

Gestión del monte: servicios ambientales y bioeconomía

26 - 30 junio 2017 | **Plasencia** Cáceres, Extremadura

7CFE01-106

Edita: Sociedad Española de Ciencias Forestales Plasencia. Cáceres, Extremadura. 26-30 junio 2017

ISBN 978-84-941695-2-6

© Sociedad Española de Ciencias Forestales



Detección automática de pistas forestales y evaluación de la precisión a partir de datos LiDAR de baja densidad

PRENDES, C.1, BUJÁN, S.2, SÁNCHEZ, S1., CANGA, E1., MAJADA, J.1

Resumen

Las pistas forestales son infraestructuras esenciales para la gestión sostenible de montes puesto que posibilitan el acceso a las masas forestales para su aprovechamiento o ejecución de tratamientos selvícolas, conectan distintas áreas, sirven de acceso para actividades recreativas y para la lucha contra incendios. Por ello, es imprescindible disponer de una cartografía actualizada de pistas, que permita conocer al menos su localización y longitud.

El objetivo general de este estudio fue establecer una metodología para la detección automática del eje de las pistas forestales en un monte de Asturias, con rodales de pino marítimo, pino insigne, roble, castaño y otras frondosas. Para ello, se generaron distintas capas de información partiendo de los datos lidar de la zona de estudio (PNOA). A partir de ellas se evaluaron dos metodologías de clasificación de imágenes: la clasificación basada en píxeles y la orientada a objetos.

Los resultados obtenidos se compararon con la cartografía real de las pistas del monte mediante indicadores de Corrección, Integridad y Calidad. Además también se evaluó la precisión del eje de las pistas combinando análisis GIS y métodos estadísticos. La clasificación basada en píxeles obtuvo valores más altos en los tres indicadores evaluados así como en la precisión posicional.

Palabras clave

GIS, clasificación basada en píxeles, OBIA, indicadores de calidad, Orlado Simple, red de pistas forestales.

1. Introducción

Los caminos forestales son los elementos de los que depende el acceso seguro a los montes y el transporte eficiente por su interior. Además permiten la conexión entre distintas áreas y en muchas ocasiones son las infraestructuras sobre las que se organizan las labores de extinción de incendios. Sin embargo, el mantenimiento y construcción de estos caminos lleva aparejado un elevado coste, tanto ambiental como económico. Por todo ello, se considera que la planificación de la red de pistas forestales es de vital importancia para llevar a cabo una gestión sostenible y eficiente del monte (FERRAZ et al, 2016). En este sentido, LASCHI et al. (2016) reconocen en su estudio que el primer paso a dar en esta dirección es la identificación de la estructura y características de la actual red de pistas a fin de evaluar el estado actual de accesibilidad a las diferentes áreas y las necesidades reales de uso de las pistas forestales

En el ámbito de la detección automática de pistas. la tecnología LiDAR, se presenta como un complemento efectivo a las técnicas clásicas de teledetección y resulta especialmente valiosa en zonas forestales porque proporciona medidas precisas de la elevación del terreno permitiendo el mapeo topográfico de alta resolución incluso bajo vegetación densa (WHITE et al, 2010). Además, España es uno de los pocos países que tienen un Plan Nacional de Observación del Territorio que



¹ CETEMAS, Centro Tecnológico y Forestal de la Madera, Área de Desarrollo Forestal Sostenible. Pumarabule, Carbayin Bajo s/n 33936 Siero (Asturias)

²Laboratorio do Territorio (LaboraTe), Universidad de Santiago de Compostela. C/ Benigno Ledo Campus Universitario 27002 Lugo

incluye la captura de datos LiDAR de acceso libre en diferentes periodos de tiempo a lo largo de todo el territorio. Hasta el momento, solo están disponibles para uso civil los datos del primer vuelo (realizado entre los años 2008-2015 dependiendo de la Comunidad Autónoma), pero se espera que próximamente tenga lugar la realización de otro vuelo que actualice los datos disponibles. Pese a la incertidumbre sobre la actualización de los datos LiDAR y su baja densidad de puntos (0,5-1 ptos/m²), la disponibilidad gratuita de esta información a escala nacional compensa los inconvenientes mencionados anteriormente, especialmente si se tiene en cuenta que la adquisición de datos es uno de los pasos más caros en los estudios de teledetección.

2. Objetivos

El objetivo general de este estudio es establecer una metodología sencilla para detectar de forma automática pistas forestales empleando datos LiDAR de baja resolución.

Los objetivos específicos se desglosan en los siguientes:

- 1. Detectar de forma automática del eje de pistas y caminos en una zona forestal, utilizando dos metodologías diferentes de clasificación de imágenes.
- 2. Comprobar la precisión de los resultados obtenidos a partir de las dos metodologías de clasificación distinguiendo entre diferentes tipologías de pistas.
- 3. Analizar y comparar resultados para determinar qué método resulta más apropiado para la detección de pistas forestales empleando datos LiDAR de baja densidad.

3. Metodología

3.1 Zona de estudio

La zona de estudio se encuentra en los concejos de Pravia y Muros del Nalón, situados en el noroeste de Asturias (Figura 1). Se trata de un Monte de Utilidad Pública (M.U.P) denominado M.U.P Monteagudo, gestionado por la administración del Principado de Asturias (Servicio de Planificación y Gestión de Montes) y cuya superficie pública es de 178,77 ha.Las especies forestales presentes en él son: *Pinus pinaster* Ait., Castanea sativa Mill., *Pinus radiata* D. Don, *Quercus robur* L. y otras frondosas.




Figura 1. Zona de estudio



Es un monte con pendientes muy elevadas, más de la mitad de su superficie (55,7%) presenta una pendiente comprendida en un intervalo entre el 31% y el 60%, mientras que el 20,7% se encuentra por encima del 61%. El rango de elevación está comprendido entre los 36 y los 335 m sobre el nivel del mar.

3.2 Fuentes de datos

Los datos de partida de los que se dispone para la detección de pistas forestales y el análisis de resultados son:

- Datos LiDAR de la zona de estudio correspondiente al vuelo del PNOA (Plan Nacional de Ortofotografía Aérea) realizado en Asturias en el año 2012. Su densidad media es de 0,5 ptos/m², con una distribución de hojas de 2x2 km. Los archivos se presentan en formato LAS, con alturas elipsoidales. El sistema geodésico de referencia es el ETRS89 en proyección UTM y los datos del estudio se encuentran en el huso 29 N.
- Red de pistas real digitalizada en campo en 2013 con ayuda del software ArcPad® (ESRI, 2009). Estos datos se encuentran en formato shape, en el que se incluyen las líneas que definen el trazado de las pistas y lleva asociada una base de datos en la que se registraron una serie de atributos generales de las vías registradas (ancho del firme y de la calzada, tipo de firme, número de carriles...) además del estado en el que se encontraban atendiendo a distintos criterios (limpieza, conservación...).

3.3 Procesado de datos LiDAR

A partir de los datos LiDAR de la zona de estudio se generaron dos rásteres que sirvieron como datos de entrada para las metodologías de detección de las pistas forestales: el Modelo Digital del Terreno (MDT) y una imagen de intensidad. Se explican a continuación los pasos que se siguieron para su obtención:

A) MDT: el primer paso para crear el MDT fue el filtrado de la nube de puntos de la zona de estudio para separar los retornos que pertenecían al terreno de los que pertenecían a la vegetación. Dicho proceso se llevó a cabo con la herramienta *GroundFilter* implementada en el software FUSION (McGAUGHEY, 2009) y que se basa en el algoritmo de filtrado de KRAUS & PFEIFER (1998). Los parámetros utilizados para dicho algoritmo fueron g=-1.5 y w=3.5. Posteriormente los puntos pertenecientes al terreno se interpolaron para crear el MDT final con ayuda de la herramienta *GridSurfaceCreate* implementada también en FUSION. Con el fin de elegir la resolución más adecuada para el MDT, se analizó la distribución espacial de los retornos pertenecientes al terreno. Una resolución aceptable, es aquella que garantiza al menos la presencia de un punto de terreno en el interior de cada píxel, en este caso 2 x 2 m. El MDT generado finalmente, sirvió para crear el mapa de pendientes (en *ArcGIS 10.4* con la misma resolución que el MDT), que se utilizó como capa de entrada en los procesos de clasificación de imágenes posteriores.

B) Imagen de intensidad

La intensidad de los datos LiDAR es el cociente entre la cantidad de energía procedente de los objetos o del terreno captada por el sensor y la cantidad de energía total emitida por el sensor (SING et al, 2010). Los valores de intensidad se ven influenciados por la orografía del terreno, las características del vuelo y del sensor y también por las condiciones atmosféricas (SONG & CIVCO, 2004). Para corregir la influencia de estos factores en los valores de intensidad se ha llevado a cabo un proceso de normalización de los mismos. Aunque existen distintas formas de hacerlo, en este trabajo se optó por utilizar la expresión empleada por GARCÍA et al. (2010) (ec.1) considerando únicamente el rango estándar ya que no se dispone del ángulo de escaneo ni de datos de la atenuación atmosférica.



$$I_{norm} = I * \frac{R^2}{R_s^2} \quad \text{ec.1}$$

donde I_{norm} son los valores de intensidad normalizados, R es el rango de cada punto (diferencia entre la altitud media del vuelo y la altitud de cada punto) y R_{s}^2 es el rango estándar (se ha tomado un valor fijo de 1000 m).

Una vez normalizada la intensidad de los datos, se creó una imagen de intensidad de la zona de estudio con ayuda de la herramienta *Intensity Image* implementada en FUSION. El tamaño de celda establecido para crear la imagen fue de 2x2 m al igual que en el caso del MDT.

3.4. Metodología de detección de pistas

Una vez obtenidas las dos capas ráster de entrada a partir de los datos LiDAR, se procedió a analizarlas con el fin de obtener como producto final la red de pistas del monte en formato vectorial. Para tal fin, se utilizaron dos metodologías: una clasificación de imágenes basada en píxeles y otra orientada a objetos (OBIA). En ambos casos, la imagen de intensidad y el mapa de pendientes fueron las capas de entrada para ejecutar los análisis. El flujo de trabajo que se ha seguido queda recogido en la Figura 2. Cabe destacar que el flujo es muy parecido en las dos metodologías, solo se diferencia en el algoritmo de clasificación de imágenes que utiliza cada una de ellas (*Maximum Likelihood vs. Meanshift Segmentation*), es por eso que los pasos posteriores a la clasificación de las dos capas de entrada son iguales en ambos casos.




Figura 2. Esquema del flujo de trabajo para la detección automática de pistas

Así pues, la primera aproximación fue llevada a cabo a nivel pixel usando el método de la máxima probabilidad o *Maximum Likelihood* implementado en *ArcGIS 10.4* (ESRI, 2016), aplicado a la imagen de intensidad normalizada y al mapa de pendientes para conseguir dos imágenes binarias a través de una clasificación no supervisada. Este método considera que los niveles digitales en el seno de cada clase se ajustan a una distribución normal, lo que permite describir cada categoría de clasificación por una función de probabilidad a partir de su vector de medias y su matriz de varianzacovarianza. El cálculo se realizó para todas las categorías que intervienen en la clasificación, asignando el píxel a aquella que maximizaba la función de probabilidad (CHUVIECO, 2002).

En la segunda aproximación, la imagen de intensidad normalizada y el mapa de pendientes fueron segmentadas utilizando el algoritmo de segmentación *Meanshift* Segmentation implementado



ArcGIS 10.4 Este algoritmo identifica las entidades o los segmentos de las imágenes agrupando los píxeles adyacentes que tienen características espectrales similares.

A partir de aquí los pasos a seguir en las dos aproximaciones para la obtención de la red de pistas, fueron los mismos. Tanto las imágenes de intensidad y los mapas de pendientes resultantes de los dos procesos de clasificación fueron reclasificados para obtener una imagen binaria de cada variable que clasificase los elementos en "pistas" (1) y "no pistas" (0) atendiendo a los valores de intensidad y pendiente. Los umbrales para la reclasificación fueron escogidos tras haber llevado a cabo un análisis visual de las clases que resultaban de la clasificación basada en píxeles y de las propiedades de los objetos resultantes de la orientada a objetos. En el caso de los objetos aquellos que tenían un valor de intensidad mayor de 130 y un valor de pendiente menor de 12º fueron clasificados como pista (1) y el resto como no pistas (0)

Las imágenes binarias de pendiente y de intensidad obtenidas en cada aproximación, se refinaron usando un filtro de mayoría implementado en *ArcGIS* 10.4 que elimina los píxeles aislados sustituyendo las celdas de la capa ráster en función del valor de las celdas vecinas. Después se multiplicaron ambas imágenes para obtener una imagen binaria final clasificada en 0 (sin pistas) y 1 (pistas). Con el fin de lograr una continuidad longitudinal de las pistas, eliminando la discontinuidad entre tramos de categoría 1, se aplicaron dos filtros morfológicos (erosión y cierre) implementados en *ArcGIS* 10.4 a la imagen final.

El último paso fue la vectorización del eje de las pistas que se llevó a cabo utilizando el módulo *ArcScan* implementado en *ArcGIS 10.4*. La vectorización automática es una técnica que convierte los datos ráster en entidades vectoriales sin intervención del analista, siempre y cuando el ráster esté clasificado en dos niveles (imagen binaria). Como resultado, se obtiene un archivo vectorial en el que el eje de las pistas queda definido por una línea. Al aplicar esta herramienta a la trama resultante de la clasificación final, se obtuvo la red de pistas en formato vectorial.

3.5 Evaluación de los resultados

La evaluación de los resultados obtenidos con los dos métodos se llevó a cabo siguiendo la metodología expuesta en el artículo DE (AZIZI et al, 2014). Para ello, en primer lugar, todas las líneas que conforman la red de pistas real se dividieron en 500 segmentos de igual longitud (que equivalieron a tramos de 48 m) para realizar una comparación por tramos con las líneas detectadas con cada una de las dos metodologías empleadas. Posteriormente de acuerdo con la resolución de los capas de entrada (2 x 2 m) y teniendo en cuenta que algunas de las pistas del monte tienen un ancho superior a 6 m se decidió construir un buffer (área de influencia) de 10 m de ancho alrededor del eje real de las pistas. De esta forma, todas las líneas detectadas que quedasen ubicadas dentro de dicha área de influencia se consideraron como pistas detectadas o "Verdaderos positivos" (VP) (Figura 3a), aquellos segmentos de la red real que no se identificaron se clasificaron como pistas no detectadas o "Falsos negativos" (FN) (Figura 3b), aquellos segmentos de la red detectada que quedaban dentro del buffer, pero solo en parte, o que estaban desplazados y quedaban fuera de él se consideraron como "Falsos positivos" (FP) (Figura 3c).




Figura 3. Criterios de evaluación de la detección de pistas. a : Ejemplo de verdadero positivo (VP), b:Ejemplo de falso negativo (FN), c:Ejemplo de falso positivo (FP), d: Leyenda de los tipos de pistas.



Atendiendo al número de TP, FN y FP que se obtuvieron con cada aproximación se calcularon los siguientes indicadores (AZIZI et al, 2014):

- Integridad: porcentaje de la red real de pistas que es detectado por cada uno de los métodos. Su expresión matemática queda recogida en la ecuación 2.
- **Corrección:** porcentaje de pistas extraídas correctamente por cada método tomando como referencia la red real. Su expresión matemática se recoge en la ecuación 3.
- Calidad: mide la calidad de la detección realizada por cada método en base a criterios de integridad y corrección. Su expresión matemática se recoge en la ecuación 4.

$$\frac{VP}{VP + FN} \qquad \text{(ec.2)} \qquad \frac{VP}{VP + FP} \qquad \text{(ec.3)} \qquad \frac{VP}{VP + FP + FN} \qquad \text{(ec.4)}$$

3.5.1 Evaluación de la precisión del eje. Método del orlado simple

La precisión del eje de las pistas obtenida con cada una de las dos metodologías se evaluó únicamente en una submuestra formada por 4 tramos de pista (A, B, C y D) de la red real, seleccionados atendiendo a sus características en cuanto al tipo de firme, el ancho de la calzada y vegetación circundante como muestra la Tabla 1.

Tramo	Longitud (m)	Tipo de firme	Ancho calzada	Vegetación
А	1381	Zahorra	2-4	Pinar
В	421	Tierra	2-4	Pinar
С	266	Roca	2-4	Repoblado
D	360	Zahorra	>4	Pinar

Tabla 1. Tipología de las pistas muestreadas para determinar la precisión posicional

Con la ayuda de un GPS de precisión centimétrica (GS14 3.75G Performance Leica) se tomaron en campo una serie de puntos en el eje central de cada tramo. La unión de esos puntos permitió generar una línea del eje real de las pistas que sirvió como referencia posicional.

El proceso de evaluación se llevó a cabo utilizando el Método del Orlado Simple, descrito entre otros en el trabajo de GOODCHILD & HUNTER (1997). Este método se fundamenta en la generación de orlados o buffers alrededor de una línea cuya elevada precisión posicional permite tomarla como referencia, en este caso, dicha línea se corresponde con el eje real de las pistas tomado con GPS. Partiendo de los buffers que se generan alrededor de la línea de referencia, se contabiliza el porcentaje de línea detectada que se encuentra dentro de cada uno. Como consecuencia, se obtiene una distribución de probabilidades de pertenencia de la línea detectada al buffer creado a partir de la línea de referencia, de forma que se puede discriminar para un percentil que se establezca como umbral la anchura de indeterminación (MOZAS-CALVACHE, 2008). Así pues se generaron 20 buffers comprendidos entre 0,5 y 10 m cada medio metro (0,5; 1; 1,5; 2; 2.5...) y se calculó el porcentaje de línea detectada en cada tramo que estaba dentro de los buffers para los distintos anchos. A partir de los resultados obtenidos se construyó una gráfica de la distribución de probabilidad de pertenencia a la línea para cada una de las dos metodologías. El percentil que se estableció como umbral para el cálculo de la anchura de indeterminación fue el P95.

4. Resultados

4.1 Análisis de indicadores

Se muestran a continuación de forma gráfica las redes de pistas obtenidas con cada una de las dos metodologías (Figuras 4 y 5). Además, en la Tabla 2 se recogen los valores de los indicadores obtenidos para cada una de las dos metodologías de detección empleadas.



Tabla 2. Valores de los indicadores para cada una de las metodologías

Pixeles			Objetos		
Integridad	Corrección	Calidad	Integridad	Corrección	Calidad
0,65	0,90	0,60	0,59	0,93	0,56

A la vista de los resultados, de forma general se aprecia que la clasificación basada en píxeles arroja unos resultados ligeramente mejores que los de la clasificación orientada a objetos, especialmente en términos de integridad y calidad. En cuanto a la corrección el valor obtenido en las dos metodologías es prácticamente el mismo. Estos valores significan que el porcentaje total de la red de pistas que se detecta con ambas clasificaciones está en torno al 60%, existe por tanto un 40% de pistas que no se han identificado




Figura 4. Red de pistas detectada con la clasificación orientada a objetos




Figura 5. Red de pistas detectada con la clasificación basada en píxeles



De manera global, la mayor parte de pistas que no se detectan son de tierra y están rodeadas de vegetación densa de frondosas, aunque también existen pistas de otros materiales (zahorra, asfalto y roca) rodeadas de repoblado de pinar o de mezcla de pinar y frondosas que no han sido detectadas por ninguno de los dos métodos. La influencia del tipo de vegetación se hace especialmente patente en las pistas que discurren a través de masas de frondosas, donde su eje queda completamente ocluido (Figura 6).



Figura 4. Pistas ocluidas por la vegetación de frondosas

En el caso de masas heterogéneas, como por ejemplo pinar y frondosas, se puede apreciar como el eje de la pista se detecta sin problema en la zona de pinar pero desaparece o sufre cortes al llegar a la zona de frondosas (Figura 7). En las zonas de repoblado (Figura 8) sin embargo, el porcentaje de pistas de todos los tipos detectado es elevado, ya que la vegetación es poco densa y no ocluye los ejes de los caminos. Sin embargo también es elevado el número de falsos positivos en estas áreas debido a que la presencia de suelo desnudo entre los árboles contribuye a que los valores de intensidad sean altos, y la clasificación tenga problemas para diferenciarlo de terreno perteneciente a las pistas. Considerando los valores de corrección se tiene que en torno al 90% de las pistas que se detectan de forma automática representan pistas reales, es decir, el error de comisión que se comete es bajo.




Figura 5. Discontinuidad en el eje en masas de frondosas




Figura 6. Problemas con el ruido en las masas de repoblado

La calidad por su parte aporta una idea global de lo buena que es la clasificación, siendo el valor máximo que puede alcanzar de 1. En ambos casos está alrededor del 0,6. Cabe mencionar que, al margen de los parámetros evaluados existen otros factores, como son las discontinuidades que se



producen en los ejes de las pistas y la cantidad de ruido que se genera en la vectorización en cada metodología que influyen en la calidad del resultado

4.2 Análisis de la precisión

Las distribuciones de probabilidad obtenidas para cada una de las dos metodologías se recogen en las Figuras 9 y 10




Figura 9. Distribución de probabilidades para cada tipo de pista obtenida con la clasificación orientada a objetos

En el caso de la distribución de la probabilidad de la clasificación OBIA se aprecia una tendencia similar en todos los tramos muestreados, siendo el tramo A el que sufre cambios más acusados en el porcentaje de pertenencia a la línea a medida que aumenta el tamaño del buffer, ente los 3 y los 4 m aumenta en un 20 %. Los tramos B, C y D por su parte siguen una progresión más similar entre sí con aumentos entorno a un 10% de pertenencia cada metro.




Figura 7. Distribución de probabilidades para cada tipo de pista obtenida con la clasificación basada en píxeles



En la Tabla 3 se muestra de forma numérica la precisión obtenida para cada metodología en cada tramo tomando como umbral de indeterminación el 95%. El rango de tolerancia es de 0,5 m por lo que las diferencias en la precisión menores de ese valor no se han tenido en cuenta. De forma global la clasificación basada en píxeles arroja mejores resultados en la precisión del eje de las clases A y D mientras que en las clases B y C las dos clasificaciones tienen la misma precisión (Tabla 3).

Tabla 3. Precisiones obtenidas (m) por cada aproximación en función del tipo de pista

Tramo	Pixeles	OBIA	
Α	7	10	
В	5.5	5.5	
С	4	4	
D	4	8	

La precisión más alta se corresponde en las dos aproximaciones con la clase C (4 m), mientras que los peores resultados son los obtenidos con la clasificación orientada a objetos en las clases A y D (8 y 10 m respectivamente).

5. Discusión

En el estudio llevado a cabo por AZIZI et al. (2014) en una zona forestal empleando datos LiDAR con una densidad de 4 ptos/m², los valores de integridad, corrección y calidad fueron 63,02%, 75,07% y 52,17%, respectivamente. En su caso emplearon como datos de entrada de una clasificación SVM (Support Vector Machine) el Modelo Digital de Superficie normalizado y la imagen de intensidad. Estos valores se encuentran bastante próximos a los resultados obtenidos a partir de la clasificación basada en píxeles presentada en esta investigación, especialmente en el caso de la calidad, a pesar de que los datos del PNOA empleados en el estudio que aquí se presenta tienen una densidad mucho menor, de tan solo 0,5 ptos/m². En relación al tema de la densidad de los datos de partida su influencia ha quedado patente en trabajos como el de SHERBA et al. (2014) que probaron a reducir la densidad de su nube de puntos para evaluar su influencia en la calidad de la detección. De esa manera pasaron de una densidad de 1,2 ptos/m² con un 86% de a un 67 % para una densidad de 0,3 ptos/m². Estos autores no establecen una densidad óptima de puntos para la detección de pistas pero si sugieren que el LiDAR Point Spacing medio debe ser muy superior a 4 m, un valor que está muy por encima de los 1,4 m de los datos del PNOA utilizados en este estudio. En el caso de la precisión del eje, el hecho de que la clasificación basada en píxeles haya sido más precisa, podría estar relacionado con la resolución de las imágenes utilizadas en el proceso de clasificación. Según CÁNOVAS-GARCÍA (2012) el enfoque de clasificación orientada a objetos es capaz de ofrecer resultados más precisos que los obtenidos por un enfoque basado en píxeles, especialmente cuando se trata con imágenes de alta resolución espacial. Sin embargo, en este caso la resolución de las capas de información que participaron en la detección de pistas no era elevada debido a la baja densidad de los datos lidar utilizados. Por otro lado, según COWEN et al. (1995) el objeto a identificar (en este caso las pistas) debe estar compuesto como mínimo por 4 píxeles para ser identificado utilizando imágenes de sensores remotos lo cual no siempre se cumple en este estudio. Ello hace que la ventaja de los métodos OBIA sobre los basados en píxeles que es la capacidad de generalización y disminución de la heterogeneidad se convierta en un inconveniente. Finalmente la zona de estudio es una zona que presenta elevada pendiente con vegetación densa en muchas áreas que unido al ancho de las pistas y la resolución de las capas de información dificulta la creación de objetos representativos de las pistas en el proceso de segmentación.



6. Conclusiones

- 1. En el presente estudio se han evaluado dos metodologías de clasificación de imágenes (basada en píxeles y OBIA) para llevar a cabo la detección automática de pistas de un monte piloto, con el fin de poder aplicar la que mejor funcione a otros casos similares. Posteriormente la precisión de la red de pistas resultante de las dos metodologías fue evaluada mediante el método del orlado simple en 4 tramos medidos en campo con un GPS de precisión centimétrica y que presentaban distintas características en cuanto a tipo de firme, ancho de la calzada y vegetación circundante
- 2. En cuanto a la detección, el método de clasificación basado en píxeles arrojó resultados ligeramente mejores que el método basado en objetos. Los valores de Integridad, Corrección y Calidad fueron 65%, 90% y 60% respectivamente frente al 59%, 93% y 56% obtenido con la clasificación orientada a objetos. En el caso de la precisión del eje de las pistas detectadas, los valores obtenidos mediante la clasificación basada en píxeles han igualado o mejorado los obtenidos por la clasificación orientada a objetos para todos los tramos.
- 3. En las zonas donde la vegetación está compuesta por frondosas, los pulsos láser tiene muchas dificultades para llegar al terreno. Esto provoca que tanto el MDT generado en esas zonas (y por tanto el mapa de pendientes) como la imagen de intensidad presente errores elevados debido a la falta de puntos de suelo. Por otro lado, las zonas de vegetación poco densa como las de repoblado en suelo desnudo, son especialmente problemáticas para la detección porque los valores de intensidad de las pistas son muy parecidos a los del terreno descubierto. Por ello aunque el eje de las pistas se detecta bien, se genera mucho ruido y falsos positivos en las inmediaciones.
- 4. La discontinuidad en el eje de las pistas es un problema importante sobre el que se necesita incidir en futuros trabajos, con el fin de conseguir una red sin discontinuidades que permita llevar a cabo análisis de distintos tipos. Las investigaciones futuras deberán enfocarse en la línea tanto de mejorar el resultado de la clasificación como de conseguir líneas más definidas y continuas en condiciones de vegetación y pendiente adversas.

7. Agradecimientos

Este estudio ha sido financiado por el proyecto SCALyFOR (Proyectos de I+D+I "Retos Investigación", Ministerio de Economía y Competitividad). Los autores quieren agradecer al Servicio de Montes del Principado de Asturias por los datos facilitados.

8. Bibliografía

AZIZI, ZAHRA, AKBAR NAJAFI, Y SAEED SADEGHIAN. 2014. «Forest road detection using LiDAR data». J. For. Res 25 (4): 975–980.

CÁNOVAS GARCÍA, FULGENCIO. 2012. Tesis doctoral: «Análisis de imágenes basado en objetos (OBIA) y aprendizaje automático para la obtención de mapas de coberturas del suelo a partir de imágenes de muy alta resolución espacial: aplicación en la Unidad de Demanda Agraria nº 28, cabecera del Argos». https://digitum.um.es/jspui/handle/10201/31541.

CHUVIECO, EMILIO. 2002. «Teledetección ambiental: la observación de la tierra desde el espacio.» http://www.sidalc.net/cgibin/wxis.exe/?lsisScript=LIBROSNL.xis&method=post&formato=2&cantidad=1&expresion=mfn=003174.

COWEN, DAVID J., JOHN R. JENSEN, PATRICK J. BRESNAHAN, GEOFFREY B. EHLER, DERRICK GRAVES, XUEQIAO HUANG, CHRIS WIESNER, Y H. E. MACKEY. 1995. «The design and



implementation of an integrated geographic information system for environmental applications». Photogramm. Eng. Remote Sens.61 (11): 1393–1404.

ESRI, 2009. Environmental Systems Resource Institute. ArcPAd 10. ESRI, Redlands, CA.

ESRI, 2016. Environmental Systems Resource Institute. ArcGIS 10.4. ESRI, Redlands, CA.

FERRAZ, ANTÓNIO, CLÉMENT MALLET, Y NESRINE CHEHATA. 2016. «Large-scale road detection in forested mountainous areas using airborne topographic lidar data». *ISPRS J.* Photogramm. Remote Sens. 112 (febrero): 23-36. doi:10.1016/j.isprsjprs.2015.12.002.

GARCÍA, MARIANO, DAVID RIAÑO, EMILIO CHUVIECO, Y F. MARK DANSON. 2010. «Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data». Remote Sens. Environ. 114 (4): 816–830.

GOODCHILD, MICHAEL F., Y GARY J. HUNTER. 1997. «A simple positional accuracy measure for linear features». Int. J. Geogr. Inf. Sci. 11 (3): 299–306.

KRAUS, K., Y PFEIFER, N., 1998. Determination of terrain models in wooded areas with airborne laser scanner data. ISPRS J. Photogramm. Remote Sens. 53: 193-203.

LASCHI, ANDREA, FRANCESCO NERI, NICCOLÒ BRACHETTI MONTORSELLI, Y ENRICO MARCHI. 2016. «A Methodological Approach Exploiting Modern Techniques for Forest Road Network Planning». Croat. J. For. Eng. 37 (2): 319–331.

MCGAUHEY, R.J., 2009. FUSION/LDV: Software for LiDAR Data Analysis and Visualization; USDA Forest Service, Pacific Northwest Research Station: Seattle, WA, USA

MOZAS-CALVACHE, ANTONIO-TOMÁS. 2008. «Control de calidad posicional en cartografía por elementos lineales». http://ruja.ujaen.es/handle/10953/408.

SINGH, K. K., J. B. VOGLER, Y R. K. MEENTEMEYER. 2010. «Estimation of land-use in an urbanized landscape using LiDAR intensity data: a regional scale approach». En Geospatial Data and Geovisualization: Environment, Security, and Society. Special Joint Symposium of ISPRS Technical Commission IV and AutoCarto 2010. 15-19 November 2010, Orlando, Florida, USA, (International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences), unpaginated CD-ROM.

SONG, MINGJUN, Y DANIEL CIVCO. 2004. «Road extraction using SVM and image segmentation». Photogramm. Eng. Remote Sens. 70 (12): 1365–1371.

WHITE, RUSSELL A., BRIAN C. DIETTERICK, THOMAS MASTIN, Y ROLLIN STROHMAN. 2010. «Forest roads mapped using LiDAR in steep forested terrain». *Remote Sens.* 2 (4): 1120–1141.

