase “suelo mineral”, por su color, fue mucho menos intenso con otras clases como “acícula” o “suelo orgánico” y sólo presentó un solape parcial con clases que representan diferentes tipos de vegetación, proporcionando buena discriminación relativa con este conjunto de clases. Llama la atención que el solape del “suelo mineral” y la “vegetación seca” también fue muy parcial, siendo esta última clase

la que presentó mayor dispersión de valores positivos y negativos en ambos ejes.

Según la gráfica de color, la clase “acícula” se distribuyó desde la parte central del eje de abscisas hacia los valores positivos y en el eje de ordenadas desde el valor -5 hasta 30. Comparando la clase “acícula” con las clases “piedra” y “suelo mineral” se observó que la primera clase de las citadas presentó un mayor rango de valores en ambos ejes. La clase “piedra” presentó los puntos bastante concentrados en el centro de la gráfica y hacia la parte superior derecha con apenas dispersión y valores de a^* de 0 a 10 y de b^* de -5 a 20. La clase “suelo mineral” agrupó los puntos desde un valor más negativo del eje de ordenadas ($b^* = -10$) hasta la coordenada ($a^* = 10$; $b^* = 15$), resultando también una clase bastante homogénea, aunque con un subconjunto de puntos dispersos con tendencia hacia el rojo ($a^* > 5$, $b^* > 15$) por tratarse de suelos correspondientes a colores relativamente rojizos (matiz Munsell 7.5 YR).

A partir de estas distribuciones de densidad de color se desarrolló un modelo de representación de cada clase estudiada ajustando su distribución a una elipse que envolvía el 68% de los puntos y que podría usarse para clasificar los píxeles de nuevas imágenes (**Fig. 4**). El modelo permitió constatar claramente la confusión entre las clases mencionadas antes y las limitaciones del color como factor discriminante.

Desde el punto de vista del color, el “suelo mineral” quedó enmascarado con diferente grado de superposición por un número relativamente importante de clases. En la **Fig. 4** llama la atención la separabilidad entre la “vegetación verde” y la “vegetación seca”, situándose el “musgo” como una clase intermedia entre ambas. Se tuvo en cuenta que las clases “musgo” y “acícula” estuvieran bien representadas en cuanto a superficie (**Tabla 1**) puesto que en las parcelas estudiadas proporcionaron la mayor superficie de suelo cubierto. Por otro lado, se observó que la clase “restos quemados” pudo confundirse con la clase “suelo orgánico”.

Los resultados de la clasificación por color condujeron a replantear este tipo de catalogación debido a la confusión entre las clases de interés. Realmente, esta limitación del uso del color como factor discriminante de algunas coberturas del suelo ya se observó también durante el análisis visual en campo. En el caso de horizonte minerales superficiales con colores más amarillos que los muestreados aquí, el procedimiento necesitaría una recalibración, y la superposición de la clase “suelo mineral” se desplazaría hacia otras clases, como la de “vegetación seca”.

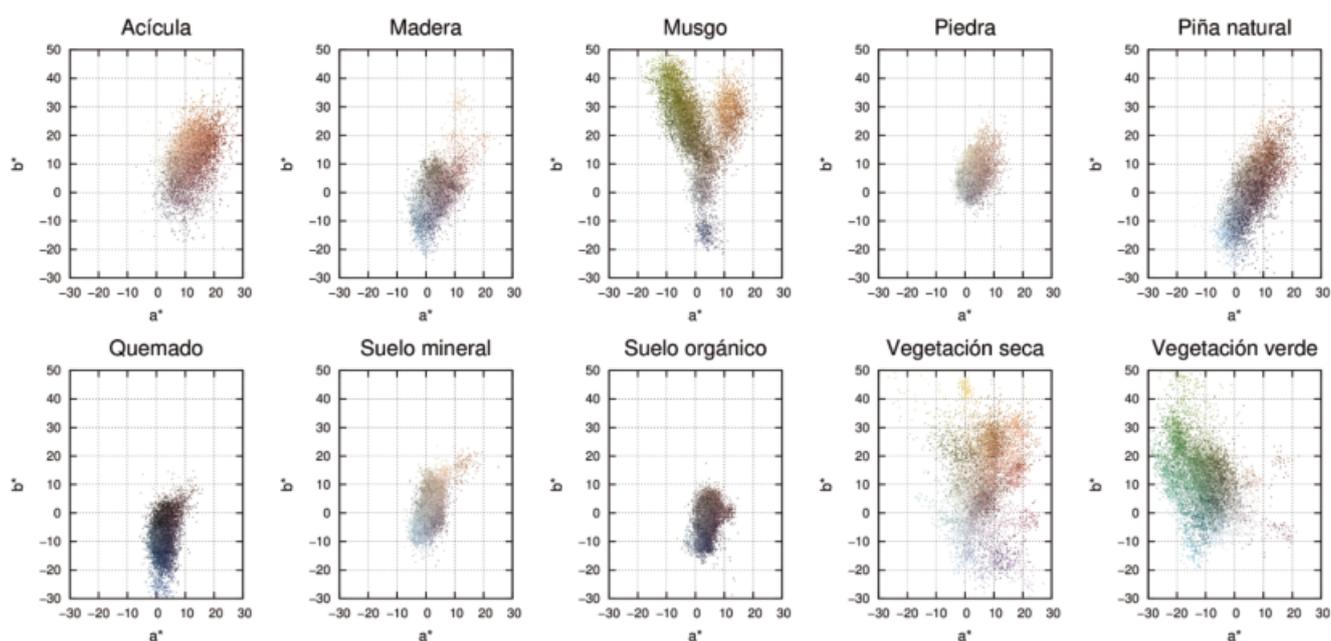


Figura 3. Gráficos de color o nubes de densidad de las 10 clases planteadas.

Figure 3. Color charts or density clouds of the 10 classes under study.

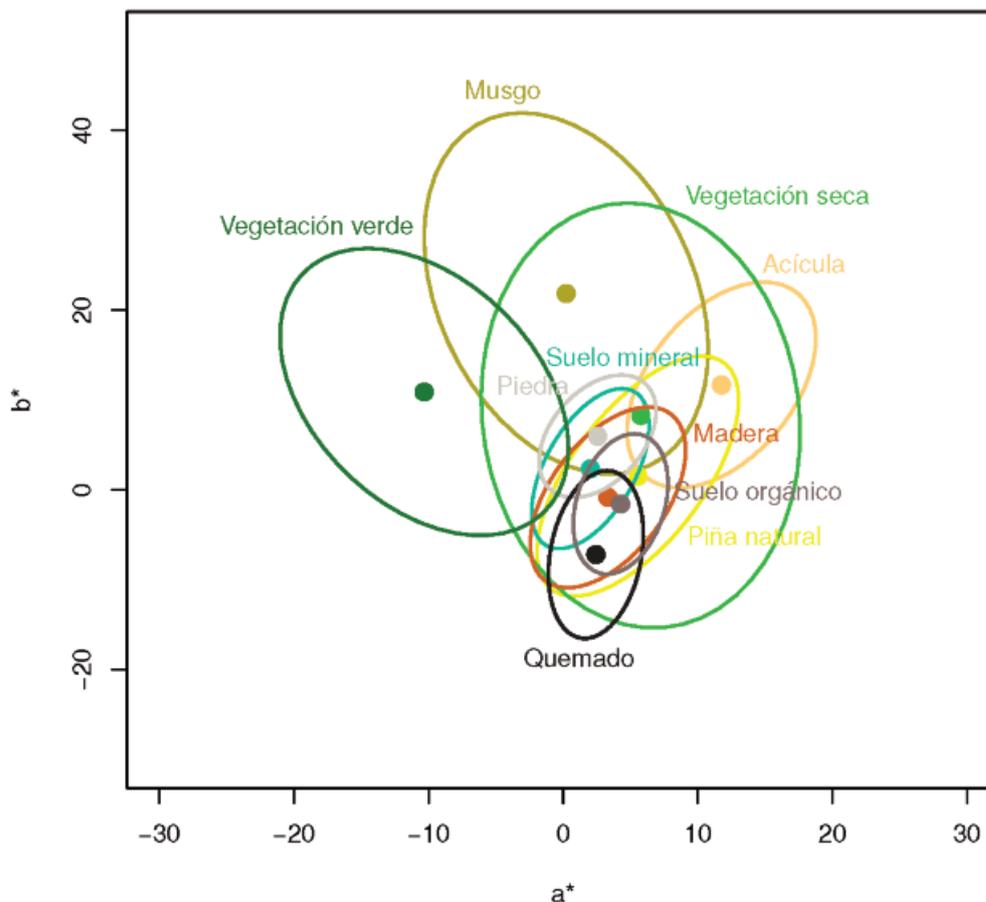


Figura 4. Ajuste mediante elipses de las distribuciones de color obtenidas para cada clase.

Figure 4. Elliptical fit of the color distributions obtained for each class.

Elementos texturales

Se creó una base de datos de elementos texturales que sirvió para identificar posteriormente todos aquellos elementos que componían las imágenes. Se usó la base de datos de la clasificación manual realizada para extraer una serie de recortes de las imágenes, de 32 x 32 píxeles de tamaño, seleccionando al azar 1000 recortes de cada clase. Los elementos texturales obtenidos se muestran en la Fig. 5. Como era de esperar, la textura de la clase “acícula” fue muy distintiva, al igual que la textura del “musgo”. Las clases “piedra” y “suelo mineral” mostraron una textura diferente visualmente a pesar de que presentaron similar color y tonalidad. Por el contrario, las clases “vegetación verde” y “vegetación seca”, aunque presentaron un color y tono diferenciado, según el pixel analizado generaron confusión debido a la semejanza de su textura. El examen textural de cada clase fue útil para descartar las confusiones detectadas en el análisis del color entre las clases “piedra” y “suelo mineral”, proporcionando más precisión para diferenciar el “suelo mineral” en cada una de las imágenes.

Clasificación automática de la imagen

En la clasificación neuronal de las imágenes se obtuvo una correcta clasificación del 95.4% de los cuadros o recortes de entrenamiento. Para estudiar el comportamiento de la red neuronal frente a imágenes desconocidas, se calculó una matriz de confusión (Fig. 6) con los 200 recortes de validación de cada clase. El resultado global de la matriz fue de un 80.5% de acierto en la clasificación de las imágenes analizadas. La matriz mostró un acierto significativo de la clasificación digital, obteniéndose coincidencias superiores al 90% para vegetación verde, acículas, y musgo, del 80-90% para material quemado, vegetación seca, y horizonte orgánico, del 70-80% para piedras, piñas, y suelo mineral, y del 60% para restos leñosos.

Las confusiones más importantes se observaron entre “piedras” y “suelo mineral”, y entre “piña natural” y “madera”, reiterando la dificultad de separar estas clases por su color (Fig. 3) y textura (Fig. 5). Sin embargo, la discriminación del “suelo mineral” presentó una importante mejora en esta clasificación neuronal al ser comparada con la baja separabilidad resultante del modelo de color (Fig. 3). Las clases que presentaron un mayor número de confusiones menores pero con un gran número de diferentes clases fueron la “vegetación seca” y la “madera”, aunque en baja proporción en casi todas ellas.

Aplicación

Los resultados obtenidos de la clasificación de imágenes con red neuronal se compararon con los resultados obtenidos de la delimitación manual de cuatro imágenes etiquetadas manualmente de forma íntegra. Para ello, en cada una de las imágenes se seleccionaron y etiquetaron todos los objetos presentes. Estas cuatro imágenes de prueba no se incluyeron en la base de datos que se utilizó para entrenar o validar la red neuronal. En la Fig. 7 pueden observarse los resultados obtenidos mediante la clasificación manual y usando la red neuronal, mostrando estos últimos gran similitud con la imagen inicial si se tiene en cuenta que la forma de los objetos analizados conllevó una deformidad debido a su representación en forma de pixel.

El desarrollo del método permite un ahorro significativo en el tiempo dedicado al trabajo de campo, ya que la descripción de la superficie del suelo mediante el método tradicional de *point quadrat* lleva entre 90 y 120 minutos por parcela, mientras que la obtención de las imágenes fotográficas ocupó 40-45 minutos. La fase de clasificación de imágenes podría simplificarse sin perder capacidad predictiva de la dinámica hídrica superficial agrupando clases como, por ejemplo, “piña” y “madera”, por un lado, y “vegetación verde”,



Figura 5. Elementos texturales empleados en el entrenamiento de la red neuronal.

Figure 5. Textural elements used in neural network training.

	Acícula	Madera	Musgo	Piedra	Piña natural	Quemado	Suelo mineral	Suelo orgánico	Vegetación seca	Vegetación verde
Vegetación verde	0	0	0	0	0	0	0	0	2	191
Vegetación seca	5	8	9	4	7	0	2	1	162	3
Suelo orgánico	0	13	1	0	2	7	3	111	4	0
Suelo mineral	0	15	4	17	1	0	145	1	2	1
Quemado	0	14	0	2	11	167	1	9	2	0
Piña natural	7	22	0	1	148	15	3	1	10	1
Piedra	0	8	3	159	3	0	21	1	4	1
Musgo	0	1	167	1	1	3	5	2	4	3
Madera	0	119	1	16	23	8	18	11	6	0
Acícula	188	0	0	0	4	0	2	1	4	0
Predicho	Observado									

Figura 6. Matriz de confusión entre las clases delimitadas de forma manual y las obtenidas con la red neuronal.

Figure 6. Confusion matrix between the manually delimited classes and those obtained with the neural network.



Figura 7. Cuatro ejemplos donde se muestra la comparación visual entre las clasificaciones obtenidas mediante selección manual (izquierda) y mediante red neuronal (derecha).

Figure 7. Examples of visual comparison between classifications obtained by manual selection (left) and convolutional neural networks (right).

“musgo”, y “vegetación seca”, por otro, que tienen una influencia similar sobre esos procesos. Sin embargo, el método puede presentar dificultades en zonas de fuerte pendiente, o en incendios de alta severidad por las perturbaciones producidas por el tránsito sobre la superficie de cenizas y restos quemados. El empleo de aparatos de vuelo no tripulado podría solventar estos inconvenientes si se consigue habilitar su movimiento a bajas alturas entre pies de arbolado y arbustos.

Conclusiones

La clasificación de imágenes basada en redes neuronales convolucionales se ha mostrado como un método eficaz y riguroso en el análisis de las cubiertas del suelo, con un alto porcentaje de acierto en la clasificación de estas, minimizando además el tiempo de prospección en campo. La diferenciación de tipos de cubierta por textura resulta una de las claves para obtener una alta validez de las clases definidas. Por todo ello, se propone continuar desarrollando el método, cuantificando también los diferentes tipos de cubierta para el análisis del riesgo de erosión de suelos.

Contribución de los autores

Alberto Mir Sabaté: Conceptualización, Metodología, Investigación, Redacción-borrador original, Redacción-revisión y edición; Carmen Castañeda: Análisis formal, Software; Borja Latorre: Análisis formal, Software; Rafael Rodríguez-Ochoa: Conceptualización, Metodología, Investigación; José Ramón Olarieta: Investigación, Redacción-borrador original, Redacción-revisión y edición.

Agradecimientos

La dirección y autorización de las quemas se realizó por Carlos Baraza Ruiz, Jefe de la Sección de Incendios Forestales del Servicio Provincial de Zaragoza, y la ejecución se llevó a cabo por el personal de Dispositivo de Prevención y Extinción de Incendios Forestales del Gobierno de Aragón. Agradecemos los útiles comentarios realizados por los revisores, y a Springer Nature el permiso para utilizar la Figura 2, cuya versión original fue publicada por Arachchilage e Izquierdo (2020) en *EURASIP Journal on Image and Video Processing*.

Referencias

- Arachchilage, S.P.K., Izquierdo, E. 2020. Deep-learned faces: a survey. *EURASIP Journal on Image and Video Processing* 25 (2020).
- Aznar, J.M., Badía, D., González-Pérez, J.A., Martí, C., Conesa, M. 2013. Variaciones en profundidad de las propiedades de un suelo yesoso forestal bajo quema controlada. *Flamma* 4: 67-70.
- Benito, E., Soto, B., Varela, E., Rodríguez-Alleres, M., Rodríguez, J.A. 2009. Modificaciones inducidas por los incendios forestales en las propiedades físicas de los suelos del noroeste de España: implicaciones de la respuesta hidrológica y en la erosión hídrica. En: Cerdá, A. y Mataix-Solera, J. (eds.) *Efectos de los Incendios Forestales sobre los Suelos de España. El Estado de la Cuestión Visto por los Científicos Españoles*, pp.303-323. Cátedra de Divulgación de la Ciencia, Universitat de Valencia, Valencia, España.
- CIE 2004. *Colorimetry, 3rd edition*. CIE Technical Report 015-2004. International Commission on Illumination, Viena, Austria.
- Díaz-Fierros F. 2006. Efectos ecológicos dos incendios forestais. En: Díaz-Fierros, F., Baamonde, P. (eds), *Os Incendios Forestais en Galicia*, pp. 29-47. Consello da Cultura Galega, Santiago de Compostela, España.
- Efthimiou, N., Psomiadis, E., Panagos, P. 2020. Fire severity and soil erosion susceptibility mapping using multi-temporal Earth Observation data: The case of Mati fatal wildfire in Eastern Attica, Greece. *Catena* 187: 104320
- Espinosa, J., Madrigal, J., Jiménez, E., Moya, D., Almodovar, J., De las Heras, J., Lucas-Borja, M., et al. 2017. Evaluación de la severidad en suelo y la vegetación de tratamientos de quemas prescritas bajo arbolado en masas puras y masas mixtas (*Pinus nigra*, *Pinus pinaster*) de la provincia de Cuenca. *Actas del 7º Congreso Forestal Español*, 7CFE01-372.
- Fernández, C., Vega, J.A. 2016a. Efectos de la aplicación de mulch para el control de la erosión post-incendio sobre la recuperación de la vegetación en áreas de matorral. *Cuadernos de la Sociedad Española de Ciencias Forestales* 42: 103-110.
- Fernández, C., Vega, J.A. 2016b. Effects of mulching and post-fire salvage logging on soil erosion and vegetative regrowth in NW Spain. *Forest Ecology and Management* 375: 46-54.
- Fernández, C., Vega, J.A., Fontúrbel, T., Pérez-Gorostiaga, P., Jiménez, E., Pérez, J.R. 2006. Runoff and soil erosion after rainfall simulations in burned soils. *Forest Ecology and Management* 234, Supplement 1: 1-12.
- Fernández, C., Vega, J.A., Fontúrbel, T. 2016. Reducing post-fire soil erosion from the air: Performance of heli-mulching in a mountainous area on the coast of NW Spain. *Catena* 147: 489-495.
- Fernández-Manso, A., Fernández-Manso, O., Quintano, C. 2016. Sentinel-2A red-edge spectral indices suitability for discriminating burn severity. *International Journal of Applied Earth Observation and Geoinformation* 50: 170-175
- Fontúrbel Literas, M.T. Jiménez Carmona, E., Fernández Filgueira, C., Vega Hidalgo, J.A. 2017. Efectos inmediatos de quemas prescritas bajo arbolado en masas puras y mixtas (*Pinus nigra*, *Pinus pinaster*) de la provincia de Cuenca en propiedades del suelo. *Actas del 7º Congreso Forestal Español*, 7CFE01-441.
- Gallardo, J., González, M.I., Pérez, C. 1982. *La Materia Orgánica del Suelo: su Importancia en Suelos Naturales y Cultivados*. I.O.A.T.O. Centro de Edafología y Biología Aplicada. Diputación Provincial de Salamanca, Salamanca, España.
- González-Vila, F.J., Gonzalo, J., González-Pérez, A., Knicker, H., González-Vázquez, R., Hernández, Z., Piedra, A., et al. 2009. Transformaciones de la materia orgánica del suelo por incendios naturales y calentamientos controlados en condiciones de laboratorio. En: Cerdá, A., Mataix-Solera, J. (eds.), *Efectos de los Incendios Forestales sobre los Suelos de España. El Estado de la Cuestión Visto por los Científicos Españoles*, pp. 219-268. Cátedra de Divulgación de la Ciencia, Universitat de Valencia, Valencia, España.
- Krizhevsky, A., Sutskever, I., Hinton, G.E. 2012. ImageNet classification with deep convolutional neural networks. *Proceedings of the 25th International Conference on Neural Information Processing Systems* 1097-1105.
- Malone, S.L., Kobziar, L.N., Staudhammer, C.L., Abd-Elrahman, A. 2011. Modeling relationships among 217 fires using remote sensing of burn severity in Southern Pine Forests. *Remote Sensing* 3: 2005-2028.
- Mataix-Solera, J. Cerdà, A. 2009. Los efectos de los incendios forestales en los suelos, síntesis y conclusiones. Nuevos retos en la investigación y en la gestión. En: Cerdá, A., Mataix-Solera, J. (eds.) *Efectos de los Incendios Forestales sobre los Suelos de España. El Estado de la Cuestión Visto por los Científicos Españoles*, pp. 493-529. Cátedra de Divulgación de la Ciencia, Universitat de Valencia, Valencia, España.
- Molina, D.M. 1993. Efectos del fuego controlado en la velocidad de infiltración del agua en suelos forestales: Un caso de estudio en la costa norte de California. *Investigaciones Agrarias. Sistemas y Recursos Forestales* 2(2): 174-183.
- Olarieta, J.R., Lizano, J. Rodríguez, R. Alcarria, Z. 2008. Efectos de un incendio sobre diversas propiedades físico-químicas del suelo y procesos de erosión hídrica en el medio semiárido (La Granja d'Escarp, Lleida). *Cuadernos de la Sociedad Española de Ciencias Forestales* 25: 345-350.
- Pausas, J.G. 2004. La recurrencia de incendios en el monte mediterráneo. En: Vallejo, V.R., Alloza, J.A. (eds.), *Avances en el Estudio de la Gestión del Monte Mediterráneo*, pp. 47-64. Fundación CEAM, Valencia, España.
- Pausas, J.G. 2012. *Incendios Forestales, una Introducción a la Ecología del Fuego*. Los Libros de la Catarata y CSIC. Madrid, España.
- Pérez-Cabello, E., Cerdà, A., de la Riva, J., Echevarría, M.T., García-Martín, A., Ibarra, P., Lasanta, T., et al. 2012. Micro-scale post-fire surface cover changes monitored using high spatial resolution photography in a semi-arid environment: a useful tool in the study of post-fire soil erosion processes. *Journal of Arid Environments* 76: 88-96.
- Pérez-Rodríguez, L.A., Quintano, C., Marcos, E., Suarez-Seoane, S., Calvo, L., Fernández-Manso, A. 2020. Evaluation of prescribed fires from unmanned aerial vehicles (UAVs) imagery and machine learning algorithms. *Remote Sensing* 12: 1295

- Petliak, H., Cerovski-Darriau, C., Zaliva, V., Stock, V. 2019. Where's the rock: using convolutional neural networks to improve land cover classification. *Remote Sensing* 11, 2211.
- Simonyan, K., Zisserman, A. 2015. Very Deep Convolutional Networks for Large-Scale Image Recognition. Conference paper at *3rd International Conference on Learning Representations* Disponible en: <https://arxiv.org/pdf/1409.1556.pdf>.
- Soto, B., Díaz-Fierros, F. 1998. Runoff and soil erosion from areas of burnt scrub: comparison of experimental results with those predicted by the WEPP model. *Catena* 31: 257-270.
- Vega, J.A. 2016. Prioridades de restauración de áreas forestales quemadas. *Cuadernos de la Sociedad Española de Ciencias Forestales* 42: 155-180.
- Vega, J.A., Fernández, C., Fontúrbel, T. 2005. Throughfall, runoff and soil erosion after prescribed burning in gorse shrubland in Galicia (NW Spain). *Land Degradation and Development* 15: 1-15.
- Vega, J.A., Fernández, C., Fontúrbel, T. 2013. Comparación de la eficacia de la siembra y del mulching + siembra para reducir la erosión en un área quemada de Galicia. *Actas del 6º Congreso Forestal Español*, 6CFE01-284.