

Detección y localización de árboles en zonas forestales mediante datos LiDAR e imágenes aéreas

J.L. Gil-Yepes, L.A. Ruiz, A. Fernández-Sarría y T. Hermosilla

Grupo de Cartografía Geoambiental y Teledetección (CGAT). Universitat Politècnica de València. Campus de Vera. Camino de Vera s/n. 46022 Valencia (España). Correo electrónico: jogiye@upv.es

RESUMEN

La tecnología LiDAR se ha utilizado durante los últimos años para la caracterización de zonas forestales. En la elaboración de inventarios forestales ciertas variables se miden a nivel de árbol, por lo que es importante su detección y localización. La metodología de detección y localización presentada comprende procesos entre los que se encuentra el procesamiento de datos LiDAR, pre-procesado y filtrado de imágenes y clasificaciones. Los resultados obtenidos combinando estos tipos de datos y aplicando varios algoritmos superan el 81% de aciertos en tareas de detección y delimitación de árboles individuales.

Palabras clave: lidar, detección, localización, árboles, inventariado forestal.

ABSTRACT

LiDAR technology has been used in recent years for characterization of forest areas. In forest inventories, some variables are measured at tree level, so that the stage of detection and location of trees is important. The detection and location methodology presented includes processes such as LiDAR data processing, image pre-processing and filtering, and classifications. The results obtained combining both types of data and applying various algorithms show values greater than 81% of accuracy in detection and delimitation of individual trees.

Keywords: lidar, detection, location, trees, forest inventory.

INTRODUCCIÓN

Las zonas forestales son entornos naturales que presentan una gran diversidad biológica, riqueza medioambiental y potencial energético que se debe gestionar, mantener y cuidar, por lo que es necesario un conocimiento detallado de estas zonas. Tradicionalmente, los inventarios forestales se han llevado a cabo mediante procedimientos convencionales basados en campañas de campo con costes elevados. Durante los últimos años, las tecnologías de teledetección han permitido una captura masiva de datos multiespectrales y tridimensionales a través de sensores situados en satélites o dispositivos aerotransportados. Los dispositivos LiDAR, junto a los sensores multiespectrales, proporcionan datos para estimar las variables forestales básicas para la creación de inventarios.

Estas variables pueden obtenerse a nivel de parcela (variables dasométricas) o a nivel de árbol (variables dendrométricas). Al trabajar a nivel de árbol se tiene un mayor nivel de detalle, en ocasiones indispensable para realizar ciertas

tareas que requieren el conocimiento preciso del comportamiento de la unidad *árbol* en las masas forestales. En este trabajo se plantea el empleo de estas técnicas para la definición de una metodología que permita automatizar la detección y localización individual de los árboles en zonas forestales.

ZONA DE ESTUDIO Y DATOS EMPLEADOS

El área de estudio se corresponde con una zona montañosa situada en el término municipal de Cuenca con una superficie de 4.100 hectáreas. En ella se extienden grandes zonas forestales en las que predominan dos clases de pino: *Pinus sylvestris* y *Pinus pinaster*, con una altura media de 10 metros. Los datos disponibles de la zona provienen de un vuelo LiDAR con una densidad nominal de 4 puntos/m², e imágenes aéreas del PNOA (Plan Nacional de Ortofotografía Aérea) visible e infrarrojo, con una resolución espacial de 0,5 m/píxel. También se dispone de datos de campo con el inventario forestal de 56 parcelas

circulares de 50 metros de diámetro localizadas mediante GPS.

METODOLOGÍA

La metodología propuesta se divide en tres partes: (i) pre-procesado de los datos, (ii) detección y localización, empleando los métodos de *watershed* y “máximos locales” (iii) evaluación de los resultados mediante su comparación con datos de campo.

Pre-procesado de los datos

La detección de los árboles se realiza sobre los modelos digitales calculados a partir de la nube de puntos LiDAR. Para el filtrado de puntos y la generación de modelos se ha empleado el algoritmo propuesto por Estornell et al. (en prensa) que consiste en un proceso iterativo a través de ventanas de diferentes tamaños, seleccionando los puntos de menor altura para la generación del modelo digital del terreno (MDT). Una vez calculados el modelo de superficie y el modelo del terreno, se ha obtenido el modelo de alturas vegetación (MAV) con una resolución espacial de 0,5 m/píxel, coincidente con la de las imágenes restando el modelo del terreno al modelo de superficie.

El pre-procesado de las imágenes consiste en un mosaico y un posterior recorte para que la imagen coincida en dimensiones con la zona de estudio y con el MAV calculado.

Detección y localización

Para el proceso de detección y localización se parte de las imágenes aéreas y del MAV. Utilizando el algoritmo *watershed* se obtienen unos primeros resultados aproximados. Este algoritmo ha sido utilizado por otros autores (Popescu y Wayne, 2004; Tarabalka et al., 2010) para la segmentación de árboles, tanto en imágenes como a partir de datos LiDAR. El algoritmo *watershed* actúa sobre una imagen a modo de detección de sumideros como si de cuencas hidrográficas se tratase.

Inicialmente, se enmascaran las zonas forestales a partir del NDVI (Normalized Difference Vegetation Index) de la imagen, seleccionando aquellos píxeles cuyo valor supera un umbral determinado. Sólo a las zonas enmascaradas se les aplica un filtrado posterior de realce de contornos en el MAV. El filtro utilizado está basado en una ponderación de la media

según la similitud de los píxeles sobre un vecindario determinado (Chuvieco, 1996 y Recio, 2009). Una vez resaltadas las copas de los árboles sobre las zonas forestales, se realiza la inversión de los valores de intensidad de la imagen, facilitando así la detección de las cuencas con el método *watershed*. Tras esto se obtiene una imagen con los segmentos delimitados (Figura 1).

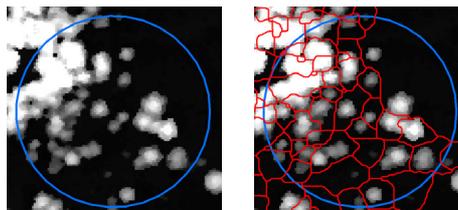


Figura 1: Detalle del MAV en una parcela (izquierda) y segmentos obtenidos mediante la aplicación de *watershed* (derecha).

Los segmentos calculados no corresponden sólo a árboles, por lo que antes de realizar el conteo se clasifican los segmentos. El proceso de asignación de clases consiste en una clasificación por píxel de máxima probabilidad seguida de una clasificación orientada a objeto. La clasificación por píxel se realiza utilizando las bandas G, R y NDVI de las imágenes y el MAV normalizado. En esta clasificación se han definido tres clases: árbol, suelo y matorral. Como paso previo a la clasificación y selección final de bandas, se realiza un estudio de separabilidad entre las diferentes clases.

Tras la clasificación por píxel se aplica un filtro de media. Posteriormente, se reclasifica cada segmento asignándole la moda de los valores de los píxeles que contiene. Para ello, se ha utilizado el software FETEX 2.0 (Ruiz et al., 2011). En esta clasificación se evalúan 30 parcelas de cada clase. Si bien los errores cometidos son elevados en las clases suelo y matorral, produciendo un valor bajo en la fiabilidad global de la clasificación, los errores correspondientes a la clase árbol son bajos, y siendo esta clase la que interesa mantener con valores altos de fiabilidad, la clasificación se considera adecuada. Estos errores se deben a segmentos de gran superficie, que a pesar de que en su interior esté situado un árbol, son clasificados como otra clase debido a la heterogeneidad de valores que presentan.

Tras la clasificación por objetos se realiza el conteo de los segmentos clasificados como árboles sobre las parcelas estudiadas en campo. Los resultados parciales obtenidos son una aproximación y se utilizan como punto de partida

para una nueva detección más rigurosa basada en el algoritmo de “máximos locales”, el cual detecta los picos máximos de altura dentro de un vecindario determinado.

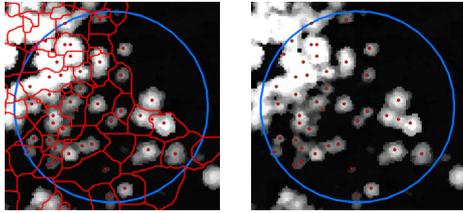


Figura 2: Detalle de detección de máximos locales de una parcela: Detección de máximos sobre segmentos (izquierda); detección final de máximos locales (puntos rojos) (derecha).

En esta segunda fase (Figura 2), cada segmento es analizado individualmente para el estudio de las diferentes clases que contiene. Aquel segmento en el que se detecte algún píxel correspondiente a la clase árbol, es seleccionado y procesado para detectar y localizar la copa del árbol por “máximos locales”. De esta forma, se analizan segmentos susceptibles de contener más de un árbol. Previo a la detección de los máximos, la imagen del MAV se filtra utilizando la media ponderada, como en el caso anterior.

Evaluación

La evaluación de los resultados está diferenciada en dos partes: la detección del número de árboles y su localización. La evaluación se realiza por parcela, comparando el número de árboles detectados con los observados en campo. La localización se evalúa midiendo la distancia entre los árboles detectados y los árboles observados, utilizando un umbral máximo de separación de 4 metros. Aquellos árboles que disten más de 4 metros de los árboles de referencia, se considera que han sido erróneamente detectados. Se ha generado una gráfica de dispersión que muestra los errores de localización en los ejes X e Y (Figura 3).

RESULTADOS Y DISCUSIÓN

En el cálculo de las aproximaciones se combinan los datos LiDAR y la información espectral para en un primer paso detectar los segmentos y en el segundo clasificarlos.

En la clasificación por píxel se obtiene una fiabilidad global del 97,7% con un coeficiente

Kappa del 0,97. Las fiabilidades del productor y del usuario también son elevadas, consiguiendo un 99,5% y un 96,8% respectivamente para la clase árbol.

Tras la clasificación por píxel se realiza la clasificación por objeto con una fiabilidad global del 63,3%. Los valores de fiabilidad de la clase árbol son de un 93,3 % para el productor y un 73,3% para el usuario. Como se ha comentado, estos errores se deben principalmente a aquellos segmentos que tienen una gran superficie y, a pesar de contener un árbol en su interior, han sido clasificados en otra clase diferente, produciendo una fiabilidad baja. Esto permite calcular unos resultados parciales en la detección.

Los resultados obtenidos en la primera aproximación de la detección son del 67% de aciertos por parcela. Se podrían haber conseguido mejores resultados si se hubieran tratado los datos estratificándolos en función de la densidad forestal de la parcelas, con el inconveniente de que se añadiría un paso más de procesado.

La detección por “máximos locales” mejora los resultados y corrige los errores cometidos en la clasificación por objeto, debido al estudio individual a nivel de segmento, valorando las clases contenidas en su interior. De esta forma, se consigue una detección más precisa con hasta un 81,7% de aciertos por parcela y un desplazamiento medio en la localización de 1,23 metros, con una desviación típica de 0,7 metros.

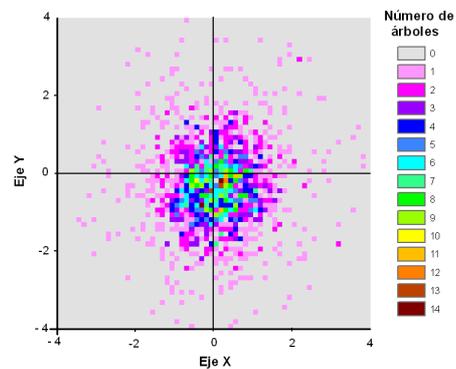


Figura 3: Gráfica de dispersión mostrando la precisión en la localización de un total de 1909 árboles contenidos en las 56 parcelas de estudio.

En la detección se dan casos en los que los errores por defecto son elevados. Estas parcelas de error se caracterizan por contener masas forestales de gran densidad. En estos casos y con la densidad de puntos empleada, tal y como

advierten Koch et al. (2006), los pulsos LiDAR no tienen suficiente capacidad de penetración, generando un error por omisión en la detección. A pesar de ello, la media de aciertos por parcela se mantiene elevada.

CONCLUSIONES

El algoritmo empleado para el procesamiento de los modelos digitales satisface las necesidades del trabajo, calculando los modelos correctamente a las resoluciones exigidas con los parámetros adecuados.

Ambas partes de la metodología de detección de árboles cumplen sus objetivos en cuanto a procedimiento y resultados. La primera aproximación se considera como un buen punto de partida, a pesar de los errores que se observan en la clasificación orientada a objeto. En la segunda fase se corrigen estos errores hasta conseguir resultados finales adecuados.

Los algoritmos *watershed* y de máximos locales facilitan la tarea de detección en las dos fases del proceso, generando una aproximación y posteriormente detectando los árboles con más precisión.

La combinación y uso de los dos tipos de datos (LiDAR e imágenes) favorece el desarrollo de la metodología. Los datos LiDAR proporcionan información tridimensional sobre la masa forestal, importante para conseguir una buena detección, mientras que las imágenes, con su información espectral, permiten mejorar la clasificación de los segmentos detectados.

BIBLIOGRAFÍA

CHUVIECO, E. 1996. *Fundamentos de teledetección espacial (3ª ed.)*. Madrid: Ediciones Rialp S.A.

ESTORNELL, J., RUIZ, L.A., VELÁZQUEZ-MARTÍ, B. y HERMOSILLA, T., (en prensa). *Analysis of the factors affecting LiDAR DTM accuracy in a steep shrub area*. International Journal of Digital Earth (DOI: 10.1080/17538947.2010.533201).

KOCH, B., HEYDER, U., WAINACKER, H. 2006. *Detection of individual tree crowns in airborne LiDAR data*. Photogrammetric Engineering & Remote Sensing, 72 (4), 357-363.

POPESCU, S.C. y WAYNNE, R.H., 2004.

Seeing the trees in the forest: using LiDAR and multispectral data fusion with local filtering and variable window size for estimating tree height. Photogrammetric Engineering & Remote Sensing, 70, 589-604.

RECIO, J.A. 2009. *Técnicas de extracción de características y clasificación de imágenes orientada a objetos aplicadas a la actualización de bases de datos de ocupación del suelo*. Universidad Politécnica de Valencia. Tesis Doctoral.

RUIZ, L.A., RECIO, J.A., FERNÁNDEZ-SARRÍA, A. y HERMOSILLA, T., 2011. *A feature extraction software tool for agricultural object-based image analysis*. Computers and Electronics in Agriculture 76 (2), 284-296.

TARABALKA, Y., CHANOSSOT, J. y BENEDIKTSSON, J.A., 2010. *Segmentation and classification of hyperspectral images using watershed transformation*. Pattern Recognition, 43, 2367-2379.

AGRADECIMIENTOS

Los autores agradecen el apoyo del Ministerio de Industria, Turismo y Comercio en el marco del proyecto TSI-020100-2009-815, *Desarrollo de técnicas y métodos para la gestión forestal sostenible a partir de datos de observación de la Tierra (INFOREST-II)*, así como a los socios y colaboradores del mismo.