

Análisis de variables extraídas de nubes de puntos fotogramétricas derivadas de imágenes UAV para la clasificación de especies arbustivas

Juan P. Carbonell-Rivera, Jesús Torralba, Javier Estornell, Luis Á. Ruiz, Pablo Crespo-Peremarch

Grupo de Cartografía GeoAmbiental y Teledetección, Universitat Politècnica de València, Camí de Vera s/n, 46022, Valencia, España. juacarri@upv.es, jetorpe@upv.es, jaescre@cgf.upv.es, laruiz@cgf.upv.es, pabcrepe@cgf.upv.es

Resumen: Las nubes de puntos derivadas de imágenes de drones están permitiendo el desarrollo de nuevos procesos en la obtención de la cartografía forestal. Estas nubes de puntos permiten aumentar la precisión de la clasificación de especies vegetales, gracias a la información geométrica y espectral que aportan. En este trabajo se aborda el análisis de diferentes variables geométricas, espectrales y de vecindario extraídas de nubes de puntos fotogramétricas para clasificar especies arbustivas. La clasificación se realizó con cinco diferentes métodos, obteniendo para el mejor modelo, *Gradient Boosting* una puntuación media aplicando validación cruzada de $0,82 \pm 0,05$. Las variables se analizaron en función de la importancia de la permutación obtenida en los cinco métodos de clasificación. Los resultados obtenidos muestran que las variables de vecindario derivadas del índice NDVI (*Normalized Difference Vegetation Index*) y la componente altimétrica son determinantes en la clasificación de especies arbustivas. Por el contrario, variables como el número de vecinos, la suma de valores propios o la banda verde y su índice derivado NormG no aportan información relevante para la mejora de los modelos. El estudio de la importancia de las variables ha permitido conocer qué variables son las más indicadas para la clasificación de especies arbustivas en entornos mediterráneos, permitiendo descartar variables irrelevantes para la clasificación. Este análisis permite mejorar el rendimiento de los modelos de aprendizaje automático, optimizando el tiempo de procesamiento y reduciendo el almacenamiento requerido.

Palabras clave: RPAS / drones, *machine learning*, bosque mediterráneo.

Analysis of features extracted from photogrammetric point clouds from UAV-derived imagery for the classification of shrub species

Abstract: UAV-based digital aerial photogrammetry point clouds are enabling the development of new processes in forest mapping. These point clouds are allowing to increase the accuracy of plant species classification, thanks to the geometric and spectral information they provide. In this paper, we analyse different geometric, spectral and neighbourhood features extracted from photogrammetric point clouds to classify shrub species. The classification was performed with five different methods, obtaining for the best model, *Gradient Boosting*, a mean score of 0.82 ± 0.05 applying cross-validation. The features were analysed according to the permutation importance obtained in the five classification methods. The results obtained show that neighbourhood variables derived from the NDVI (*Normalized Difference Vegetation Index*) and the altimetric component are determinant in the classification of shrub species. In contrast, variables such as the number of neighbours, the sum of eigenvalues or the green band and its derived index NormG do not provide relevant information for the improvement of the models. The study of the importance of the variables has allowed us to know which features are the most suitable for the classification of shrub species in Mediterranean environments, allowing us to discard irrelevant features for classification. This analysis makes it possible to improve the performance of the machine learning models, optimising processing time and reducing the storage required.

Keywords: Unmanned Aerial Vehicle, machine learning, Mediterranean forest.

1. INTRODUCCIÓN

La gestión eficaz de los bosques y la evaluación de su estado requieren una cartografía precisa de las especies forestales. En los últimos años, los avances en el ámbito de la teledetección, en especial mediante drones, están permitiendo la obtención de datos con mejores resoluciones. Además, la aplicación de técnicas de procesado más avanzadas permite caracterizar el bosque de forma cada vez más precisa, obteniendo mapas de especies vegetales con mayor nivel de detalle. Las nubes de puntos fotogramétricas obtenidas a partir de imágenes adquiridas desde

drones han demostrado su potencial para discriminar entre especies arbóreas o arbustivas (Carbonell-Rivera et al., 2022). El estudio de la estructura espacial de este tipo de nubes de puntos y la información espectral que contienen mejora la separabilidad de las clases estudiadas, pero requiere de técnicas más eficaces de procesado de datos para hacer frente a la mayor complejidad y al aumento de la dimensionalidad. Del fenómeno Hughes (Hughes, 1968) se extrae que, al aumentar la dimensionalidad de los datos, el número de muestras de aprendizaje necesarias para entrenar un clasificador también debe aumentar. Por ello,

la reducción del número de variables es una parte esencial en la clasificación de especies. Las técnicas de reducción dimensional seleccionan las variables que contienen información no redundante, minimizando el error que conlleva su eliminación de la clasificación.

Este artículo tiene como principal objetivo el análisis de la importancia de diferentes tipos de variables (geométricas, espectrales y de vecindario) extraídas de nubes de puntos fotogramétricas derivadas de imágenes adquiridas desde drones, que puedan ser empleadas en un futuro para la clasificación de especies arbustivas mediterráneas.

2. MATERIAL Y MÉTODOS

2.1. Zona de estudio y toma de datos

La zona de estudio cubre un área de 2889 m² y está localizada en el Parque Natural de la Sierra Calderona, situado al este de la península ibérica, entre las provincias de Valencia y Castellón (Figura 1). La existencia de las especies actuales deriva de un incendio forestal que arrasó 70 ha del parque natural en 2014. La sucesión ecológica provocada por el incendio está representada por la presencia de especies arbustivas adaptadas a la intensa radiación solar, indiferentes al sustrato, y a suelos con un alto grado de pedregosidad y pobres en nutrientes. La densidad arbustiva es muy elevada, formando un estrato de vegetación horizontal prácticamente continuo, donde las diferentes especies se mezclan sin superar los 150 cm de altura y sin presencia de cobertura arbórea.

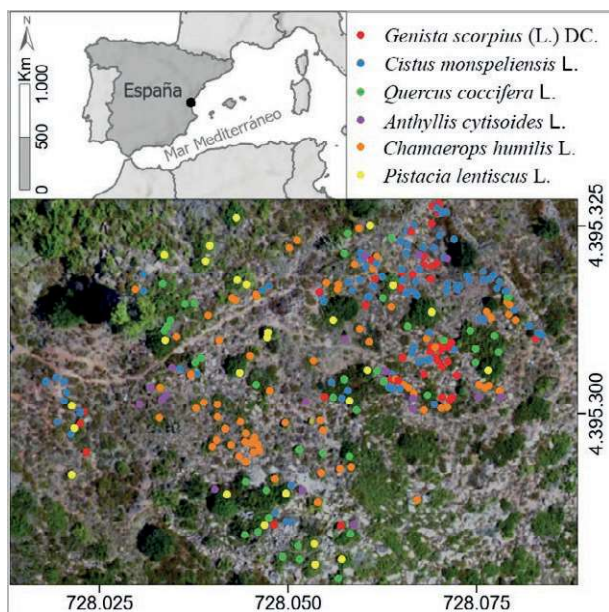


Figura 1. Ubicación de la zona de estudio (arriba) y de los individuos analizados para cada una de las especies arbustivas representativas de la zona (abajo).

El trabajo de campo se llevó a cabo el día 23 de julio de 2020, realizando una campaña de obtención de datos aéreos multispectrales y de datos GNSS (*Global Navigation Satellite System*). Los datos aéreos se tomaron mediante UAV (*Unmanned Aerial Vehicle*), realizando un vuelo cerca del mediodía solar para minimizar las sombras, bajo condiciones meteorológicas de sol y sin viento. El vuelo se realizó con un UAV *DJI Inspire 2* equipado con

una cámara multispectral *Micasense RedEdge*. Esta cámara está compuesta por cinco sensores (4,8 × 3,6 mm) de 1,2 MP de resolución con una distancia focal fija de 5,5 mm y un tamaño de píxel del sensor de 3,75 μm. Cada sensor recoge diferente información espectral en las bandas del azul, verde, rojo, borde rojo e infrarrojo cercano. El vuelo tuvo una duración de 6 minutos, tomando 1.150 imágenes en una extensión de 2,12 ha con una altitud media de vuelo de 49,2 m y un solapamiento longitudinal y transversal del 80%. Previa y posteriormente al vuelo, se tomaron imágenes a un panel de calibración de reflectancia conocida para realizar la calibración radiométrica.

Durante la campaña GNSS se registró la posición y especie de un total de 296 individuos, correspondientes a las especies arbustivas más representativas de la zona de estudio (Figura 1). Se tomó la proyección sobre el suelo del centro de cada individuo. De igual forma, se georreferenciaron los centros de 6 puntos de control del terreno (GCPs, por sus siglas en inglés). Para esta campaña se utilizó un equipo GNSS Leica GPS1200, aplicando RTK con la red ERVA.

2.2. Procesado de datos UAV

Todas las fases del procesado se llevaron a cabo con una estación de trabajo con las siguientes especificaciones: CPU Intel® i7-8700 CPU @ 3.20 GHz con 32 GB de memoria RAM y una tarjeta gráfica GeForce RTX 1060. Las imágenes se procesaron con la versión 1.5.3 de Agisoft Metashape. El flujo de trabajo comienza con la calibración radiométrica y alineamiento de las imágenes. Los GCPs registrados en campo se utilizaron para mejorar la orientación de las imágenes, así como para escalar el bloque fotogramétrico y dotarlo de coordenadas absolutas. Durante este proceso, se obtuvo una nube de puntos inicial que posteriormente fue densificada. A continuación, se recortó la nube de puntos al área de estudio. Por último, se normalizaron las alturas de la nube de puntos recortada, a partir de los puntos clasificados como terreno de la propia nube de puntos.

2.3. Extracción de variables

Tras el proceso de normalización de alturas, se eliminaron los puntos con una altura inferior a 10 cm, con el objetivo de eliminar los puntos correspondientes al terreno y a la vegetación herbácea. A continuación, se almacenaron la coordenada Z y los valores de reflectancia (bandas azul, verde, roja, borde rojo e infrarrojo cercano), y se calcularon 22 índices espectrales de cada punto: ARVI, BI, DVI, EVI, GNDVI, GR, IPVI, MSAVI, MSR, NDVI, NBRDI, NGBDI, NGRDI, NormG, OSAVI, RDVI, RGRI, RVI, SARVI, SAVI, SR y SRxNDVI (ver Carbonell-Rivera et al., 2022).

Adicionalmente, se realizó un análisis de vecindario de cada punto, determinando el vecindario de un punto como $p \in R^3$, siendo R^3 el conjunto de puntos dentro de una esfera s , de centro p y radio 10 cm, obteniéndose 18 variables (Tabla 1).

Al finalizar la extracción de características se dispuso de un total de 46 variables: una variable de tipo geométrica

(componente Z); 27 variables espectrales (divididas en 5 bandas y 22 índices) y 18 variables extraídas del análisis de vecindario (16 variables geométricas y 2 espectrales). Ocho de estas variables se extrajeron de los valores propios de la matriz de covarianza, creada a partir de las coordenadas de los puntos pertenecientes al vecindario (Hughes, 1968).

Tabla 1. Nombre, descripción y ecuación de las variables de vecindario, siendo S_p el conjunto de puntos de un vecindario.

Nombre (Descripción)	Ecuación
Dist_mean (Distancia media del punto con sus puntos vecinos)	$\frac{1}{n} \left(\sum_{i=1}^n d(S_{p,i}, p) \right)$
Dist_std (Desviación estándar del punto con sus puntos vecinos)	$\sqrt{\frac{(\sum_{i=1}^n (d(S_{p,i}, p) - \bar{d}(S_p, p))^2)}{n-1}}$
NDVI_mean (Media del NDVI del punto y de sus puntos vecinos)	$\frac{1}{n} \left(\sum_{i=1}^n NDVI(S_{p,i}) \right)$
NDVI_std (Desviación estándar NDVI del punto y sus puntos vecinos)	$\sqrt{\frac{\sum_{i=1}^n (NDVI(S_{p,i}) - \overline{NDVI(S_p)})^2}{n-1}}$
Numbers (Número de vecinos)	n
Z_mean (Altura media del punto y sus vecinos)	$\frac{1}{n} \left(\sum_{i=1}^n z(S_{p,i}) \right)$
Z_std (Desviación estándar de la altura del punto y sus vecinos)	$\sqrt{\frac{(\sum_{i=1}^n (z(S_{p,i}) - \bar{z}(S_p))^2)}{n-1}}$
Dif_Z (Altura máxima del vecindario menos altura mínima del vecindario)	$\max(z(S_p)) - \min(z(S_p))$
Z_Zmin (Altura del punto menos la altura mínima del vecindario)	$z(p) - \min(z(S_p))$
Zmax-Z (Altura máxima del vecindario menos la altura del punto)	$\max(z(S_p)) - z(p)$
Sum_λ (Suma de valores propios)	$\lambda_1 + \lambda_2 + \lambda_3$
Omnivariance (Omnivarianza)	$\sqrt[3]{\lambda_1 \cdot \lambda_2 \cdot \lambda_3}$
Eigenentropy (Entropía propia)	$-\sum_{i=1}^n \lambda_i \cdot \ln(\lambda_i)$
Anisotropy (Anisotropía)	$(\lambda_1 - \lambda_3) / \lambda_1$
Planarity (Planaridad)	$(\lambda_2 - \lambda_3) / \lambda_1$
Linearity (Linealidad)	$(\lambda_1 - \lambda_2) / \lambda_1$
Surface Variation (Variación de la superficie)	$\lambda_3 / (\lambda_1 + \lambda_2 + \lambda_3)$
Sphericity (Esfericidad)	λ_3 / λ_1

2.4. Evaluación de los modelos

Las muestras de aprendizaje para el entrenamiento de los modelos se obtuvieron a partir de la posición de los individuos registrada en campo. A estas muestras puntuales se les aplicó un *buffer* planimétrico de 15 cm, siendo este valor el radio mínimo de los individuos más pequeños identificados. El círculo resultante se utilizó para recorrer la nube de puntos. Tras obtener las muestras de cada clase, se realizó un proceso de filtrado manual para evitar

la introducción de valores atípicos en las muestras de entrenamiento. Para su clasificación se utilizaron diferentes métodos de clasificación de *machine learning*: *Decision Tree*, *Extra Trees*, *Gradient Boosting*, *Random Forest* (RF) y *MultiLayer Perceptron* (MLP). Para cada uno de estos métodos se ajustaron los hiperparámetros con el fin de optimizar los modelos, aplicando validación cruzada en 10 iteraciones para su evaluación.

La comparación de variables se basó en el valor de importancia de la permutación (Breiman, 2001) que obtuvo cada variable al utilizarse en los diferentes métodos de clasificación. La importancia de la permutación se define como la disminución de la puntuación de un modelo cuando un único valor de una variable se permuta aleatoriamente. Este procedimiento estudia la reducción de la puntuación del modelo para conocer la dependencia del modelo y la variable. De esta forma, una variable obtendrá una mayor puntuación si al permutar sus valores aumenta el error del modelo, por el contrario, obtendrá una menor puntuación si el modelo permanece sin cambios tras la permutación.

3. RESULTADOS Y DISCUSIÓN

La evaluación por validación cruzada de los diferentes modelos obtuvo una puntuación media en las 10 iteraciones de 0,75±0,04 para el método *Decision Tree*, 0,82±0,06 para *Extra Trees*, 0,74±0,07 para MLP, 0,82±0,05 para *Gradient Boosting* y 0,79±0,06 para RF. En este caso, el modelo con mayor media y menor desviación típica se obtuvo aplicando *Gradient Boosting*.

La Figura 2 muestra los valores de importancia de la permutación normalizada obtenidos para los diferentes métodos de clasificación. En el caso ideal, una variable que describiera perfectamente el fenómeno en los cinco métodos de clasificación obtendría un valor de 5 en el eje de abscisas. Este análisis es dependiente de la forma en la que trabaja cada método de clasificación. Así se puede observar que algunos métodos como *Decision Tree* obtienen un valor de importancia de la permutación mayor a

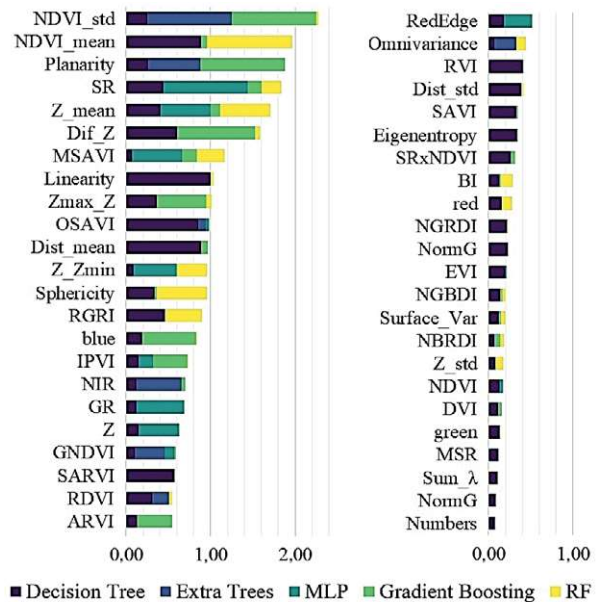


Figura 2. Importancia de la permutación normalizada en función del método de clasificación.

cero en todas las variables, mientras otros métodos como RF únicamente obtienen valores positivos en 27 de las 46 variables.

Las variables con mayor importancia fueron variables espectrales extraídas del análisis de vecindario (NDVI_std y NDVI_mean), siendo las más relevantes en la clasificación de las especies estudiadas. Entre las diez variables con mayor importancia, encontramos cinco variables geométricas extraídas del análisis de vecindario (planarity, Z_mean, Dif_Z, linearity y Zmax_Z). Variables como la planaridad y la linealidad se han utilizado comúnmente para la clasificación de nubes de puntos LiDAR (Hackel et al., 2016), permitiendo diferenciar las especies en función de su forma y porte. Tres de estas variables derivan de la componente Z (Z_mean, Dif_Z, Zmax_Z), indicando la notable relevancia que tiene la altura de la especie para su clasificación. De igual forma, entre las primeras diez variables encontramos tres índices espectrales: SR, MSAVI y OSAVI. Por el contrario, la variable con menor importancia fue el número de vecinos (*numbers*), seguida




Figura 3. Ortofoto en una planta de *Q. coccifera* (A), nube de puntos RGB (B) y variables “NDVI_std” (C), “NDVI_mean” (D), Planarity” (E), “SR” (F), “Z_mean” (G) y “Dif_Z” (H).

de variables como la suma de valores propios (Sum_λ), el índice espectral NormG o la banda verde, indicando la menor importancia que posee esta banda para distinguir las especies estudiadas. En este sentido, la Figura 3 muestra la representación de las seis variables con mayor importancia de la permutación normalizada obtenida para un ejemplar de *Quercus coccifera*. En ella se observa cómo cada variable incide en aspectos como la geometría (planarity, Z_mean y Dif_Z) o la respuesta espectral (NDVI_std, NDVI_mean y SR), permitiendo diferenciar el *Quercus* de los demás arbustos a su alrededor.

4. CONCLUSIÓN

En este trabajo se han analizado diferentes variables de tipo geométrico y espectral con el objetivo de encontrar aquellas más determinantes para clasificar especies arbustivas mediterráneas en nubes de puntos fotogramétricas. La importancia de la permutación es un estadístico que ha permitido ordenar las variables en función de su relevancia en la clasificación de especies arbustivas. De este análisis se extrae que las variables de vecindario extraídas de índices espectrales son fundamentales para la clasificación de especies arbustivas, encontrando además entre las diez variables con mayor importancia cinco variables geométricas extraídas del análisis de vecindario y tres índices espectrales. Por el contrario, se ha comprobado que variables como el número de vecinos, la suma de valores propios o la banda verde y su índice derivado NormG no aportan información relevante para la mejora de los modelos. Las especies arbustivas estudiadas en este trabajo son representativas de los entornos mediterráneos, haciendo que el estudio se pueda aplicar para clasificar especies arbustivas en entornos similares. El estudio de la importancia de las variables ha permitido conocer las variables que más información aportan a los modelos, descartando aquellas que menor información aportan a la distinción de especies.

5. AGRADECIMIENTOS

La financiación ha sido aportada por la ayuda BES-2017-081920 y el proyecto de I+D+i PID2020-117808RB-C21 financiados por MCIN/AEI/ 10.13039/501100011033 y por “FSE Invierte en tu futuro”.

6. BIBLIOGRAFÍA

- Breiman, L. 2001. Random forests. *Machine learning*, 45, 5-32.
- Carbonell-Rivera, J.P., Torralba, J., Estornell, J., Ruiz, L.Á., Crespo-Peremarch, P. 2022. Classification of Mediterranean Shrub Species from UAV Point Clouds. *Remote Sensing*, 14, 199.
- Hackel, T., Wegner, J.D., Schindler, K. 2016. Contour detection in unstructured 3D point clouds. En *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pp. 1610-1618.
- Hughes, G.F. 1968. On the Mean Accuracy of Statistical Pattern Recognizers. *IEEE Transactions on Information Theory*, 14, 55-63.