



# Detección y localización de árboles en áreas forestales empleando datos LiDAR y ortofotografías

## *Tree detection and location on forestal areas using LiDAR data and orthophotographies*

José L. Gil-Yepes, Luis A. Ruiz, Alfonso Fernández-Sarria y Txomin Hermerosilla  
Grupo de Cartografía Geoambiental y Teledetección. Universitat Politècnica de València, España

### Resumen

Se propone una metodología para automatizar la detección y la localización de árboles en zonas forestales a partir de datos LiDAR y ortofotos. Para la automatización se han empleado diversos algoritmos para las diferentes fases como son el pre-procesado de datos LiDAR y la detección y la localización de los árboles con watershed y máximos locales. Los resultados obtenidos son satisfactorios, consiguiendo tasas de aciertos en la detección y localización que pueden ser útiles para ciertas aplicaciones prácticas en inventarios forestales.

**Palabras clave:** LiDAR, detección de árboles, inventarios forestales, watershed, máximos locales.

### Abstract

*An automatic tree detection and location methodology is proposed using LiDAR data and orthophotos. For the automation are applied various algorithms on the different stages as the pre-processing of the LiDAR data and tree detection and location with watershed and local maxima. The results obtained are satisfactory, getting high accuracy rates on detection and location which can be useful for certain applications in forest inventories.*

**Keywords:** LiDAR, tree detection, forest inventories, watershed, local maxima.

### Introducción

Durante los últimos años numerosos proyectos medioambientales han hecho de la gestión forestal

una necesidad actual captando la atención de las nuevas tecnologías LiDAR para la obtención de datos tridimensionales en masa, su análisis y aplicación en inventarios forestales (Hudack et al., 2009 y Yu et al., 2010). Las aplicaciones de los datos LiDAR e imágenes multiespectrales no solo resultan útiles en el inventariado de zonas forestales. Estos datos ofrecen un amplio abanico de posibilidades como puede ser la detección de edificios, aplicaciones hidrológicas, agrícolas o la creación de modelos de predicción de incendios. El LiDAR (Light Detection And Ranging) está basado en una combinación de tres sistemas de toma de datos diferentes: un láser escáner aerotransportado, un sistema GPS y un sistema inercial o INS (Baltasavias, 1999). Gracias a los datos proporcionados por el LiDAR se pueden calcular variables de estructuras forestales difíciles de obtener de forma directa mediante trabajos de campo. La estructura forestal puede caracterizarse mediante medidas relacionadas con la cobertura vegetal y la altura como variables más comunes, y otras como son las relaciones entre altura, copa y diámetro. Estas variables permiten obtener un mejor conocimiento y control de las zonas forestales. Es habitual encontrar casos en los que el conocimiento de estas características es insuficiente, por lo que hay que buscar otro tipo de variable u objeto, como son las unidades de árbol, sobre las que se pueda trabajar (Heinzel et al., 2008). Las características dendrométricas y dasométricas son fundamentales para el inventariado y catalogación de bosques, debido a que permiten conocer en profundidad la estructura interna, biomasa, biodiversidad, detección del crecimiento o cambios en los ecosistemas, entre otros. Algunos trabajos realizados utilizando métodos multiespectrales con procedimientos LiDAR muestran resultados prometedores para la segmentación de zonas fores-

tales, obteniendo valores elevados de precisión en la detección de árboles (Suárez et al., 2005).

La detección y localización de árboles se puede abordar desde diferentes puntos de vista y utilizando diferentes algoritmos y procedimientos. En la metodología propuesta se han utilizado los algoritmos "watershed" y "máximos locales", los más extendidos en la detección y segmentación de árboles (Hirata et al., 2009; Wulder et al., 2000; Pouliot et al., 2002; Leckie et al., 2005).

El presente trabajo pretende aportar una solución práctica a un problema real a partir de la combinación de imágenes multispectrales y datos LIDAR, siendo el objetivo principal el desarrollar una metodología que automatice la detección de los árboles sobre zonas forestales basándose en estos datos. Además, se han comparado varios algoritmos de interpolación de datos LIDAR y se han evaluado dos algoritmos de segmentación, detección y localización de árboles.

Con estos estudios y métodos desarrollados se pretende avanzar en el desarrollo de las técnicas de localización para la estimación de las características dendrométricas necesarias para cualquier inventariado o estudio de áreas forestales.

## Área de estudio y datos utilizados

El estudio se ha realizado en una zona de montaña de 4.000 ha con grandes extensiones forestales situada en la provincia de Cuenca (España). Se pueden encontrar áreas forestales de diferentes densidades, así como zonas de matorral y suelo desnudo. En las zonas arboladas se encuentran diversas especies de árboles en las que predominan tres especies básicas de pino: *Pinus sylvestris*, *Pinus pinaster* y *Pinus nigra*. La altura media es de 10 metros, pudiéndose encontrar casos de árboles que se sitúan sobre los 20 metros de altura.

Los datos LIDAR utilizados poseen una densidad nominal de 4 pto/m<sup>2</sup>. Las imágenes multispectrales utilizadas son ortoimágenes RGB e IR (PNOA) con una resolución de 0.5 metros de tamaño de píxel. Como datos de campo se catalogaron parcelas circulares de estudio de 50 metros de diámetro de las cuales se conoce el número de árboles y su localización obtenida a partir de GPS. Las ortoimágenes del PNOA fueron obtenidas a partir de la IDEE de Castilla la Mancha.

## Metodología de trabajo

La metodología de trabajo (Figura 1) se puede dividir en tres partes: (i) el preprocesado de los datos, (ii) el proceso de detección y localización de árboles y (iii) la evaluación del método.



Figura 1. Esquema de la metodología empleada

### Preprocesado de los datos

En el trabajo se han realizado tareas de preprocesado de las imágenes y también de los datos LIDAR. El preprocesado de las imágenes ha consistido en un mosaico de la zona de estudio y así obtener una única imagen. Los datos LIDAR se han procesado con dos algoritmos diferentes para realizar un estudio comparativo y calcular un modelo adecuado a las necesidades del trabajo.

El primer algoritmo utilizado está basado en una predicción lineal con una precisión individual para cada una de las medidas tomadas (Kraus y Pfeifer, 1998), implementado como un proceso iterativo de cálculo de superficies entre puntos de referencia en el terreno y el modelo de superficie media. El tamaño de la zona de estudio y el volumen de los datos a gestionar hizo necesario el cálculo del modelo digital por zonas, por lo que al finalizar la generación del mismo se realizó un mosaico de toda la zona de estudio (Figura 2).

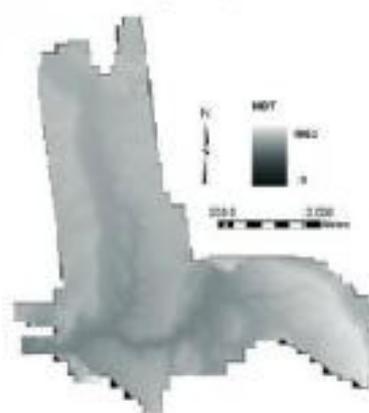


Figura 2. Mosaico de modelo digital del terreno (algoritmo Kraus y Pfeifer)

El segundo algoritmo para el modelo digital de superficie es el propuesto por Estomell et al. (2011) en el que se filtran en un primer paso los puntos que no pertenecen al suelo a partir de un proceso iterativo para la selección de puntos mínimos, donde se seleccionan los puntos de altura mínima dentro de una ventana inicial que va recorriendo toda la zona de estudio. A partir de estos puntos se calculan los modelos digitales del terreno y de superficies.

La comparación entre los modelos del terreno generados se ha realizado mediante estudios de diferencias y desplazamientos entre ambos. Se encontraron áreas con diferencias significativas debido principalmente a la falta de densidad de puntos LiDAR, ya que en dichas zonas discurrían vaguadas con presencia de agua. En ellas se han podido ver varios de los efectos que se producen con los dos algoritmos estudiados (Figura 3).

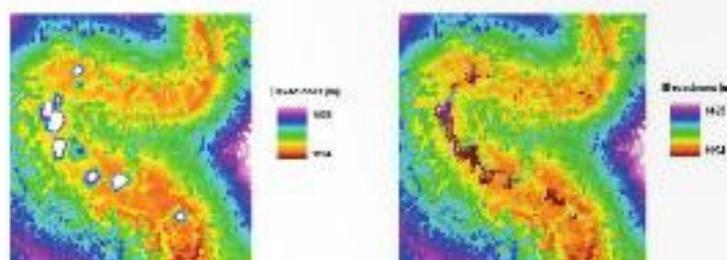


Figura 3. Detalle de modelo de superficies con errores por falta de densidades LiDAR con (a) algoritmo de filtrado iterativo y (b) algoritmo de Kraus y Pfeifer

El mapa de diferencias entre los modelos generados por los dos algoritmos se puede observar en la Figura 4, donde se muestran las zonas con mayor divergencia entre modelos. Estas zonas se corresponden con terrenos de altos desniveles o con vaguadas donde la densidad de puntos LiDAR es menor. Las diferencias están acotadas en un rango de valores entre los 5 y -5 metros, donde se encuentran el 99.8% de píxeles en toda la zona de estudio.

Otra forma de evaluar los algoritmos ha sido el estudio de las orientaciones, en el que se ha querido comprobar si alguno de los algoritmos utilizados introduce desplazamiento en los modelos durante el proceso de filtrado o en la interpolación al observarse valores anormalmente elevados en el mapa de diferencias. Para ello, se han realizado mapas de orientaciones de ambos modelos y se han relacionado con los mapas de

diferencias. Los resultados obtenidos muestran que ningún algoritmo introduce ningún despla-

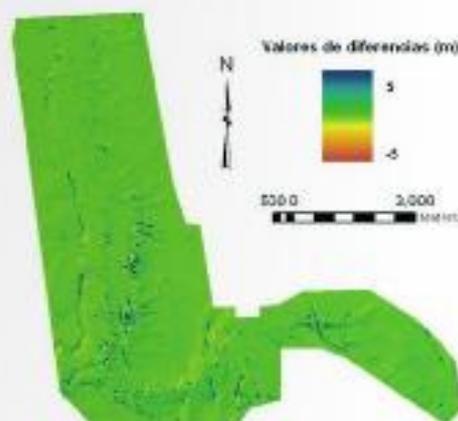


Figura 5. Mapa de diferencias entre modelos con intervalo de valores entre 5 y -5 metros

miento, confirmando así que los valores elevados de las diferencias se deben a las bajas densidades de datos LiDAR en las zonas antes mencionadas.

Una vez realizado el estudio entre modelos digitales se ha escogido el modelo procesado mediante el algoritmo de filtrado iterativo de selección de puntos mínimos, debido a que se adapta mejor a las zona de trabajo presentando menores discrepancias y mejores ajustes en zonas de grandes cambios de pendiente. Se ha generado un modelo de alturas de vegetación (MAV) de 0.5 metros de tamaño de píxel en el que, al realizar la diferencia entre el modelo digital de superficie y el modelo digital del terreno, se han obtenido los árboles normalizados a un mismo nivel de referencia (Figuras 5).

#### Detección y localización de árboles

Para la detección y la localización de árboles se ha combinado la información LiDAR con la información espectral. El procedimiento consiste en una primera aproximación en cuanto al conteo de árboles a partir de una segmentación basada en el

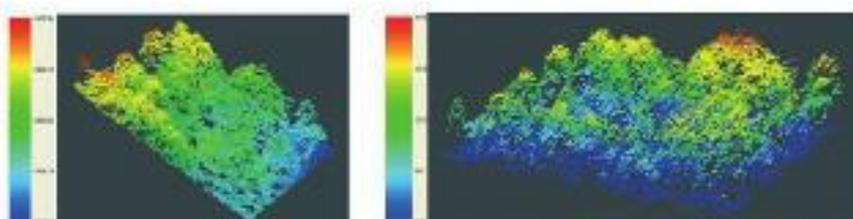


Figura 6. (a) Nube de puntos MAV y (b) nube de puntos MAV normalizado

algoritmo "watershed". Tras esta primera aproximación, se realiza la detección y localización de cada uno de los árboles mucho más precisa con el algoritmo de "máximos locales".

El algoritmo "watershed" ha sido utilizado como método de segmentación en otros trabajos con información multispectral (Tarabalka et al., 2010) así como con datos LiDAR (Andersen et al., 2005; Popescu y Wayne, 2004). La metodología propuesta pretende utilizar ambos tipos de información.

En el primer método para la detección de árboles sobre la zona de estudio (Figura 7 (a)) se ha utilizado la información espectral para el cálculo del NDVI (índice de vegetación normalizado) y el MAV derivado de los datos LiDAR (Figura 7 (b)). De esta forma se detectan las zonas de masas forestales, las cuales se filtran y procesan con un filtro de suavizado que permite resaltar las copas de los árboles (Recio, 2009). Tras el realce de las copas, se realiza la inversión de la imagen o filtro negativo (Figura 7 (c)), de forma que las copas de los árboles se convierten en las zonas más bajas. Al aplicar el algoritmo "watershed" sobre esta imagen, se detectan las copas de los árboles que actúan como sumideros generándose polígonos o segmentos correspondientes a cada una de las copas de los árboles. La Figura 7 (d) muestra un detalle de los contornos correspondientes a las copas de los árboles sobre el MAV.

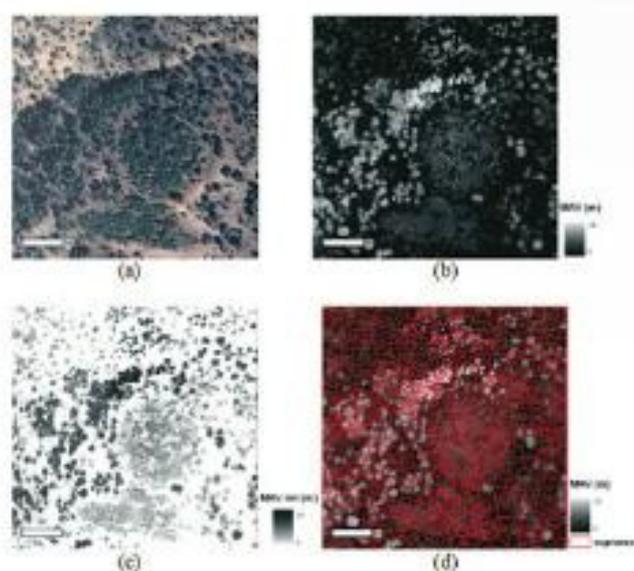


Figura 7. (a) Detalle de la zona de estudio RGB, (b) detalle MAV normalizado, (c) detalle imagen negativa y (d) segmentos calculados con watershed sobre MAV

Esta primera detección es considerada como una aproximación al número total de árboles sobre las zonas de estudio y a su localización. Uno de los problemas que presenta esta segmentación es que se generan segmentos que no se corresponden con árboles, sino con matorrales y pequeñas zonas de suelo desnudo. Por ello, el siguiente paso consiste en la clasificación por píxel de toda la zona de estudio, utilizando las bandas G (verde), R (rojo), el NDVI y el modelo de vegetación, seguida de una reclasificación orientada a objetos partiendo de los segmentos generados (Figura 7 (d)). De esta forma, se asigna a cada segmento una clase entre suelo, matorral o árbol. Los resultados de la clasificación orientada a objetos se muestran en la tabla 1.

Evaluación				
Clasificación	Matorral	Suelo	Árbol	Total general
Matorral	21	19	2	42
Suelo	2	8		10
Árbol	7	3	28	38
Total general	30	30	30	90
				63,3%

Si bien la fiabilidad global calculada es baja, la clase árbol está bien definida y diferenciada con respecto a las otras dos. Con propósito de detectar los segmentos de árbol, los valores bajos en la clasificación de suelo y matorral no se consideran de importancia. Los segmentos clasificados como árbol son contados y comparados con los datos de campo y calculando las estadísticas a nivel de parcela. Los resultados se muestran en la Tabla 2.

Nº Parcelas estudiadas	56
Máximo exceso	15 ud
Máximo defecto	37 ud
Media de aciertos por parcela	67,00%

Una vez realizada la segmentación, en las zonas más densas se percibe una falta de segmentación, esto es, en ocasiones existen varios árboles dentro de un mismo segmento. Por el contrario, existen segmentos en los que se encuentra tan solo un árbol que ha sido clasificado como suelo o matorral debido a la gran presencia de estos en torno al árbol (Figura 8).

Estos ejemplos ponen de manifiesto parcelas en las que los segmentos han sido incorrectamente clasificados, introduciendo así un error por defecto de árboles localizados en esta primera aproximación. A pesar de ello, se han conseguido detectar

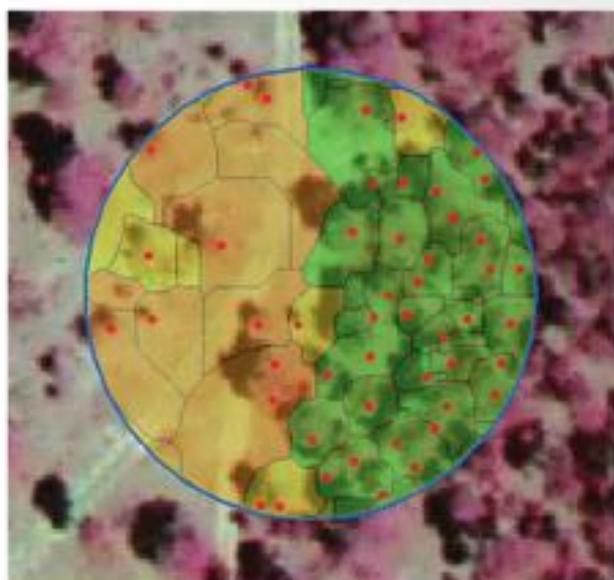


Figura 8. Ejemplo de clasificación por objeto de una parcela de estudio de 25m de radio. (Los puntos rojos son los árboles tomados en campo, los polígonos amarillos los segmentos clasificados como matorral, en naranja los clasificados como suelo y en verde los clasificados como árbol).

1872 árboles de un total de 2387 árboles de referencia.

La localización realizada mediante este método se ha evaluado a partir de los geocentros de los segmentos. De esta forma, comparando los geocentros estimados con el árbol observado más cercano, se han calculado las estadísticas de localización que se muestran en la Tabla 3.

A partir de las anteriores aproximaciones se inicia un proceso de detección más riguroso basado en el algoritmo de máximos locales. Este segundo proceso analiza cada segmento anteriormente calculado y procesa las diferentes clases contenidas (árbol, suelo o matorral). Si un segmento analizado contiene algún elemento correspondiente a un árbol (un

<b>N° Parcelas estudiadas</b>	<b>56</b>
<b>Medio desplazamiento</b>	1,11 m
<b>Desviación típica general</b>	3,73 m

píxel clasificado como árbol), este segmento es procesado y se busca sobre él la copa del árbol del modelo de vegetación. Éste modelo es previamente filtrado y posteriormente se le aplica el algoritmo de máximos locales. De esta forma, se

analizan los segmentos susceptibles de tener uno o más árboles en su interior, evitando errores por defecto. La Figura 9 muestra un ejemplo de detección de árboles sobre el MAV a partir de los segmentos anteriormente calculados y clasificados.

Una vez calculadas las coordenadas de los árboles, se evalúa la detección y la localización a partir de la referencia de las parcelas tomadas en campo. El número total de árboles detectados con este segundo proceso es de 2394, siendo el total de árboles de referencia, como se ha comentado anteriormente, de 2387 unidades, existiendo una diferencia de tan sólo 0.3% de exceso respecto a las parcelas de referencia.

### Evaluación del método

La evaluación se diferencia en dos partes: el conteo y la localización.

El conteo se ha realizado por parcela, calculando la media de aciertos por unidad de parcela. En este

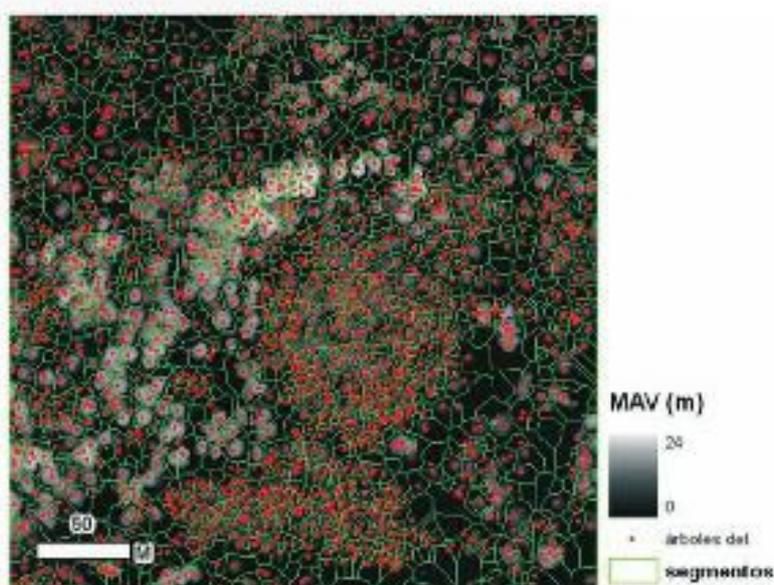


Figura 9. Árboles detectados sobre segmentos y CHM

proceso más preciso se ha obtenido una media de aciertos del 81.7%. Los errores máximos y mínimos calculados se expresan en términos absolutos, por lo que muestran el máximo error cometido

<b>N° Parcelas estudiadas</b>	<b>56</b>
<b>Máximo exceso</b>	22 ud
<b>Máximo defecto</b>	12 ud
<b>Media de aciertos por parcela</b>	81,70%

por defecto y por exceso. Los errores y la media de aciertos se muestran en la Tabla 4.

En cuanto a la localización, se han obtenido unos resultados que mejoran a los resultados aproximados en gran medida, consiguiendo una media de desplazamiento total de 1.23 metros, inferior a los 3 píxeles de desplazamiento. La Tabla 5 muestra las estadísticas de la localización de árboles.

	Media	Desviación est.
Media	1.233 m	0.223 m
Desv. típica general	0.704 m	0.154 m

Con las localizaciones se han calculado gráficas de dispersión tanto para los resultados aproximados como para los finales. Estas gráficas consisten en representar la distancia de los árboles detectados en función de los de referencia en dos ejes de coordenadas: coordenadas X y coordenadas Y, donde el centro de la imagen representa un error cero en la localización (Figura 10).

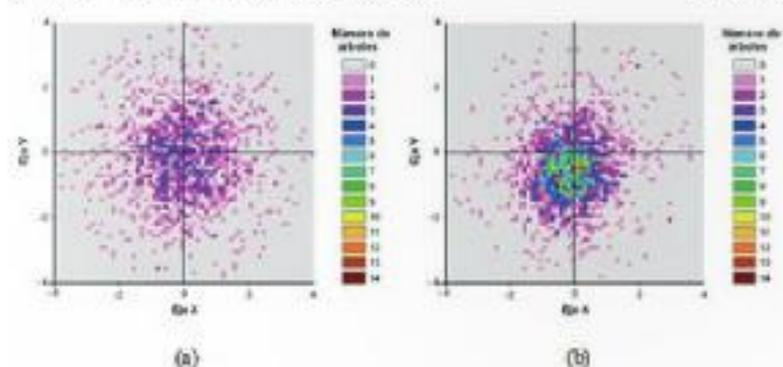


Figura 10. (a) Gráfica de dispersión de la localización en la segmentación y (b) gráfica de dispersión utilizando máximos locales.

Como se puede observar en las gráficas de dispersión, los resultados finales muestran un menor desplazamiento que con el primer método realizado, mejorando la media del desplazamiento en aproximadamente 3 metros. Las gráficas muestran los errores en los dos ejes de desplazamiento de los árboles detectados con respecto del árbol de referencia más cercano.

La leyenda muestra los colores en función de la cantidad de árboles. En la Figura 10 (a) se observa una mayor dispersión observando una concentración de árboles mayor en torno a los 4 metros. La Figura 10 (b), correspondiente a la segunda fase de detección, se caracteriza por una concentración de valores en el punto central de la gráfica indicando una mayor precisión en la localización.

## Discusión de resultados y conclusiones

En el primer proceso se han obtenido valores aproximados que han permitido obtener mejores resultados con el segundo proceso más preciso. En este primer proceso han intervenido tanto datos LIDAR filtrados como información multispectral en forma de índices de vegetación y de clasificaciones. Se podría haber conseguido una mejor aproximación tratando los parámetros utilizados de forma individual para cada una de las parcelas según su densidad arbórea. El principal problema que se ha presentado en la aproximación es que el conteo y localización han dependido principalmente de la clasificación orientada a objeto, dándose casos en los que a pesar de haberse clasificado píxeles como árbol dentro de los segmentos, su valor de moda corresponde al de otra clase, por lo que se introduce un error por defecto. En cambio, en aquellas zonas de gran densidad se produce un exceso. Ambos errores se han corregido en su gran mayoría en el segundo proceso.

En la fase de mejora de la primera aproximación se han obtenido resultados muy satisfactorios tanto en conteo como en localización. Esta ha dependido básicamente de los segmentos obtenidos en la aproximación, los cuales se han tratado individualmente para conseguir un conteo y una localización más precisos. A la vista de los resultados, se plantea un método automático para detectar y localizar la unidad de árbol sobre zonas forestales con una fiabilidad en torno al 81% con un error medio de 1.2 metros.

Con la detección individual de árboles se puede obtener características de cada uno de ellos entre las cuales, se encuentran características dasométricas necesarias para estimaciones de biomasa, conocimiento de estructuras arbóreas, especie, etc., obtenidas tradicionalmente por campañas de campo exhaustivas y caras. La metodología de detección y segmentación reduce parte del trabajo de campo y facilita el cálculo de estas características. Estos métodos tienen amplias posibilidades de futuro con aplicaciones orientadas a la gestión de zonas forestales, inventariado forestal, detección

de cambios en los ecosistemas y otras aplicaciones similares.

## Agradecimientos

Este trabajo se ha realizado en el marco del proyecto Desarrollo de técnicas y métodos para la gestión forestal sostenible a partir de datos de observación de la Tierra (INFOREST-II) (TSI-020100-2009-815), cofinanciado por el Ministerio de Industria, Turismo y Comercio y por el Fondo Europeo de Desarrollo Regional (FEDER).

## Referencias

- Andersen, H.E., McGaughey, R.J. y Reutebuch, S.E. (2005). Estimating forest canopy fuel parameters using LiDAR data. *Remote Sensing of Environment* 94, pp:441-449.
- Baltsavias, E.P. (1999). Airborne laser scanning: basic relations and formulas. *ISPRS Journal of Photogrammetry & Remote Sensing* 54, pp:199-214.
- Estomell, J., Ruiz, L.A., Velázquez-Martí, B., Hermosilla, T., (2011) IN PRESS. Analysis of the factors affecting LIDAR DTM accuracy in a steep shrub area. *International Journal of Digital Earth*.
- Heinzel, J.H., Weinacker, H. y Kock, B. (2008). Full automatic detection of tree species based on delineated single tree crowns – a data fusion approach for airborne laser scanning data and aerial photographs. *SilviLaser*. Edinburgh, UK.
- Hirata, Y., Furuya, N., Suzuki, M. y Yamamoto, H. (2009). Airborne laser scanning in forest management: Individual tree identification and laser pulse penetration in a stand with different levels of thinning. *Forest Ecology and Management* 258, pp:752-760.
- Hudack, A.T., Evans, J.E. y Smith, A.M.S. (2009). LIDAR utility for natural resource managers. *Remote Sensing* 1, pp:934-951
- Kraus, K., y N. Pfeifer (1998). Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing* . 53, pp:193-203.
- Leckie, D.G., Gougeon, F.A., Tinis, S., Nelson, T., Burnett, C.N. y Paradine, D. (2005). Automated tree recognition in old growth conifer stands with high resolution digital imagery. *Remote Sensing of Environment* 94, pp:311-326.
- Popescu, S.C. y Wynne, 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, pp:589-604.
- Pouliot, D.A, King, D.J., Bell, F.W. y Pitt, D.G. (2002). Automated tree crown detection and delineation in high-resolution digital camera imagery of coniferous forest regeneration. *Remote Sensing of Environment* 82, pp:322-334.
- Recio, J. (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. Tesis Doctoral. Universidad Politécnica de Valencia.
- Suárez, J.C., Ontiveros, C., Smith S. y Snape, S. (2005). Use of airborne LIDAR and aerial photography in the estimation of individual tree heights in forestry. *Computer & Geosciences* 31, pp:253-262.
- Tarabalka, Y., Chanossot, J. y Benediktsson, J.A. (2010). Segmentation and classification of hyperspectral images using watershed transformation. *Elsevier- ScienceDirect -Pattern Recognition* 43, pp:2367-2379.
- Wulder, M., Nieman, K.O. y Goodenough, D.G. (2000). Local Maximum Filtering for the Extraction of Tree Locations and Basal Area from High Spatial Resolution Imagery. *Remote Sensing of Environment* 73, pp:103-114.
- Yu, X., Hyypä, J., Holopainen, M. y Vastaranta, M. (2010). Comparison of Area-Based and Individual Tree-Based Methods for Predicting Plot-Level Forest Attributes. *Remote Sensing* 2, pp:1481-1495.