



CENTRO INTERNACIONAL DE ESTUDOS
DE DOUTORAMENTO E AVANZADOS
DA USC (CIEDUS)

TESIS DOCTORAL

**LA TECNOLOGÍA LIDAR AL
SERVICIO DE LA
REPRESENTACIÓN DEL RELIEVE
Y LA IDENTIFICACIÓN DE
COBERTURAS DEL SUELO**

Sandra Buján Seoane

ESCOLA DE DOUTORAMENTO INTERNACIONAL
PROGRAMA DE DOCTORADO EN GESTIÓN SOSTENIBLE DE LA
TIERRA Y EL TERRITORIO

LUGO
2018



DECLARACIÓN DE LA AUTORA DE LA TESIS

La tecnología LiDAR al servicio de la representación del relieve y la identificación de coberturas del suelo

Dña. **Sandra Buján Seoane** presento mi tesis, siguiendo el procedimiento ajustado al Reglamento, y declaro que:

1. La tesis abarca los resultados de la elaboración de mi trabajo.
2. De ser el caso, en la tesis se hace referencia a las colaboraciones que se tuvo en este trabajo.
3. La tesis es la versión definitiva presentada para su defensa y coincide con la versión enviada en formato electrónico.
4. Confirmando que la tesis no incurre en ningún tipo de plagio de otros autores ni de trabajos presentados por mi para la obtención de otros títulos.

En Lugo, 23 de octubre de 2018



Fdo. Sandra Buján Seoane

DECLARACIÓN DEL DIRECTOR DE LA TESIS

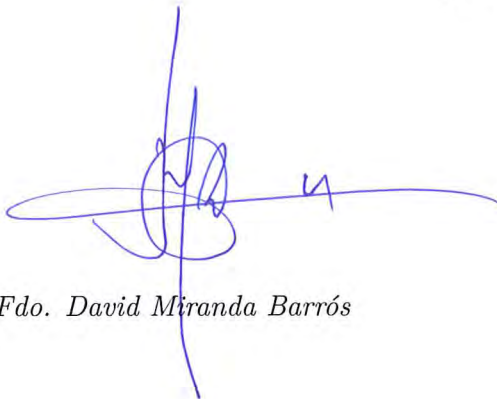
La tecnología LiDAR al servicio de la representación del relieve y la identificación de coberturas del suelo

D. David Miranda Barrós

INFORMA:

Que la presente tesis, se corresponde con el trabajo realizado por Dña. Sandra Buján Seoane, bajo mi dirección, y autorizo su presentación, considerando que reúne los requisitos exigidos en el Reglamento de Estudios de Doctorado de la USC, y como director de ésta no incurre en las causas de abstención establecidas en la Ley 40/2015.

En Lugo, 23 de octubre de 2018



Fdo. David Miranda Barrós



*A mi familia...
el impulso de cada uno de mis pasos*





*Everythings is related to everything else,
but near things are more related than distant things.*
([Tobler, 1970](#))





Agradecimientos

En primer lugar, me gustaría darle las gracias a mi director, David Miranda, por creer en mí, por tu protección y apoyo en esta etapa, por creer que podía llegar a este punto del camino! Sin tu confianza esto no hubiera sucedido. Te pido disculpas por haber incumplido casi todos los planes y plazos, habidos y... por haber. Aunque hoy me encuentro algo cansada no dudes que mañana daré lo mejor de mí misma para estar a la altura de la confianza que has depositado en mí. También me gustaría darle las gracias a mi coordinador en el LaboraTe durante este tiempo, Miguel Cordero, por su paciencia y su visión práctica. Si el papel de director es difícil, el de coordinador ... Sin pretender ofender a ningun@ de mis compañer@s, nadie mejor que tú para ese puesto. Eres la prueba de que es posible ejercer ese papel desde la cercanía. Me quito el sombrero ante ti!!

Rafael Crecente se convirtió en mi *jefe* a finales de 2009, sin embargo por caprichos del destino no conocería a Rafa hasta 2014 en Ecuador. Su capacidad para *visionar* y *conectar* era abrumadora. Muchas veces he pensado que difícilmente volveré a conocer a alguien con sus cualidades, pero doy gracias por poder sentir *morriña* de la sensación que él producía.

A mis compañer@s del LaboraTe. Parte de esta tesis es vuestra tesis. Me siento en deuda con cada un@ de vosotr@s. También me gustaría agradecerle a Chester y mis compañer@s del IERSE (Universidad del Azuay), y a Oswaldo Padilla y Eduardo Kirby de la ESPE (Universidad de las Fuerzas Armadas), su apoyo durante mi estancia en Ecuador.

Me regalasteis momentos que no olvidaré jamás. Volveré! También me gustaría darle las gracias a los integrantes de la *Red de Tecnologías LiDAR e de Información Xeoespacial*, por convertirse en el medio y pretexto para compartir ideas e inquietudes.

La paciencia no es una de mis cualidades, *socializar* nunca ha sido algo fundamental para mí y al parecer la amistad se encuentra estrechamente relacionada con las dos. En algún punto del camino eso también cambió (más *socializar* que la paciencia) y llegasteis sin avisar, según mi abuela, como las mejores visitas. Cada uno de vosotros habéis contribuido a crear esta tesis porque de alguna manera me habéis inspirado a mí. MaJo, eres el aceite si yo soy el agua, y el agua si me toca ser aceite, y aunque la gran mayoría de las veces estamos en los extremos - cada una en el suyo - en ningún momento te he sentido más lejos que a mi lado. Algunas de tus palabras las llevo en la piel y muchos pozos hubieran sido más oscuros sin ti. Gracias por todo! Inés, eres la calma en la tempestad, la fuerza bajo control, grandes principios bajo la más dura de las corazas, la esperanza de que un sistema mejor es posible. Nunca he podido estar mucho tiempo cerca de alguien que no admirara, pero tú qué fácil me lo has puesto! Pilar, por años nuestros caminos se cruzaron una y otra vez cada martes, un instante, pocas palabras. Un día los instantes se convirtieron en momentos y las palabras en conversaciones. Gracias por compartir tu tiempo conmigo! Andrea, nadie interpreta lo que siento como tú. Cada vez que me he puesto a bucear en lo que siento, en busca de porqué lo siento, has aparecido con el sol y una colchoneta de colores. Eres mi oasis particular, todo un lujo! Manu, ojalá llegue el día que escuche tu visión del mundo y no me retuerza en la silla, sin duda ese día seremos mejores personas y el mundo será más justo.

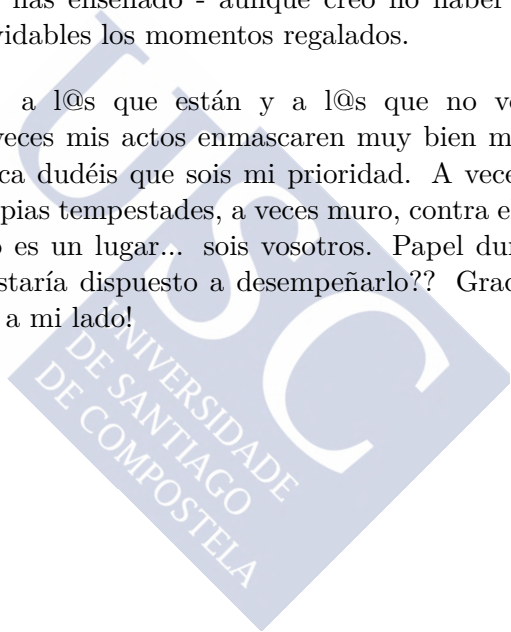
Lau y Edu, cuánto ha pasado desde el *LiDAR team*?? No quiero hacer cuentas!! Ha sido un honor trabajar a vuestro lado, habéis sido mi referente y qué sola me he sentido sin vosotros! A veces investigar es un proceso poco agradecido donde constantemente estás siendo evaluada y la duda en ti misma es un sentimiento demoleedor ... Edu, en uno de tus últimos correos me escribías *...has nacido para la investigación, que nadie te diga otra cosa porque no sería cierto...* Esas palabras han venido a mi cabeza en múltiples ocasiones estos últimos meses, proporcionándome oxígeno cuando me creía sin aire. Perdón por sacar

"nuestra vida a la calle" pero necesitaba agradeceréelo públicamente. Mil gracias a los dos!

Estrella y Emilio, hace más de 10 años que toqué a vuestra puerta y me considerasteis parte de vuestra familia. Sin vosotros no estaría aquí. No lo olvidaré nunca. Gracias!

José, no hay nadie que me conozca mejor que tu, incluso creo que me has mostrado partes de mi que ni yo misma conocía. No hay nadie a quien admire más que a ti. Perdón por el tiempo robado, gracias por lo mucho que me has enseñado - aunque creo no haber aprendido lo suficiente - e inolvidables los momentos regalados.

A mi familia, a l@s que están y a l@s que no volveré a ver. Aunque algunas veces mis actos enmascaren muy bien mis verdaderos sentimientos, nunca dudéis que sois mi prioridad. A veces mi refugio, incluso de mis propias tempestades, a veces muro, contra el que necesito chocar. Hogar no es un lugar... sois vosotros. Papel duro el vuestro, pero quién más estaría dispuesto a desempeñarlo?? Gracias por estar en todo momento a mi lado!





Listado de publicaciones

- **Presentación en workshop:** Sandra Buján, Miguel Cordero, David Miranda, 2016. DTMOFLabTe. Algoritmo de filtrado para la identificación de puntos terreno empleando datos LiDAR. Workshop Gestión y computación de datos LiDAR. 2 febrero, Lugo (Galicia, España) (Presentación oral).
- **Presentación en congreso:** Sandra Buján, Miguel Cordero, David Miranda, 2016. DTMOFLabTe. Algoritmo de filtrado para la identificación de puntos terreno empleando datos LiDAR. IV Encontro de Mocidade Investigadora. 9 - 10 junio, Santiago de Compostela (Galicia, España) (Póster).
- **Artículo:** Sandra Buján, Chester Sellers, Miguel Cordero, David Miranda, 2018. DebCloud: A new tool for improving LiDAR data filtering in urban areas. *Journal of Photogrammetry, Remote Sensing and Geoinformation Science* (*pendiente de revisión*).
- **Presentación en workshop:** Sandra Buján, Miguel Cordero, David Miranda, 2018. Proportional per Cell. Nuevo método para reducir la densidad de puntos LiDAR. Workshop en Gestión y computación de datos LiDAR. 27 de septiembre, Santiago de Compostela (Galicia, España) (Presentación oral).



Índice

Agradecimientos	I
Listado de publicaciones	V
Índice	VII
1 La representación del relieve	1
1.1 Introducción	3
1.1.1 Principales algoritmos de filtrado	5
1.1.2 Fundamentos de los filtros de densificación	21
1.1.3 El problema desde el punto de vista del usuario	27
1.1.4 Solución propuesta: DTMofLabTe	29
1.2 Material y métodos	30
1.2.1 Datos ISPRS	30
1.2.2 ¿Qué puntos pertenecen al terreno?	33
1.2.3 Principios del filtro DTMofLabTe	34
1.2.3.1 Descripción de los parámetros de filtrado.	35
1.2.3.2 Descripción de las funciones.	35
1.2.3.3 Operaciones e integración de funciones.	43
1.2.4 Evaluación de la precisión y análisis de resultados	47
1.3 Resultados y discusión	49
1.3.1 Ajuste de parámetros.	49
1.3.2 Evaluación interna de DTMofLabTe	52
1.3.2.1 Efectividad del proceso de depurado.	52
1.3.2.2 Influencia del método OWM en la selección de los P_S .	57
1.3.2.3 Influencia de los parámetros variables en el filtrado.	61
1.3.3 Evaluación externa y comparación con otros filtros	67

1.3.3.1	Resultados de DTMofLabTe	67
1.3.3.2	Comparación con otros algoritmos de filtrado	70
1.4	Conclusiones	81
2	Factores que afectan a la precisión de los MDT	91
2.1	Introducción	92
2.2	Material y métodos	106
2.2.1	Datos LiDAR	106
2.2.2	Descripción de la función DecimaTe	108
2.2.2.1	Random per Area (<i>RpA</i>).	108
2.2.2.2	Semi-Random per Cell (<i>SRpC</i>).	110
2.2.2.3	Proportional per Cell (PpC).	111
2.2.3	Descripción de la función <i>ThinData</i> (FUSION).	113
2.2.4	Metodología de evaluación	113
2.2.4.1	Evaluación a nivel método.	114
2.2.4.2	Evaluación a nivel modelo.	117
2.3	Resultados y discusión	124
2.3.1	Evaluación a nivel método	124
2.3.2	Evaluación a nivel modelo	134
2.3.2.1	Precisión de los MDT	134
2.3.2.2	Análisis de sensibilidad y predictivo	155
2.4	Conclusiones	166
3	Las coberturas del suelo	175
3.1	Introducción	177
3.2	Área de estudio, material y métodos	188
3.2.1	Zona de estudio	188
3.2.2	Datos	189
3.2.3	Normalización de la intensidad	192
3.2.4	Reducción de la densidad de puntos	200
3.2.5	Obtención del Modelo Digital del Terreno	202
3.2.6	Variables LiDAR y especificaciones de cálculo	205
3.2.6.1	En base a la elevación/altura	207
3.2.6.2	En base a la intensidad	214
3.2.6.3	En base a los retornos	219
3.2.6.4	En base a la rugosidad	226
3.2.6.5	En base a la textura	231

3.2.7	¿Qué coberturas del suelo serán identificadas?	236
3.2.8	<i>Random Forest</i> : Importancia de las variables	237
3.2.9	HyClass : Clasificación híbrida	241
3.2.9.1	Coberturas <i>Pv</i> y <i>Ps</i>	246
3.2.9.2	Coberturas <i>Sd</i> , <i>Vb</i> y <i>Vr</i>	251
3.2.9.3	Coberturas <i>Ed</i> , <i>Vm</i> y <i>Va</i>	252
3.2.10	Evaluación de la precisión	255
3.3	Resultados y discusión	261
3.3.1	Evaluación de la normalización de la intensidad	261
3.3.2	Análisis de la importancia de las variables	267
3.3.3	Análisis de la clasificación híbrida	278
3.4	Conclusiones	305
	Referencias Bibliográficas	317
	Índice de Figuras	350
	Índice de Tablas	356
	Anexos - CD	360
A	Anexos del Capítulo 1.	363
	La representación del relieve	363
A.1	Principales algoritmos de filtrado (1996 - 2016).	364
A.2	Integración de funciones de DTMofLabTe como complemento de otros algoritmos.	366
A.3	Elección de parámetros óptimos.	385
A.4	Efectividad del proceso de depurado y selección de puntos semilla.	394
A.5	Comportamiento de <i>T_{Ie}</i> , <i>T_{IIIe}</i> y <i>T_e</i> ante variaciones de los parámetros variables.	419
A.6	Evaluación cualitativa y cuantitativa. Comparativa con otros métodos.	435
A.7	Resumen resultados (gráficas <i>online</i>).	454

B	Anexos del Capítulo 2.	
	Factores que afectan a la precisión de los MDT	457
B.1	Características de las muestras.	458
B.2	Código fuente de la función DecimaTe	468
B.3	Indicadores de la evaluación del método. Resultados cualitativos y cuantitativos.	469
B.4	Evaluación de los modelos. Resultados cualitativos y cuantitativos.	500
C	Anexos del Capítulo 3.	
	Las coberturas del suelo	509
C.1	Coordenadas de los puntos de control terreno.	510
C.2	Selección de muestras de entrenamiento y validación	520
C.3	Ejecución de <i>HyClass</i> a partir de nubes con diferentes densidades de puntos.	524
C.4	Resultados cuantitativos de la clasificación HyClass empleando nube de puntos con densidad reducida.	527





CAPÍTULO 1

La representación del relieve

A pesar de la gran cantidad de esfuerzos y recursos destinados al desarrollo de algoritmos de filtrado de nubes de puntos LiDAR, esta tarea sigue considerándose un desafío, ya no sólo en lo referente a la efectividad y eficiencia, sino también a la *usabilidad* y la accesibilidad. En este estudio se describen los fundamentos de **DTMofLabTe** (*Digital Terrain Model using Overlap Filter - LaboraTe*), un nuevo algoritmo de filtrado implementado en el programa libre R. Su modo de operar presenta cuatro diferencias con respecto al esquema que siguen los filtros de densificación desarrollados hasta el momento. 1) El algoritmo está formado por un conjunto de funciones que operan secuencialmente (el *output* de la primera es el *input* de la segunda ...) pero con capacidad para funcionar de manera independiente, lo que haría posible su integración con otros algoritmos de filtrado; 2) se define y emplea la variable penetrabilidad, que junto con las variables elevación y pendiente permite la identificación de puntos terreno; 3) previamente a la selección de los puntos semilla, se incluye un proceso de depurado de la nube de puntos orientado a la eliminación de los puntos de edificaciones y la reducción de errores de comisión; 4) se emplea una ventana móvil con solape longitudinal entre ventanas y transversal entre *pasadas* para la selección de los puntos semilla. Para comprobar la precisión del filtrado se utilizan los datos LiDAR de referencia de la *International Society of Photogrammetry and Remote Sensing* y los resultados se comparan con los obtenidos en 23 estudios previos. Teniendo en cuenta las 15 muestras de referencia y empleando la combinación óptima de parámetros el error total es $Te = 3.34\%$ y el coeficiente Kappa $K = 92.62\%$. Estos resultados únicamente son mejorados por el algoritmo morfológico de [Pingel et al. \(2013\)](#) y el algoritmo de superficie adaptativa de [Hu et al. \(2014\)](#) ($Te_{Pingel} = 3.01\%$; $K_{Pingel} = 93.33\%$; $Te_{Hu} = 2.87\%$; $K_{Hu} = 93.63\%$).

Palabras clave: MDT, procesado de puntos LiDAR, algoritmos de filtrado híbridos, programa R.

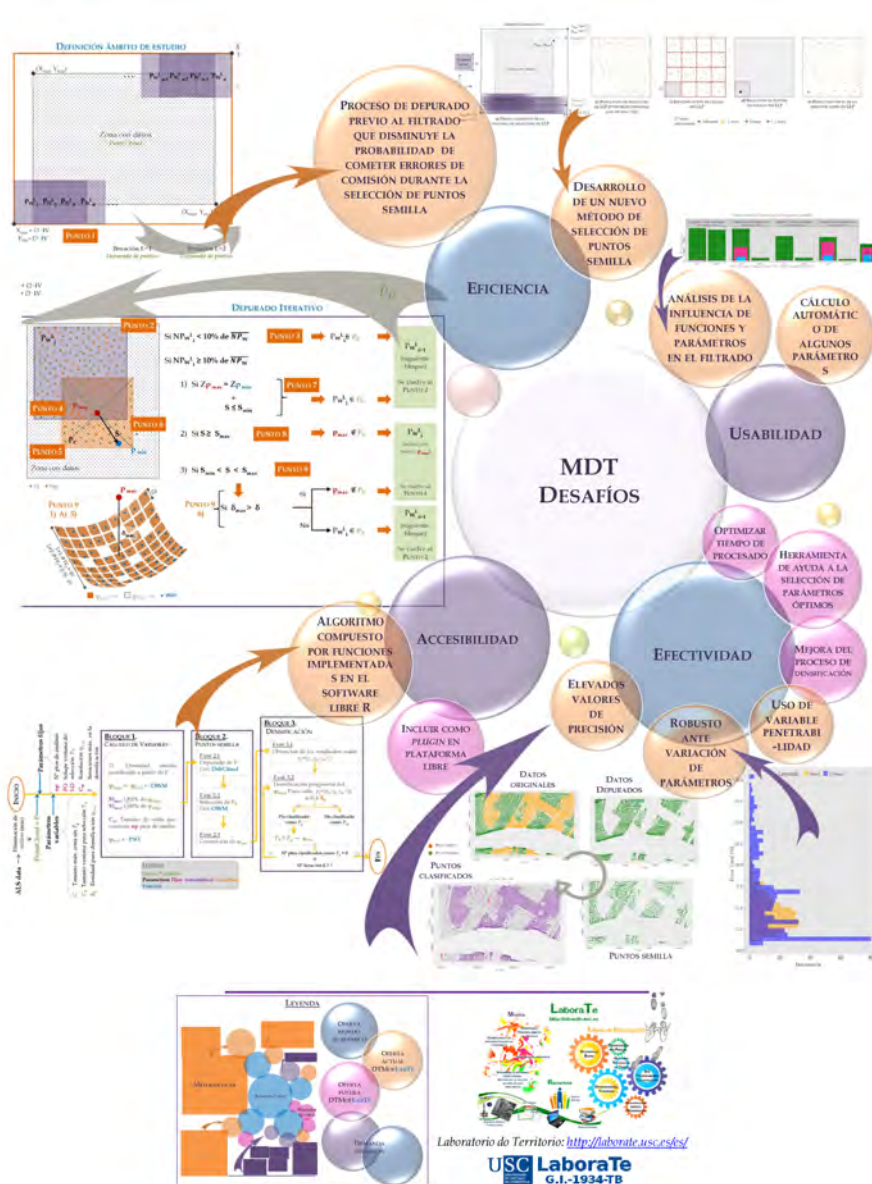


Figura 1.1: Resumen gráfico

1.1 Introducción

Durante siglos hemos sentido la necesidad de definir, analizar y explicar nuestro entorno, buscando incansablemente un acuerdo ideal entre el mundo real y el proyectado en nuestra mente (*conceptual model*). Para ello se creó una herramienta fundamental: el mapa. Sin embargo, la magnitud de las intervenciones del hombre en el territorio aceleró los ciclos de cambio de la naturaleza, dando lugar a la necesidad de contar con técnicas que den soluciones a las nuevas demandas. Gracias a los avances de la tecnología de la información fue posible abandonar las visiones estáticas proporcionadas por los documentos cartográficos convencionales (Moreira, 2001) y avanzar hacia herramientas digitales que permiten construir un mapa sustentado por un modelo de datos con contenido geográfico (*mathematical model*) (Li et al., 2005). Si bien en un inicio esta posibilidad sólo se encontraba al alcance de unos pocos, la llegada de Internet y los avances en el campo de la informática y computación, permitieron que de los mismos datos se pudieran crear diferentes mapas y que éstos llegaran a millones de usuarios.

Hoy en día ya no sólo se nos permite compartir los datos, sino que tenemos a nuestro alcance la posibilidad de interactuar con ellos, generarlos, modificarlos, interpretarlos y difundirlos. Hemos pasado de ser usuarios a creadores capaces de compartir con el mundo nuestra visión de la realidad. Un ejemplo de este avance se refleja en el modo de representar el terreno. En un inicio, los esfuerzos se centraron más en el *cómo* que en la exactitud del *dónde*. Quizás por su relación coste-eficiencia, los mapas de curvas de nivel (*contoured topographic maps*) han sido la forma más habitual de representar el terreno, de forma que la elevación y la morfología son representados por medio de líneas de contorno tras un proceso de generalización y abstracción. Sin embargo, la necesidad de una visión global del mundo, motivada por las conquistas y el comercio; los avances en geometría, que posibilitaron el desarrollo de los sistemas de referencia; la invención de la fotografía; avances en las cámaras y en los *Global Positioning Systems* (GPS); el desarrollo de la aviación y la detección remota, ..., proporcionaron un nuevo punto de vista del mundo, revolucionando tanto la forma de plasmarlo en

un plano, como el tipo de datos empleados para lograrlo, así como los métodos para adquirir estos últimos (Robinson et al., 1995).

Miller y Laflamme (1958) además de describir en detalle el uso de ordenadores y métodos fotogramétricos para la adquisición de datos, previamente propuestos por Roberts (1957), también introdujeron el concepto de Modelo Digital del Terreno (MDT): *The digital terrain model (DTM) is simply a statistical representation of the continuous surface of the ground by a large number of selected points with known X, Y, Z coordinates in an arbitrary coordinate field* (en Li et al. (2005)). Sin embargo, la gran diversidad de métodos que permiten obtener datos georreferenciados, el volumen de éstos y el amplio abanico de posibilidades para extraer información a partir de ellos, han agitado los cimientos de la representación del terreno. La tercera dimensión ya no es una característica adicional de la información geoespacial, sino que es parte fundamental.

Aunque existen múltiples técnicas para la adquisición de datos topográficos (topografía clásica, fotogrametría, *Interferometric Synthetic Aperture Radar*,...), la tecnología LiDAR ha sido reconocida como uno de los métodos estándar para la adquisición de este tipo de datos (Ulrich et al., 2007, Chen, 2010, Mongus y Žalik, 2012) debido a su precisión; a su capacidad para penetrar a través de la vegetación y obtener datos del terreno; y a la posibilidad de cubrir grandes áreas a un relativo bajo coste (Chen et al., 2012a, Maguya et al., 2013). A estos hechos se suman los esfuerzos de los Estados y la comunidad científica para disponibilizar la información geoespacial. En la última década, estas iniciativas favorecieron la multiplicación de las aplicaciones de los MDT, p. ej. para visualizar, evaluar y analizar la superficie terrestre, rectificar las imágenes aéreas y de satélite, desarrollar análisis espaciales o servir de base para crear otros modelos (Stereńczak et al., 2013). A su vez son considerados un eslabón clave para aplicaciones forestales (p. ej. inventarios forestales y estimación de biomasa) (Hyypä et al., 2008, González-Ferreiro et al., 2013b); modelización de recursos naturales (p. ej. detección de cambios en la morfología y modelado hidrográfico) (Hladik y Alber, 2012); ayuda a la prevención y mitigación de riesgos naturales (Raber et al., 2007) o planeamiento (Brennan y Webster, 2006, Dinis et al., 2010, Yan et al., 2015). De esta forma se pone de manifiesto tanto

la creciente importancia de los MDT como la necesidad de desarrollar nuevos métodos para su creación, adaptados al nuevo perfil de usuario-creador.

1.1.1 Principales algoritmos de filtrado

Hace más de una década, Flood (2001) identificaba el aumento de la eficiencia en el post-procesado de los datos LiDAR como uno de los desafíos al que tenía que hacer frente el sector comercial. Concretamente citaba que entre el 60%-80% de los recursos iban destinados a la clasificación manual de los datos y al control de calidad final. Desde entonces, se desarrollaron un gran número de algoritmos de filtrado, respaldados por los avances tecnológicos, los programas libre y la masiva disponibilidad de datos. Aunque las compañías privadas (y organismos públicos) no son muy transparentes en cuanto a su eficiencia en este tipo de procesos, el depurado manual de los modelos y su control de calidad lejos de perder peso en los *workflow* de los proyectos comerciales siguen desempeñando un importante papel, tanto por su influencia en la precisión como por su peso en los presupuestos (Renslow, 2012). Sin embargo, a pesar del esfuerzo realizado en este campo, la comunidad científica considera que este problema no está totalmente resuelto (Chen et al., 2012a, Maguya et al., 2013, Zhang y Lin, 2013, Hu et al., 2014) y sigue la búsqueda del *algoritmo perfecto*. Prueba de ello es que la producción de filtros lejos de disminuir ha aumentado con el paso de los años (Figura 1.2).




Figura 1.2: Evolución y tipología de los filtros desarrollados desde 1996 hasta 2016 (elaboración propia a partir de 75 artículos de algoritmos de filtrado - Anexo A.1).

En los últimos años se realizaron varias revisiones con el objetivo de comparar diferentes algoritmos de filtrado. Mientras algunas se centraron en evaluar cuantitativamente los resultados de diferentes filtros (Sithole y Vosselman, 2004, Zhang y Whitman, 2005) otras analizaron y compararon sus fortalezas y debilidades desde un punto de vista teórico (Liu, 2008, Meng et al., 2010). La tendencia en este tipo de revisiones es agrupar los diferentes algoritmos en categorías atendiendo a las similitudes que comparten durante el proceso de filtrado. En este estudio se consideran las siguientes categorías: 1) los algoritmos morfológicos; 2) los que implican una segmentación/cluster; 3) los que incorporan un proceso de densificación, se incluyen aquí muchos de los algoritmos tradicionalmente denominados como *surface-based*, *slope-based* o *interpolation-based*; y 4) los métodos híbridos, los cuales debido a su funcionamiento podrían incluirse en más de un grupo o en ninguno de los anteriores.

Los **filtros morfológicos** se basan en el concepto de morfología matemática usada tradicionalmente en el análisis de imágenes digitales. Se distinguen principalmente dos operaciones morfológicas básicas, dilatación y erosión. Si bien algunos autores usaron dichas operaciones de manera individual (Arefi y Hahn, 2005), lo habitual es usar combinaciones de éstas. A este respecto destaca la operación morfológica de apertura, ampliamente usada en el procesamiento de imágenes en escala de gris para suavizar los componentes *brillantes* de la imagen. Si trasladamos este concepto al procesamiento de datos LiDAR, y se toma como base el supuesto de que la elevación de los objetos (coches, edificios y vegetación) es habitualmente mayor que la del terreno que los rodea; al rasterizar los datos, la elevación será representada en escala de grises, y de esta forma, los objetos pueden identificarse por cambios en los tonos de gris (Zhang et al., 2003). La apertura se compone de dos operaciones básicas ejecutadas secuencialmente, erosión y dilatación. La erosión permite eliminar los detalles irrelevantes dentro del elemento estructural (*structuring element* - SE) mientras que la dilatación magnifica los valores elevados.

A diferencia de los filtros que operan sobre una nube de puntos, la mayoría de los algoritmos morfológicos simplifican el procesamiento de los datos LiDAR transformándolos en una imagen mediante un proceso

de rasterizado. Así, en lugar de operar sobre la nube de puntos bruta lo hacen sobre un ráster. Esta simplificación de los datos hace que estos filtros se encuentren entre los más eficientes en cuanto a tiempo de procesado, de forma que la relación positiva simplicidad-eficiencia-eficacia es el principal motivo por el que este tipo de filtros son desarrollados. Sin embargo la interpolación inicial de los datos supone una pérdida significativa de información que puede introducir errores en el filtrado (Yan et al., 2012, Guan et al., 2014). La gran mayoría de estos filtros son previos a 2007; y si bien se trata del tipo de filtro menos habitual teniendo en cuenta las cuatro categorías consideradas en este estudio (sólo el 14% de los filtros analizados es morfológico - Figura 1.2), en los últimos años se han desarrollado renovados algoritmos morfológicos que han demostrado su potencial y eficiencia en el filtrado de datos LiDAR (Hui et al., 2016). Filtros recientes como el de Li et al. (2014), abordaron la limitación del rasterizado de los datos organizando la nube de puntos a través de una estructura indexada (*grid index structure*), lo que permite mantener la precisión de los datos brutos y la simplicidad de la estructura regular de las imágenes sin necesidad de realizar una interpolación.

El elemento estructural(SE) es la ventana bidimensional que se emplea para aplicar las operaciones morfológicas. La definición de su forma y fundamentalmente su tamaño, constituye uno de los principales retos de este tipo de filtros (Wang y Tseng, 2010), considerándose este último un parámetro crítico para el cual no hay un único valor óptimo (Kilian et al., 1996, Arefi y Hahn, 2005). Por un lado, si el tamaño del SE es grande, el terreno será suavizado, pues los puntos terreno localmente más elevados, como los situados en líneas de rotura o zonas de elevada pendiente, serán eliminados y provocarán un aumento del error de omisión; por otro, si es demasiado pequeño, los detalles del relieve serán conservados a expensas de aumentar los errores de comisión en caso de existir grandes edificaciones. En este sentido, resulta de vital importancia llegar a un acuerdo en el tamaño de dicha ventana, de forma que ésta debería ser más pequeña que los detalles a conservar y más grande que los objetos que se desean eliminar. Los filtros morfológicos tradicionales tienen serias dificultades para operar sobre datos de baja densidad o para preservar las características del terreno en aquellas regiones donde se suceden zonas con pendiente elevada y otras más

llanas (Maguya et al., 2013). Esta limitación fue el detonante para adoptar estrategias multi-nivel, donde el operador morfológico se aplica varias veces variando el tamaño del SE (Kilian et al., 1996).

En esta línea, Zhang et al. (2003), tomando como referencia el algoritmo propuesto por Kilian et al. (1996) y en vista que se infravaloraba la elevación real del terreno no sólo en las crestas sino también en las zonas llanas, propusieron introducir un umbral máximo de diferencia de elevación entre las superficies de referencia y los puntos. Así, en cada iteración se consideraban como terreno aquellos puntos cuyos residuales con respecto a la superficie de referencia fuesen inferiores al umbral establecido. Inicialmente, establecieron que el tamaño del SE aumentase de forma lineal para preservar los detalles del terreno. Sin embargo, esta estrategia requería mucho tiempo de procesado y por ello se optó por un aumento exponencial del tamaño del SE, lo que permitió reducir el número de iteraciones. Debido a que el umbral de diferencia de elevación estaba vinculado a un valor constante de pendiente, este algoritmo producía errores de omisión en zonas donde la pendiente del terreno no era constante. Teniendo en cuenta esta limitación, Chen et al. (2007) desarrolló un algoritmo morfológico que no contemplaba esta restricción, lo que permitía obtener mejores resultados en zonas donde la pendiente no es constante (Hui et al., 2016). A mayores desarrollaron métodos para eliminar *outliers* y para asignarle valores a los píxeles vacíos en función de si éstos se debían a la presencia de superficies de agua o a bajos ratios de penetración en zonas con vegetación densa. Estas mejoras demandaban definir un gran número de parámetros, lo cual se presenta como un inconveniente para el usuario final. Por otro lado, el problema de las celdas vacías pudo verse agravado al tener en cuenta únicamente el último retorno. Posteriormente, Pingel et al. (2013) indicarían en su estudio la conveniencia de emplear todos los retornos para generar la superficie inicial.

Generalmente, al seguir una estructura multi-nivel, el parámetro de diferencia de elevación o pendiente debe tomar un valor máximo cuando se usan los mayores tamaños de ventana, con el propósito de reducir los errores de omisión en zonas con elevada pendiente y disminuir a medida que lo haga el SE (Li et al., 2014). Siguiendo esta rutina, algunos objetos complejos como edificaciones a diferentes alturas con formas artificiosas

son difíciles de eliminar. Para mitigar este tipo de errores, [Li et al. \(2014\)](#) mejoraron el algoritmo *Top-Hat* tradicional añadiendo un filtro *sloped brim* que les permitió identificar aquellos puntos objeto clasificados como terreno, disminuyendo así los errores de comisión. Sus resultados en zonas urbanas son buenos, sin embargo las zonas rurales caracterizadas por presentar elevadas pendientes y vegetación densa, son castigadas con elevados errores de omisión localizados sobre todo en las líneas de rotura. Los entornos rurales continúan siendo una asignatura pendiente para este tipo de filtros ([Yunfei et al., 2008](#)). Previamente al desarrollo de este algoritmo, [Pingel et al. \(2013\)](#) mejoró los filtros morfológicos previos ([Kilian et al., 1996](#), [Zhang et al., 2003](#), [Chen et al., 2007](#)), y aunque no presentó una solución novedosa, la inclusión de diferencias puntuales resultaron determinantes para mejorar significativamente los resultados alcanzados hasta el momento por los filtros morfológicos. Las principales diferencias que presenta con los filtros desarrollados hasta el momento son: 1) el método empleado para asignarle valores a las celdas sin datos en la superficie inicial; 2) incremento lineal del tamaño del SE circular y empleo de un único parámetro para controlar el umbral de elevación máxima permitida; 3) método de interpolación para generar la superficie del terreno provisional y 4) vincularon la pendiente con un umbral de elevación para identificar los puntos terreno.

Los filtros morfológicos no tienen en cuenta la continuidad horizontal al considerar únicamente diferencias de elevación o pendiente entre elementos. De este modo, en ocasiones resulta insuficiente discriminar los puntos terreno en base únicamente a propiedades geométricas, por ello algunos autores consideraron que el proceso de filtrado podría verse fortalecido mediante la agrupación de puntos en segmentos (también denominados objetos), lo que permite contar con información contextual y topológica además de la geométrica ([Pfeifer y Mandlbürger, 2008](#)). La mayoría de los *filtros de segmentación o cluster* se desarrollaron entre el año 2000 y el 2008 (Figura 1.2), tal vez impulsados por su popularidad como parte de las clasificaciones orientadas a objetos frente a las clasificaciones tradicionales basadas en píxeles. De forma genérica, este tipo de métodos de filtrado agrupan los puntos en segmentos siguiendo un criterio de homogeneidad para posteriormente a cada segmento asignarle una clase. De esta forma, los puntos incluidos en dichos objetos también son clasificados. En la mayoría de los casos se

diferencia entre terreno u objeto (Tóvári y Pfeifer, 2005), aunque en algunos la clase objetos se divide a su vez en vegetación y edificaciones (Nardinocchi et al., 2003). El criterio de homogeneidad empleado para formar los segmentos se basa generalmente en la elevación o en el cálculo de la normal de cada punto. Tóvári y Pfeifer (2005), además de emplear la normal también consideró su variación a nivel local y la proximidad espacial entre puntos. En cuanto a la clasificación, es habitual recurrir a información contextual (clase, densidad de puntos por segmento,...), topológica (conectividad, compacidad, distancia,...) o geométrica (tamaño, forma, elevación,...). Por ejemplo Schiewe (2001) empleó valores medios y máximos de pendiente. En algunos casos, los puntos que han sido clasificados como terreno a partir de este proceso, se emplean para calcular una superficie de referencia a partir de la cual es posible refinar esa primera clasificación. Esta corrección se puede hacer calculando el residual de cada punto con respecto a esa superficie y eliminando aquellos que sobrepasan un umbral establecido previamente (Brovelli et al., 2002).

Este tipo de filtros pueden operar sobre la nube de puntos bruta (Tóvári y Pfeifer, 2005) o sobre los datos en formato ráster (Nardinocchi et al., 2003, Van de Woestyne et al., 2004, Forlani y Nardinocchi, 2007). Si bien estos métodos son menos sensibles a la presencia de ruido (Guan et al., 2014) y más eficientes en referencia al tiempo de procesado, comparten las limitaciones de los filtros morfológicos derivadas del empleo de datos en formato ráster, como es la pérdida de información, la dificultad para manejar el solape de diferentes coberturas o tener en cuenta la conexión topológica real entre puntos (Tóvári y Pfeifer, 2005). Al igual que en las clasificaciones orientadas a objetos (OBIA), la precisión de la segmentación juega un papel crucial en la calidad final del filtrado. Nardinocchi et al. (2003), partiendo de la nube de puntos rasterizada realizó una segmentación teniendo en cuenta la diferencia de elevación entre puntos con el propósito de identificar cuatro clases (terreno, vegetación, edificios y sin clasificar). Sin embargo, observó que algunas zonas se encontraban sobre-segmentadas mientras que en otras un mismo segmento estaba compuesto por puntos pertenecientes a diferentes clases. Estos son dos claros ejemplos de errores derivados del proceso de segmentación. Para corregir los puntos mal clasificados se basó en características topológicas junto con la orientación de la

pendiente.

Generalmente este tipo de algoritmos funcionan mejor en las zonas urbanas que en las forestales o rurales, pues en las primeras, la segmentación se ve favorecida tanto por la presencia de *saltos* entre los puntos objeto y terreno (Tóvári y Pfeifer, 2005), como que las cubiertas de las edificaciones forman planos que fácilmente pueden pasar a formar parte de un único segmento debido a su homogeneidad tanto en relación a la elevación como a la pendiente (Pfeifer y Mandlbürger, 2008). Sin embargo, la presencia de vegetación o edificaciones con formas complejas generan errores en el proceso de segmentación, resultando difícil establecer un criterio de homogeneidad que funcione de manera universal en toda la zona. De este modo se generarán muchos más segmentos y de menor tamaño que en las zonas urbanas. Así, se espera que la calidad de la segmentación sea tanto mejor cuanto más homogénea sea la zona a filtrar.

Por último, otra de las limitaciones que que presentan este tipo de filtros está relacionada con la densidad de puntos. A la hora de rasterizar los datos, si la densidad es baja el ráster resultante representará una superficie suavizada, dificultando la segmentación. Los objetos que se formen presentarán bordes poco nítidos que no se ajustan de forma precisa, por ejemplo, a los límites de las edificaciones. Brovelli et al. (2002) citó ésta como una de las principales limitaciones de su algoritmo, afirmando que su método no se puede aplicar sobre datos con densidades inferiores a 0.18 pto/m². Por otro lado, en el caso de elevadas densidades, la rasterización de los datos es más compleja y costosa, y debido a su elevado grado de detalle puede producirse una sobresegmentación (Tóvári y Pfeifer, 2005). Este problema también se puede dar en zonas forestales debido a la estructura de la vegetación y a la pendiente del terreno (Forlani y Nardinocchi, 2007).

Como camino alternativo a los filtros descritos, algunos autores se decantaron por el desarrollo de filtros que incluían un proceso iterativo de densificación. En este estudio se incluyen dentro de la categoría de ***filtros de densificación*** la gran mayoría de algoritmos que tradicionalmente han sido clasificados como *surface/interpolation/slope based* pues se considera que comparten de forma genérica la misma

secuencia de pasos para identificar los puntos terreno. Estos pasos son principalmente dos: 1) creación de una superficie continua de referencia empleando bien todos los puntos bien una muestra representativa de puntos terreno, 2) para posteriormente a partir de dicha superficie, ir añadiendo iterativamente nuevos puntos al modelo en base al cumplimiento de una serie de reglas considerando la elevación y/o la pendiente.

Uno de los algoritmos pioneros de este tipo fue el PTD (*Progressive TIN Densification*) de [Axelsson \(1999\)](#). A partir de un conjunto de puntos con elevación mínima seleccionados localmente se genera un TIN que es densificado iterativamente en base al cumplimiento de una serie de umbrales apoyados en los ángulos y las diferencias de elevación entre cada punto y el TIN de referencia. Este método obtuvo los mejores resultados en la comparativa realizada por [Sithole y Vosselman \(2004\)](#) y su posterior integración en el programa comercial *TerraSoild* lo convirtieron en uno de los más usados. Pese a su popularidad, este método presenta errores ante la presencia de pequeños objetos y discontinuidades en el terreno; tiene dificultades para identificar puntos terreno en líneas de rotura y zonas de elevada pendiente; y también puede generar errores de comisión debido a la identificación errónea como puntos terreno aquellos que se localizan en la parte inferior de los objetos ([Shao y Chen, 2008](#), [Li et al., 2014](#), [Chen et al., 2016a](#)). En un intento por mitigar el efecto de estas limitaciones, varios han sido los investigadores que lo han tomado como referencia para el desarrollo de nuevos filtros. [Sohn y Dowman \(2002\)](#) para la selección de los mínimos locales adoptaron un método *downward*, mientras que para la densificación del TIN emplearon un método *upward*, donde se establece por encima de cada triángulo de la fase *downward* un área de influencia. Los puntos en el interior de esta zona se emplearán para construir figuras tetraédricas, de forma que aquellos puntos que produzcan los tetraedros más planos se considerarán puntos terreno. Este criterio de clasificación de los puntos asume que el terreno es llano en una vecindad local, de forma que puede generar errores en montículos y colinas, apareciendo la parte superior de éstas como superficies horizontales. Más recientemente, se ha combinado con procesos de segmentación ([Zhang y Lin, 2013](#), [Lin y Zhang, 2014](#)) o con métodos morfológicos ([Zhao et al., 2016](#)).

Otro algoritmo pionero de este tipo es el de predicción lineal de Kraus y Pfeifer (1998). Una adaptación de este filtro se encuentra implementada en el programa gratuito FUSION (McGaughey, 2010). En este caso, la superficie de referencia se crea a partir de todos los puntos, de forma que ésta *flota* entre los puntos terreno y los puntos objeto. Intuitivamente, los puntos que se encuentran por debajo de esta superficie tiene mayor probabilidad de pertenecer al terreno que aquellos situados por encima. En base a este supuesto, a partir de los residuales de los puntos y una función de pesos, la elevación de cada punto es ponderada para calcular una nueva superficie de referencia que iterativamente se irá adaptando a la superficie del terreno. Posteriormente, Pfeifer et al. (2001) modificó este algoritmo llevándolo a una escala jerárquica donde los datos seguían una estructura piramidal. De esta forma, aumentaron la eficiencia al disminuir el tiempo de procesado y redujeron los errores de comisión debidos a la presencia de edificaciones (Zhang y Lin, 2013). Al igual que en el caso anterior, se tomó como punto de partida para el desarrollo de nuevos algoritmos. Schickler y Thorpe (2001) modificó el algoritmo clásico de predicción lineal empleando como superficie de referencia un TIN y teniendo en cuenta además de la nube de puntos, mediciones externas como puntos y líneas de rotura. También Lee y Younan (2003) modificaron el filtro original añadiéndole un método de refinado de puntos. Sin embargo, los algoritmos que proporcionarán los mejores resultados serán aquellos que al igual que Axelsson (1999) generan la superficie de referencia inicial a partir de un conjunto de puntos con elevación mínima seleccionados a nivel local. Estos algoritmos concentran la mayor parte de los esfuerzos en el proceso de densificación bien empleando sofisticados métodos de interpolación (Chen et al., 2013) bien desarrollando umbrales de elevación dinámicos cuyo valor varía en función de las características del terreno (Hu et al., 2014).

La gran mayoría de estos filtros (Kraus y Pfeifer, 1998, Vosselman, 2000, Roggero, 2001) emplean las variables pendiente y elevación en el proceso de densificación. El supuesto de partida es que, en una vecindad local, la pendiente o elevación entre dos puntos terreno es menor que la esperada en el caso de que por lo menos uno de los puntos sea objeto. Este tipo de algoritmos presentan buenos resultados en zonas relativamente llanas, no obstante tienen serias dificultades en zonas con

elevada pendiente. En estos casos falla el supuesto sobre el que sustenta este tipo de filtros: grandes diferencias de pendiente/elevación entre dos puntos no se deben a que uno de ellos representa un objeto, sino al efecto del relieve del terreno (Maguya et al., 2013). Afinar en el valor que se le asigna al umbral de pendiente o emplear filtros que lo calculen automáticamente en función del terreno, como son los filtros adaptativos (Sithole, 2001), los de dirección dual (Wang y Tseng, 2010) o el desarrollado por Hu et al. (2014), puede mejorar el resultado del filtrado al disminuir el error de omisión en zonas con elevada pendiente. Sin embargo, la presencia de rampas, la sucesión de áreas llanas y escarpadas, o la presencia de vegetación densa en terreno abrupto, sigue constituyendo un desafío para este tipo de filtros (Mongus y Žalik, 2012).

Seo y O'Hara (2008) en su comparación de los resultados de varios algoritmos de filtrado analizaron el coste computacional que implicaba cada uno de ellos. Así, tomando como referencia los datos de tres áreas de estudio calcularon el tiempo que cada algoritmo tardaba en realizar el filtrado. Concluyeron que los métodos que implican un proceso de densificación como el de Axelsson (1999) tienen un mayor coste computacional que por ejemplo los filtros morfológicos (entre 10 y 25 veces mayor dependiendo de las características de la zona a filtrar). La mayor parte de este coste se le atribuye al método de interpolación usado y al proceso de clasificación, ambos directamente relacionados con el número de puntos. Adicionalmente y vinculado con lo anterior, también influye el número de iteraciones que es necesario ejecutar, pues son computacionalmente intensas y contribuyen de manera significativa a aumentar el tiempo de procesado (Guan et al., 2014).

A pesar de que la interpolación produce una disminución de la eficiencia del filtrado, el empleo de sofisticados métodos de interpolación posibilita el uso de información contextual (Hu et al., 2014), provocando que este tipo de filtros obtengan mejores resultados en zonas complejas y heterogéneas que otros algoritmos (Sithole y Vosselman, 2004). A este respecto, Evans y Hudak (2007) demostraron el potencial del método TPS (*Thin Plate Spline*) frente a otros métodos de interpolación como el kriging, IDW (*Inverse Distance Weighting*) o TIN. Recientemente, otros investigadores como Mongus y Žalik (2012), Chen et al. (2013) o Hu et al. (2014) lo incluyeron en sus filtros alcanzando muy buenos

resultados (empleando los datos de referencia del ISPRS, el coeficiente Kappa teniendo en cuenta todas las muestras fue de 87.12%, 90.51% y 93.63%, respectivamente). Para compensar la disminución de la eficiencia, en algunos casos se organizaron los datos empleando una estructura piramidal (Hu et al., 2014). En la sección 1.1.2 se incluye una revisión más exhaustiva de los filtros que implican un proceso de densificación, pues si bien el algoritmo que se presenta en este estudio, **DTMofLabTe**, es híbrido, su esencia es la de un filtro de densificación.

A medida que la tecnología LiDAR se fue consolidando y ganando adeptos, los algoritmos de filtrado han incrementado su nivel de complejidad. Ante la necesidad de dar respuesta a los desafíos actuales en relación a la representación del terreno y en aras de aumentar la precisión en la identificación de los puntos que lo definen, la tendencia en la última década es la de integrar varios métodos/procesos de filtrado aprovechando sus fortalezas (Figura 1.2), dando lugar a los denominados *métodos híbridos* (Maguya et al., 2013). Uno de esos desafíos son las regiones forestales caracterizadas por un relieve heterogéneo y la existencia de zonas con baja densidad de puntos terreno. El reducido porcentaje de puntos terreno puede deberse al tipo de vegetación, donde cada especie presenta un ratio de penetración diferente; la complejidad del relieve o las características del sensor (Kobler et al., 2007). A causa de las particularidades de estas zonas, algunos filtros como los que incluyen un proceso de segmentación o de selección de puntos semilla no funcionan bien en este tipo de regiones. Los primeros presentan dificultades para generar segmentos a partir de datos con baja densidad mientras que los segundos, para evitar los errores de comisión producidos al introducir erróneamente puntos objeto en la nube de puntos semilla, deberán usar un tamaño de malla grande, ocasionando un aumento de los errores de omisión por la generalización del relieve en aquellas zonas con mayor densidad de puntos. Además, los filtros que emplean umbrales de elevación o pendiente tampoco obtendrán buenos resultados, pues el principio en el que se basan (las mayores diferencias de elevación/pendiente se dan entre puntos objeto) no se cumple, ya que algunas zonas pueden presentar una pendiente mayor que la establecida en el umbral.

Para enfrentarse al reto de representar el terreno en entornos

forestales y/o montañosos, algunos investigadores se inclinaron por diseñar algoritmos basados en nuevos enfoques, fundamentalmente estadísticos (Yunfei et al., 2008, Bretar y Chehata, 2010, Maguya et al., 2013). Dichos algoritmos han adoptado muy diversas perspectivas. Por ejemplo Yunfei et al. (2008), basándose en el método *skewness balancing* desarrollado por Bartels y Wei (2006), asume que los valores de intensidad y elevación de los puntos terreno siguen una distribución normal. Dicha distribución puede verse alterada por la presencia de puntos objeto. Así, a partir de las medidas estadísticas de distribución, curtosis y asimetría, el algoritmo va descartando los puntos objeto. Este algoritmo es sensible en aquellas zonas donde no se cumple el supuesto de partida, bien porque los valores del terreno no sigue una distribución normal, fundamentalmente en cuanto a los valores de intensidad influenciados por múltiple factores (Donoghue et al., 2007), bien porque no hay puntos suficientes (Bartels y Wei, 2010). Por otro lado, Maguya et al. (2013) sostiene que el terreno está compuesto por una sucesión de zonas llanas y abruptas. Por tanto, puede dividirse y en función de la complejidad de cada parte y emplear el modelo de ajuste más apropiado (en su caso, de menor a mayor complejidad: lineal, cuadrático o spline cúbica). Si bien ofrece buenos resultados en zonas forestales con elevada pendiente, este método presenta como principales limitaciones el elevado volumen de cálculo; sensibilidad a variaciones del tamaño de las particiones; ocurrencia de errores en zonas con pocos datos, y en los bordes de las divisiones entre particiones, pues el filtrado se realiza sin solape entre ellas.

Se incluyen también en esta categoría los métodos *machining-learning* como el basado en *artificial neural networks* (ANN) de Jahromi et al. (2011) o el *conditional random field* (CRF) propuesto por Lu et al. (2009). Este último, a diferencia de los CRF clásicos que emplean variables discretas para generar y entrenar el modelo, usa variables continuas como la elevación. Aunque obtienen muy buenos resultados, la aplicación de este tipo de métodos implica una elevada carga de trabajo manual pues para entrenar el modelo es necesario disponer de un conjunto de muestras independientes y representativas tanto del terreno como de los objetos (Guan et al., 2014).

Por otro lado, debido al elevado volumen de cálculo requerido por

los algoritmos que emplean la nube de puntos bruta, otros autores optan por rasterizar los datos y cambiar la ventana bidimensional de análisis, insensible a cambios de elevación a pequeña escala (por ejemplo, la producida por vegetación arbustiva, coches o pequeños muros) por técnicas basadas en un escaneo direccional, que aunque pueden ocasionar líneas artificiales transversales al terreno u objetos resultan efectivas en la detección de pequeños objetos (Meng et al., 2009). Así, estos métodos calculan diferencias de elevación o pendiente a lo largo de una línea de escaneo en una dirección específica sobre los datos rasterizados. De tal forma que se crea un perfil para cada línea de escaneo y se identifican los puntos terreno a lo largo de dicho perfil. Puesto que los métodos de escaneo direccional son sensibles a superficies que presentan patrones en diferentes direcciones a lo largo de una misma línea de escaneo, Shan y Aparajithan (2005) desarrollaron un algoritmo bidireccional para mitigar este problema. Sin embargo no le sacaron el máximo provecho a la información derivada del análisis de vecindad pues ésta se definió sólo en una dimensión (a lo largo de la línea de escaneo).

Por su parte, Meng et al. (2009) extendió este método adoptando una estrategia multi-direccional (MGF - *Multi-directional Ground Filtering*) en la que se integra el método de ventana bidimensional con el escaneo direccional para aprovechar las ventajas de ambos métodos. Los criterios en los que se basaron para identificar los puntos terreno fueron la pendiente medida como máximo en 4 direcciones; diferencia de elevación entre cada punto y el punto terreno más próximo (punto semilla) y la diferencia de elevación entre cada punto y la elevación mínima en una vecindad local. Aunque se mostró efectivo en zonas urbanas, en las que presenta la ventaja de que su buen funcionamiento es independiente del tamaño y forma de los objetos; no fue así en las zonas rurales, donde los mayores errores se localizaron en las crestas de las montañas o bordes de barrancos o en el filtrado de vegetación baja en zonas de elevada pendiente. Este último error pudo verse agravado por la necesidad de emplear umbrales altos de elevación y pendiente (de media 2 m y 40°, respectivamente) para minimizar los errores de omisión en estas zonas. Por último, el algoritmo fallará en el caso particular de que un puente se disponga en paralelo a la última dirección de exploración.

Posteriormente, Guan et al. (2014) desarrollaron un algoritmo

basado en un análisis *Cross-Section-Plane* (CSP), que al igual que el método anterior, emplea una estrategia multi-direccional sobre los datos rasterizados. Además de las variables elevación y pendiente también emplea los valores de intensidad para identificar potenciales puntos terreno. Aunque mejoran los resultados de [Meng et al. \(2009\)](#) en zonas rurales, este tipo de filtros siguen siendo sensibles al valor que se le asigna a los umbrales de elevación y pendiente.

A diferencia de los filtros citados hasta el momento, otros algoritmos híbridos surgen de filtros existentes, modificados para mitigar alguna de sus limitaciones. Las principales modificaciones se basan en combinar varios de los métodos incluidos en alguna de las categorías anteriores o en incluir algún proceso complementario. Algunos autores combinaron filtros morfológicos con otro tipo de filtros ([Silván-Cárdenas y Wang, 2006](#), [Kobler et al., 2007](#), [Shao y Chen, 2008](#), [Susaki, 2012](#)) mientras que otros vincularon un proceso de segmentación con un método de densificación ([Feng et al., 2009](#), [Yuan et al., 2009](#)). Como ya se comentó previamente, uno de los métodos de densificación más empleados es el algoritmo PTD de [Axelsson \(2000\)](#). El PTD presenta errores de omisión en terrenos con elevada pendiente y líneas de rotura, o de comisión ante la presencia de objetos pequeños. Para abordar estas limitaciones, [Lin y Zhang \(2014\)](#) mejoraron el método híbrido de [Zhang y Lin \(2013\)](#) combinando el método PTD con una segmentación.

Por otro lado, el filtro de [Lin y Zhang \(2014\)](#) emplea el método de segmentación propuesto por [Tóvári y Pfeifer \(2005\)](#) y se basa en el supuesto de que el terreno puede ser descrito por una superficie suavizada y continua que es posible incluir en un único segmento. Después de segmentar la nube de puntos y descartar aquellos segmentos cuya proporción de múltiples retornos es superior al 50% por considerarlos vegetación, se lleva a cabo una densificación progresiva de los segmentos terreno, donde la unidad de análisis pasa de ser un simple punto a un segmento. Esta combinación permite aumentar el número de puntos semilla, sobre todo en zonas urbanas donde el PTD se ve forzado a emplear un tamaño de malla grande para evitar introducir errores de comisión debido a la presencia de edificaciones de gran tamaño. Así, en este tipo de zonas es habitual obtener buenos resultados, no sólo por el aumento de los puntos semilla sino también debido a las ventajas que

presentan los métodos de segmentación en este tipo de zonas. Si bien su método consiguió uno de los objetivos, reducir los errores de omisión con respecto al método PTD clásico, lo hicieron a costa de aumentar casi el triple los errores de comisión. Estos últimos errores se debieron fundamentalmente a fallos en el filtrado de puentes y rampas. Otros estudios como el de [Yan et al. \(2012\)](#) cambiaron el método PTD por uno basado en la pendiente, dándole más importancia al proceso de segmentación. En este estudio se observó una relación directa entre la densidad de puntos y la precisión del filtrado, de forma que el filtro se mostró más eficaz cuanto mayor era la densidad de puntos.

Finalmente, otros autores optaron por incluir procesos complementarios en algoritmos existentes. Dos claros ejemplos de este tipo de filtros y de la versatilidad de los métodos complementarios son los desarrollados por [Chang \(2010\)](#). En el primero de ellos se combina una segmentación con un proceso de densificación (SMSM - *Segmentation Modeling and Surface Modeling*), mientras que en el segundo se sucede un proceso basado en la pendiente y uno estadístico (SSA - *Slope-based Statistical Algorithm*). Ambos algoritmos son precedidos por un proceso de depurado de la nube de puntos bruta que busca eliminar los puntos que representan la vegetación como paso previo a la selección de los puntos semilla. El método de depurado adopta como supuesto de partida que las zonas con vegetación presentan múltiples retornos frente a las zonas impermeables que únicamente contienen un retorno. Así, es posible diferenciar dos clases: vegetación y no vegetación. A la imagen binaria resultante de esta clasificación se le aplica un filtro morfológico para posteriormente crear una primera superficie de referencia a partir de las celdas clasificadas como no vegetación. Aquellos puntos cuya diferencia de elevación con respecto a la superficie de referencia supere la altura de un coche serán tomados como vegetación y eliminados. La nube de puntos resultante será empleada para la selección de los puntos semilla.

El método de depurado anterior demostró ser muy efectivo para la eliminación de puntos de vegetación, permitiendo reducir la probabilidad de introducir errores de comisión en la nube de puntos semilla sobre todo en zonas forestales. Sin embargo, esta ventaja no se observa en zonas urbanas. Si bien los errores de comisión tienen una influencia negativa en la calidad del modelo final, la magnitud de éstos es mucho mayor si se dan

en zonas urbanas, pues es más probable que la incorrecta clasificación de los puntos tengan lugar en las cubiertas de las edificaciones y no en la vegetación (Lu et al., 2008). Por tanto, en las zonas urbanas no sería posible reducir el tamaño de ventana en la selección de los mínimos locales sin aumentar de forma dramática los errores de comisión. Este método también produce elevados errores de comisión en zonas con vegetación densa (sólo presentan un retorno) mientras que cerca de barrancos (estas zonas presentan múltiples retornos) aumentan los errores de omisión.

También Véga et al. (2012) incluyó en su algoritmo *Sequential Iterative Dual-Filter* (SIDF) un proceso de depurado, pero en su caso, posterior a la selección de los puntos semilla. El filtro SIDF genera una primera superficie de referencia a partir de un conjunto de puntos con elevación mínima seleccionados localmente. A continuación son eliminados iterativamente aquellos puntos fácilmente identificables como puntos objeto. Para ello emplea la diferencia de elevación entre los puntos y la superficie de referencia. A partir de las celdas donde se detectaron los puntos objeto, las que presentan una pendiente elevada y las que tras aplicarle al MDE un filtro local superan un umbral β fijado por el usuario, se crea una máscara y se eliminan los puntos semilla en su interior. A partir de los puntos restantes se crea una nueva superficie de referencia. Para finalizar, a partir de otro proceso iterativo, nuevos puntos son añadidos a la nube de puntos terreno siempre y cuando la diferencia de elevación entre dichos puntos y la última superficie de referencia sea inferior al umbral β . Este algoritmo únicamente se probó en una zona rural, y aunque obtuvo mejores resultados que la mayoría de los algoritmos incluidos en el estudio de Sithole y Vosselman (2004), los elevados errores de comisión provocaron que el Te en estas zonas fuese superior al obtenido por otros algoritmos desarrollados en la misma época (por ejemplo, Shao y Chen (2008) o Chang (2010)). Por otro lado, la apariencia rugosa de la primera superficie de referencia indica la existencia de errores de comisión en la nube de puntos semilla que probablemente se propaguen hasta el modelo final. Tal vez la optimización del tamaño de ventana hubiera ayudado a mitigar estos errores. Por otro lado, la mitad de las fases en la que se estructura este algoritmo son iterativas. Véga et al. (2012) indicaron que el número de repeticiones está directamente relacionado con la estructura de la

vegetación, de manera que cuanto más densa es la vegetación mayor será el número de interacciones que es necesario realizar (entre 4 y 18 repeticiones). Este funcionamiento iterativo tiene mucha influencia en la eficiencia, pues eleva el tiempo de procesado. Finalmente, otro factor que pudo influir en la precisión del filtrado es el método de interpolación. El algoritmo SIDF emplea el método *kriging* para obtener una superficie continua a partir de los puntos clasificados como terreno. Evans y Hudak (2007) concluyó en su estudio que este método era el que peores resultados proporcionaba en comparación con otros tres interpoladores (IDW - *Inverse Distance Weighting*, TIN - *Triangulated Irregular Networks* y TPS - *Thin Plate Spline*), tanto desde el punto de vista del ajuste como del tiempo de procesado. Según estos autores, el interpolador TPS proporciona los mejores resultados. Su empleo en lugar del *kriging* sin duda mejoraría los tiempos de procesado y podría favorecer una reducción de los errores de omisión, puesto que el interpolador empleado tiende a crear superficies erosionadas (Evans y Hudak, 2007).

1.1.2 Fundamentos de los filtros de densificación

Los filtros de densificación inician el proceso de identificación de P_g (*Ground Points*) a partir de una superficie inicial de referencia (en este estudio denominada $\varphi_{t=0}$). Esta superficie puede ser estimada a partir de todos los puntos, caso del *linear prediction-based filter* desarrollado por Kraus y Pfeifer (1998); o empleando una muestra de puntos, generalmente mínimos locales (*Local Lowest Points* - LLP), caso del *adaptive TIN filter* desarrollado por Axelsson (2000). Mediante un proceso iterativo, nuevos puntos se clasifican como P_g teniendo en cuenta las superficies de referencia intermedias obtenidas durante el proceso y el cumplimiento de una serie de condiciones. En la mayoría de los casos, el proceso termina bien cuando no son añadidos más puntos bien cuando se llega a un número máximo de iteraciones establecidas a priori por el usuario. Por tanto, el proceso se puede resumir en dos etapas: 1) obtención de la superficie de referencia inicial y 2) establecimiento del criterio a seguir para la densificación de la nube de puntos terreno.

Con respecto a la primera de ellas, Kraus y Pfeifer (1998) y Lee y Younan (2003) emplearon todos los puntos para generar una superficie de referencia inicial que *flota* entre los puntos, de forma que todos tienen la misma probabilidad de pertenecer al terreno. Esta superficie de referencia la usaron para calcular el residual de los puntos, es decir, la diferencia de elevación que existe entre cada punto y dicha superficie. En base a la idea de que los puntos con residuales positivos tienen menor probabilidad de pertenecer al terreno que aquellos cuyos residuales son negativos, generaron una función de pesos que asignaba los mayores pesos a los puntos con menores residuales, los cuales consideraban deberían tener mayor influencia en la generación de la siguiente superficie. Por el contrario, a los puntos con residuales positivos se les asignan menores pesos, y por tanto tendrán una menor influencia en la *actualización* de la superficie en la siguiente iteración.

Si bien los filtros que tienen en cuenta todos los puntos a la hora de generar la superficie de referencia inicial han sido un referente en este campo, los filtros más recientes se basan en la selección de LLP. La gran mayoría de los estudios abordan esta tarea empleando el método de mínimos locales (LMM- *local minimum method*), es decir, seleccionan los puntos de elevación mínima en un entorno local definido por una ventana cuadrada que o bien se desplaza hasta cubrir toda la zona de estudio (Mongus y Žalik, 2012) o bien forma parte de una malla que se superpone a la nube de puntos (Axelsson, 1999). Este método puede aplicarse sólo una vez al inicio del filtrado (Axelsson, 1999) o en los diferentes niveles de una pirámide de datos bien mediante un enfoque *bottom-up* (Mongus y Žalik, 2012) bien *top-down* (Chen et al., 2013, Hu et al., 2014). Sin embargo, la presencia de *low outliers* invalida el supuesto de que los puntos con menor elevación en un entorno local son los candidatos más adecuados para ser considerados como LLP (Mongus y Žalik, 2012). Para evitar este tipo de errores, Chen et al. (2012b) modificó el LMM para eliminar automáticamente los *low outliers*. Para ello calcula la diferencia de elevación entre los dos puntos con menor elevación en un entorno local. Si esta diferencia es inferior a un umbral, ambos puntos son considerados como LLP, en caso contrario, el de menor elevación es descartado. A continuación, siguiendo el mismo proceso se compara el punto con la segunda menor elevación con el tercero menos elevado.

Aunque la estrategia anterior es válida, lo más habitual es detectar y eliminar los *low outliers* antes de la selección de los LLP. Entre los métodos más usados destacan el análisis del histograma de elevaciones para determinar los umbrales de elevación a partir de los cuales un punto es considerado *outlier* (Zhang y Lin, 2013); filtros de eliminación estadística basados en la elevación como el que se encuentra implementado en el programa FUSION (McGaughey, 2010), el usado por Feng et al. (2009) o por Chang (2010); mediante operadores morfológicos (Mongus y Žalik, 2012); métodos de eliminación radial en base a diferencias de pendiente (Jahromi et al., 2011) o número de puntos vecinos (Hu et al., 2014) o incluso combinaciones de los anteriores con métodos manuales (Lin y Zhang, 2014). Todos estos métodos operan a nivel punto, sin embargo también es posible realizar esta operación a nivel pixel, rasterizando la nube de puntos y analizando la desviación de elevación entre cada píxel y sus vecinos (Seo y O'Hara, 2008).

En referencia a la segunda etapa, en general la nube de puntos terreno es densificada con aquellos puntos *no clasificados* cuya diferencia de altura con respecto a una superficie de referencia es inferior a cierto umbral. Se diferencian aquí dos puntos clave que han sido abordados de muy diversas formas por los desarrolladores de *interpolation-based filters*. En primer lugar se encuentra la asignación de un umbral máximo permitido, de manera que es posible establecer un umbral único para toda la zona, que puede (Chen et al., 2013) o no (Kraus y Pfeifer, 1998, Lee y Younan, 2003) ser modificado en cada iteración; o bien establecer umbrales específicos para diferentes regiones de la zona de estudio en función de las características del terreno (Hu et al., 2014). En segundo lugar es necesario fijar un criterio para cumplir con dicho umbral, que generalmente se basa en calcular la diferencia de elevación que hay entre el punto analizado, la celda de la superficie de referencia donde el punto es localizado y las 8 celdas vecinas a dicha celda. Así, si cierto número de los 9 residuales calculados se encuentra por debajo del umbral establecido, ese punto será considerado terreno. En el caso de Chen et al. (2013) estableció un límite de 4, mientras que Hu et al. (2014) lo limitó en 5.

Finalmente, la elección del método de interpolación que se usará para transformar la nube de puntos terreno en una superficie continua en cada

iteración se debe incluir en la lista de factores que es necesario tener en cuenta a la hora de desarrollar un algoritmo de filtrado. La elección del método más adecuado requiere tener en cuenta aspectos como la exactitud, densidad y distribución de los datos o el nivel de precisión final requerido (Maguya et al., 2013). Evans y Hudak (2007) evaluaron cómo el método de interpolación empleado en el filtro MCC (*Multiscale Curvature Classification*) influía en la calidad final del filtrado. En su análisis emplearon 4 métodos de interpolación: Kriging ordinario, IDW (*Inverse Distance Weighting*), TIN (*Triangulated Irregular Networks*) y TPS (*Thin Plate Spline*). Estos autores concluyeron que el método de interpolación TPS reporta el MDT más preciso. Posterior a este trabajo, algunos autores en estudios similares también optaron por emplear como interpolador el método TPS (Mongus y Žalik, 2012, Chen et al., 2013, Hu et al., 2014).

En la Tabla 1.1 se incluyen las principales características (filtro, método empleado para iniciar el algoritmo, variable y criterio empleados en la fase de densificación y método de finalización del algoritmo) de una selección de *interpolation-based filters* desarrollados hasta el momento.

Tabla 1.1: Características de los filtros de densificación.

Filtro	Método de iniciación	Variable usada en la densificación	Criterio de densificación e interpolador	El algoritmo finaliza cuando ...
Kraus y Pfeifer (1998)	Estimación de $\varphi_{t=0}$ a partir de todos los puntos.	Residuales.	Función de pesos. Iterativo.	No se añaden más puntos al $\varphi_{t=n}$ o se llega a un n° máximo de iteraciones.
Axelsson (2001)	<i>Ground seeds</i> : mínimos locales en celdas de tamaño establecido por el usuario.	Ángulo y distancia al TIN.	Umbrales establecidos por el usuario. Iterativo. TIN.	No se añaden más puntos al $\varphi_{t=n}$.
Haugerud y Harding (2001)	Estimación de $\varphi_{t=0}$ a partir de todos los puntos.	Curvatura local.	Umbrales establecidos por el usuario. Iterativo. TIN.	El n° de puntos clasificados como P_g es inferior al 0.1% de los retornos clasificados como P_{ng} .
Sohn y Dowman (2002)	<i>Ground seeds</i> : emplea un método <i>downtward</i> para seleccionar mínimos en el interior de los triángulo de un TIN.	Distancia y ángulos.	Empleo de un método <i>upward</i> , generando un <i>buffer</i> por encima de los triángulos de la etapa anterior y analizando los puntos en su interior. Iterativo. TIN.	No quedan puntos que analizar.
Lee y Youman (2003)	Estimación de $\varphi_{t=0}$ a partir de todos los puntos.	Residuales.	Función de pesos. Iterativo. Media ponderada de los valores de elevación en cada celda.	El valor del <i>penetrating rate</i> es inferior a un umbral establecido por el usuario.
Evans y Hudak (2007)	Estimación de $\varphi_{t=0}$ a partir de todos los puntos.	Curvatura local.	Umbrales establecidos por el usuario que varían automáticamente en cada iteración. Multi-escala e iterativo. TPS.	Estructurado en tres escalas. Se pasa de una escala a otra cuando el n° de puntos clasificados como P_g es inferior al 0.1% de los clasificados como P_{ng} .

continúa en la página siguiente

Tabla 1.1 – Características de los filtros de densificación (continuación).

Filtro	Método de iniciación	Variable usada en la densificación	Criterio de densificación e interpolador	El algoritmo finaliza cuando ...
Kobler et al. (2007)	Reducción de la nube de puntos original empleando un filtro basado en la pendiente entre puntos vecinos.	Distribución de elevaciones.	Estimaciones independientes del relieve a partir de una muestra de puntos. No iterativo. TIN.	No tiene.
Chen et al. (2013)	<i>Ground seeds</i> : Variante del método de mínimos locales con ventana móvil.	Residuales.	Umbral inicial establecido por el usuario que varía automáticamente en cada iteración. Multi-escala e iterativo. TPS.	No se añaden más puntos al $\varphi_{t=n}$.
Zhang y Lin (2013)	<i>Ground seeds</i> : Mínimos locales a partir de una malla de celdas cuadradas.	Residual al plano de ajuste para calcular la normal, nº de vecinos y ángulo entre un LLP y un potencial P_g .	Empleo del método de segmentación <i>surface growing method</i> . Iterativo. TIN.	No se añaden más puntos al $\varphi_{t=n}$.
Hu et al. (2014)	<i>Ground seeds</i> : Mínimos locales a partir de una ventana móvil.	Residuales.	Umbral inicial establecido por el usuario que varía con las características del terreno y se actualiza en cada iteración. Multi-escala e iterativo. TPS.	Nº de puntos añadidos < a cierto umbral.

1.1.3 El problema desde el punto de vista del usuario

Después de la descripción anterior y en relación al procesado de los datos LiDAR y la obtención de un MDT, una de las decisiones más importantes a las que se enfrenta el usuario sigue siendo la selección del filtro que mejor se adapte a sus necesidades (Korzeniowska y Lacka, 2011). Los nuevos usuarios de datos LiDAR y técnicas de filtrado generalmente se encuentran con serias dificultades para seleccionar el algoritmo más apropiado. Algunos estudios han abordado este problema identificando los factores que afectan a la precisión de los MDT (Sithole, 2002, Hodgson et al., 2005) y han profundizado en las características del terreno que influyen en el funcionamiento de los algoritmos de filtrado, comparando varios de estos filtros y posteriormente analizando la calidad de los MDT resultantes (Sithole y Vosselman, 2004, Meng et al., 2010). Como ya se ha mencionado, la gran mayoría de los algoritmos logran buenos resultados en zonas poco complejas como son las áreas de baja pendiente, con cobertura homogénea y con elevada densidad de puntos LiDAR. En el lado opuesto se encuentran los resultados obtenidos por otros estudios donde se concluye que muchos de los algoritmos desarrollados tienen dificultades para procesar zonas donde bien la densidad de puntos LiDAR bien la proporción de puntos terreno es baja (Sithole y Vosselman, 2004); donde el terreno presenta cambios bruscos de pendiente y se suceden zonas relativamente llanas con áreas de elevada pendiente (Susaki, 2012), enfatizando en este caso el hecho de que la pendiente del terreno es la característica que ejerce mayor influencia en el resultado del proceso de filtrado (Hu et al., 2014); en zonas forestales con vegetación mixta (en relación a la especie y madurez) (González-Ferreiro et al., 2013a, Maguya et al., 2013); o en zonas urbanas con edificios que presentan diversidad de formas y tamaños, pequeños objetos (coches y mobiliario urbano), rampas, escaleras, patios y vegetación (Feng et al., 2009).

A la vista de lo expuesto esta decisión no es sencilla pues obliga al usuario a poseer un elevado grado de conocimiento del funcionamiento de los diferentes filtros. Tal decisión se complica aún más debido a que este conocimiento es difícil de adquirir pues en la mayoría de los casos todos estos avances se encuentran separados del usuario por el muro de

la *usabilidad*¹ (facilidad de uso) y accesibilidad (posibilidad de acceso). Estos obstáculos se ven alimentados por el hecho de que la mayoría de los detalles de los algoritmos de filtrado son celosamente salvaguardados por sus creador@s (Zhang y Lin, 2013) y no se incluyen en sus publicaciones; al igual que tampoco se llevan a cabo análisis sobre la influencia de los diferentes parámetros en el resultado final y para terminar, aquellos que acaban incluidos en programas comerciales se convierten en *cajas negras* que operan sobre los datos.

Suponiendo que el usuario pase la prueba de seleccionar el algoritmo de filtrado, éste debe enfrentarse a una nueva prueba, la selección de los valores de los parámetros que minimicen los errores del filtrado. Hace más de una década, Sithole y Vosselman (2004) concluyeron en su estudio que sería ideal poder determinar automáticamente las características del entorno y usarlas para seleccionar el mejor algoritmo de filtrado con sus parámetros óptimos. La tendencia actual en el desarrollo de estos métodos se basa parcialmente en esta idea, ya que los nuevos filtros reconocen alguna de las características del terreno y modifican automáticamente alguno de sus parámetros, mayoritariamente en función de la variación de la pendiente (Hu et al., 2014), adaptándose y proporcionando así buenos resultados en diferentes tipos de entornos sin necesidad de cambiar de filtro. Sin embargo, esta tendencia no se encuentra completamente consolidada y se hace necesario abordar este problema no sólo teniendo en cuenta características topográficas, como la pendiente, sino también otros factores como son la cobertura, la densidad de puntos o la estructura de la vegetación. Así, la independencia total del usuario por ahora no es posible, y la elección de los parámetros óptimos de filtrado para una determinada zona de estudio, uno de los más importantes objetivos de cara a la obtención de la máxima eficiencia y efectividad en el filtrado (Susaki, 2012), sigue siendo otra de las dificultades a las que es necesario hacer frente en este proceso.

¹Según ISO 9241-11 (1998) *usabilidad* es el grado de eficacia, eficiencia y satisfacción con la que los usuarios pueden lograr objetivos específicos en contextos de uso particular. En nuestro caso, cuando se habla de *usabilidad* nos estamos refiriendo únicamente a su atributo subjetivo: la satisfacción (Hassan et al., 2004).

1.1.4 Solución propuesta: **DTMofLabTe**

Resulta obvio que los aspectos anteriores dificultan enormemente la tarea de comprender el funcionamiento de los filtros y consecuentemente la selección de los valores de los parámetros que permitan obtener resultados adaptados a las necesidades del usuario. En una sociedad que avanza hacia la democratización real de la información y los procesos colaborativos, el uso de estas herramientas todavía se encuentra limitado a unos pocos. Por tanto, es evidente que l@s creador@s de filtros, además de centrar nuestros esfuerzos en mejorar la efectividad y la eficiencia, deberíamos ponernos del lado del usuario, la *usabilidad* y la accesibilidad, y desarrollar algoritmos y herramientas que faciliten la obtención de soluciones en este campo. Así, en este estudio se presenta **DTMofLabTe** (*Digital Terrain Model using Overlap Filter - LaboraTe*), un nuevo algoritmo de filtrado implementado en el programa libre R ([R Development Core Team, 2010](#)).

Además de pretender responder alguna de las necesidades de los usuarios, desde el punto de vista de la efectividad se encuentra orientado a reducir los errores de comisión en la selección de puntos semilla en zonas urbanas. Este algoritmo sigue el esquema general de la mayoría de los filtros de densificación desarrollados hasta el momento, pero tomando también como referente los métodos híbridos que incluyen un proceso de depurado en su planteamiento. Así, se diferencia de los algoritmos previos en varios puntos: 1) está formado por un conjunto de funciones implementadas en R que operan secuencialmente (el *output* de la primera es el *input* de la segunda ...) pero con capacidad para funcionar de manera independiente, lo que haría posible su integración con otros algoritmos de filtrado; 2) se define y emplea la variable penetrabilidad, que junto con las variables elevación y pendiente se usarán en diferentes puntos del proceso de filtrado; 3) previamente a la selección de los puntos semilla, se incluye un proceso de depurado de la nube de puntos original orientado a la eliminación de los P_{ng} (*non-Ground Points*) de las edificaciones permitiendo disminuir el tamaño de ventana en la selección de los puntos semilla a la vez que se disminuyen los errores de comisión en dicha selección; 4) los puntos semilla se seleccionan mediante un nuevo método que emplea una ventana móvil con solape longitudinal

entre ventanas y transversal entre *pasadas*.

La estructura que presenta este capítulo es la siguiente: en el apartado 1.2 se incluye la descripción de los datos empleados (sección 1.2.1); una descripción detallada del algoritmo **DTMofLabTe** (sección 1.2.3); y por último se describen los estadísticos empleados en la evaluación cuantitativa de los resultados (sección 1.2.4). El apartado de resultados (apartado 1.3) se divide en dos secciones. En la primera se incluye la evaluación interna del algoritmo (sección 1.3.2) detallando el proceso seguido para optimizar los valores de los parámetros variables (sección 1.3.1); la efectividad del proceso de depurado (sección 1.3.2.1); impacto del nuevo método de selección de puntos semilla (sección 1.3.2.2) y modificaciones de los valores de los parámetros variables (sección 1.3.2.3) en la precisión del filtrado. En la segunda sección (sección 1.3.3) se incluye la evaluación externa del algoritmo empleando los datos LiDAR de referencia de la *International Society of Photogrammetry and Remote Sensing* (sección 1.3.3.1) y se comparan estos resultados con los obtenidos en 23 estudios previos (sección 1.3.3.2). En el apartado 1.4 se incluyen las principales conclusiones que se desprenden de este estudio. En el CD adjunto se incluyen los anexos con los resultados cuantitativos y cualitativos complementarios así como los enlaces a las gráficas *online*.

1.2 Material y métodos

1.2.1 Datos ISPRS

Para evaluar el algoritmo **DTMofLabTe** se emplearon los datos LiDAR de referencia de la *International Society of Photogrammetry and Remote Sensing (ISPRS Commission III, the Working Group III/3 "3D Reconstruction from Airborne Laser Scanner and InSAR Data")*. Estos datos fueron capturados por un escáner Optech ALTM en la ciudad de Stuttgart y en una zona rural en el sur de Alemania (libre descarga en la web: <http://www.itc.nl/isprswgIII-3/filtertest/>).

Se dispone de 7 grupos de datos de áreas con diferentes característi-

cas, de los cuales 4 se corresponden con entornos urbanos (*Sites 1-4*) y 3 con zonas rurales (*Sites 5-7*). Dentro de estas zonas se delimitaron un total de 15 áreas de referencia. En cada una de ellas, combinando técnicas de filtrado automáticas y manuales, los puntos LiDAR se clasificaron como *terreno* (P_g - *ground points* - codificado como 0) y *no-terreno* (P_{ng} - *non-ground points* - codificado como 1). Si bien la definición de lo que es terreno es subjetiva, en este caso se definió como la capa superior del suelo o cualquier estratificación delgada que lo cubre (p. ej. pavimento). Dentro de esta clase no se han incluido ni los puentes ni las pasarelas, pero sí las rampas y los patios. En los archivos, cada registro incluye las coordenadas X, Y, Z seguidas del código que clasifica los puntos en terreno (0) y no-terreno (1) (Vosselman, 2003).

Para evitar errores durante el proceso de filtrado, los *low outliers* (debidos fundamentalmente al efecto *multi-path* o errores en el registro) fueron identificados y eliminados de las nubes de puntos combinando el método de umbrales con un método de eliminación radial (Meng et al., 2010, Hu et al., 2014). En la Tabla 1.2 se indican algunas de las características de las zonas de análisis y de los datos LiDAR. En las celdas de las columnas P_g y P_{ng} se especifica el número de puntos terreno y no-terreno originales antes de la eliminación de los *outliers*. El número de *outliers* se indica entre paréntesis. Adicionalmente, en dicha tabla también se incluye la proporción de P_g en relación a los P_{ng} , la densidad media de puntos y los valores de pendiente de las diferentes muestras, representados por la media y el percentil del 90%. Los valores de pendiente que se obtuvieron a partir de un modelo generado con los P_g de las muestras de referencia. En este estudio, P representa la nube de puntos libre de *outliers*.

Tabla 1.2: Características de las zonas de análisis y los datos LiDAR

Muestra	Características	Puntos		$\frac{P_g}{P_{ng}}$	Densidad ptos/m ²	Pendiente (%)	
		P_g (outliers)	P_{ng} (outliers)			Media	Q90
Muestra 11	Urb. Vegetación y edificios en pendiente elevada.	21786 (9)	16224 (13)	1.3	0.93	53.8	100.0
Muestra 12	Urb. Edificios y coches.	26691 (37)	25428 (35)	1.0	0.95	11.9	26.8
Muestra 21	Urb. Vegetación y edificios en pendiente elevada.	10085 (0)	2875 (0)	3.5	0.89	7.5	17.2
Muestra 22	Urb. Puentes y pasarela.	22504 (6)	10202 (17)	2.2	0.96	16.4	43.9
Muestra 23	Urb. Grandes edificios y discontinuidades del terreno.	13223 (0)	11872 (1)	1.1	0.82	24.2	60.4
Muestra 24	Urb. Rampa.	5434 (30)	2059 (1)	2.6	0.83	24.1	57.0
Muestra 31	Urb. Grandes edificios.	15556 (2)	13306 (14)	1.2	1.01	4.6	9.2
Muestra 41	Urb. Outliers (efecto multi-path).	5602 (0)	5629 (116)	1.0	0.63	12.8	28.2
Muestra 42	Urb. Estación de tren.	12443 (0)	30027 (2)	0.4	0.91	6.8	15.5
Muestra 51	Rur. Vegetación en pendiente.	13950 (0)	3895 (0)	3.6	0.18	18.9	56.2
Muestra 52	Rur. Pendiente.	20112 (0)	2362 (0)	8.5	0.17	33.3	78.2
Muestra 53	Rur. Terreno discontinuo.	32989 (0)	1389 (0)	23.8	0.17	39.2	78.3
Muestra 54	Rur. Edificios de baja resolución.	3983 (0)	4625 (5)	0.9	0.17	11.7	23.8
Muestra 61	Rur. Bordes agudos y zanjas.	33854 (0)	1206 (0)	28.1	0.17	16.3	40.2
Muestra 71	Rur. Puente y terreno discontinuo.	13875 (0)	1770 (0)	7.8	0.18	15.0	45.4

1.2.2 ¿Qué puntos pertenecen al terreno?

El proceso de filtrado tiene como objetivo identificar en la nube de puntos LiDAR aquellos puntos que representan el terreno. Generalmente esta identificación se basa en diferentes supuestos. Por ejemplo, los filtros que implican selección de puntos semilla asumen que en un entorno local los puntos con menor elevación pertenecen al terreno; aquellos que introducen un proceso de densificación en base a una superficie continua admiten que los puntos por debajo o más próximos a esta superficie tienen mayor probabilidad de pertenecer al terreno que aquellos más distantes; los filtros basados en la pendiente aceptan que los mayores cambios de pendiente entre dos puntos se dan cuando por lo menos uno de ellos pertenece al terreno; los que implican un proceso de segmentación admiten que los puntos en el interior de bordes cerrados no pertenecen al terreno,... No obstante, la validez de estas suposiciones no es universal, pues dependerá de las características del entorno a filtrar. Por tanto, para determinar dichos puntos y como paso previo al establecimiento de los supuestos sobre los que se apoyará el algoritmo de filtrado, es necesario definir que se entiende por terreno.

En el mundo real podemos distinguir sin ningún tipo de duda entre lo que es terreno y lo que no. Sin embargo, en una nube de puntos LiDAR esta tarea es mucho más compleja (Sithole, 2005). Así, tal y como afirmaba Sithole y Vosselman (2004) la decisión de qué es o no terreno es puramente subjetiva. Debido a que los datos de referencia usados en este estudio son los proporcionados por el ISPRS, la definición de terreno adoptada es la establecida en Sithole y Vosselman (2004). Así, de manera simplificada estos autores consideran que el mundo real se compone de dos elementos: terreno y objetos. De esta forma, se considera terreno la parte superior del suelo en la que se incluyen tanto aquellas coberturas artificiales (asfalto, patios o rampas), como las naturales (hierba o vegetación baja). Por otro lado, se consideran objetos tanto elementos artificiales (edificios, coches, puentes o pasos elevados) como naturales (vegetación arbustiva o arbolada).

1.2.3 Principios del filtro **DTMofLabTe**

DTMofLabTe ha sido implementado en el programa libre R ([R Development Core Team, 2010](#)) en un intento de responder al desafío de la *usabilidad* y accesibilidad al que se enfrentan los usuarios a la hora de emplear estas herramientas. Se trata de un algoritmo híbrido que toma como referencia el esquema de funcionamiento de los filtros de densificación. Sin embargo, presenta cuatro diferencias fundamentales con respecto a dichos filtros. Como primer punto distintivo, este algoritmo está formado por un conjunto de funciones que operan secuencialmente (el *output* de la primera es el *input* de la segunda ...) pero con capacidad para funcionar de manera independiente, lo que haría posible la integración de sus funciones a nivel individual como complemento de otros algoritmos de filtrado (en el Anexo [A.2](#) se incluye una demostración de su integración con otro filtro). Por otro lado, además de usar las variables elevación y pendiente para identificar los LLP, se define y emplea la variable penetrabilidad. Finalmente, las dos diferencias restantes se basan en dos supuestos: 1) los puntos con elevación mínima seleccionados localmente (LLP) son suficientes para definir las principales características del terreno y generar una primera superficie de referencia que lo defina; y 2) cualquier modificación en la creación de dicha superficie puede repercutir significativamente en el resultado final ([Pingel et al., 2013](#)).

En base a los supuestos anteriores, en este estudio se han destinado muchos esfuerzos a intentar mejorar el proceso de selección de los LLP. En primer lugar, de forma similar al planteamiento realizado por [Chang \(2010\)](#) y [Véga et al. \(2012\)](#) y como paso previo a la selección de los LLP, se incluye un proceso de depurado de la nube de puntos original orientado a la eliminación de los P_{ng} que se corresponden con edificaciones y vegetación. Este paso permite disminuir el tamaño de ventana en la selección de puntos semilla aumentando el número de puntos seleccionados sin aumentar los errores de comisión. De esta forma, en zonas urbanas podrían definirse mejor las rampas o patios interiores de edificaciones y evitar seleccionar puntos de edificaciones como LLP; mientras que en las zonas rurales se identificarían las discontinuidades del terreno donde éste se encuentra a diferentes alturas. En segundo

lugar, y como última diferencia, se desarrolló un método para seleccionar los LLP que emplea una ventana móvil cuyo desplazamiento se realiza con solape longitudinal entre ventanas y transversal entre *pasadas*.

1.2.3.1 Descripción de los parámetros de filtrado.

Los parámetros de **DTMofLabTe** pueden agruparse en tres categorías: fijos, aquellos que permanecen constantes para todas las áreas de estudio; variables, establecidos por el usuario en función de las características de la zona a filtrar; y automáticos, cuyos valores se fijan automáticamente durante el filtrado. En la Tabla 1.3 se incluye una breve descripción de todos estos parámetros.

1.2.3.2 Descripción de las funciones.

Tal y como se mencionó previamente, **DTMofLabTe** está formado por un conjunto de funciones que operan secuencialmente. Se incluye aquí la función **PNT**, a partir de la cual se obtiene un ráster con porcentajes de penetrabilidad; la función **OWM** (*Overlap Window Method*) para la selección de puntos semilla y la función **DebCloud** para el depurado de la nube de puntos original. A continuación se describe cada una de estas funciones.

La función OWM. El método LMM (*Local Minimum Method*) es uno de los más populares para la selección de puntos semilla (P_S) debido a su simplicidad y eficiencia. La principal limitación que presenta es la selección del tamaño de ventana, pues debe ser lo suficientemente grande como para minimizar la influencia de los P_{ng} y lo suficientemente pequeño para conservar las características del relieve (Chen et al., 2013). En zonas llanas sin grandes edificaciones, el tamaño de ventana no tendrá gran influencia en los resultados del filtrado, sin embargo se debe prestar especial atención al valor de este parámetro en zonas complejas donde coexisten edificaciones con una orografía compleja. En este último caso, el tamaño de ventana requerido para minimizar la influencia de los P_{ng} será demasiado grande como para preservar muchos de los detalles del

Tabla 1.3: Descripción de los parámetros de **DTMofLabTe**.

P. Fijos	<p>Número óptimo de puntos. np es el número medio de puntos por celda que se consideran necesarios para calcular la penetrabilidad. El valor por defecto es de 10 puntos.</p> <p>Solape longitudinal y transversal. FO (<i>Forward Overlap</i>) y LO (<i>Lateral Overlap</i>) representan el porcentaje de solape longitudinal y transversal (en tanto por uno) entre las ventanas de selección de los puntos semilla en su desplazamiento a través de la nube de puntos. El valor por defecto es 0.8.</p> <p>Resolución de los modelos intermedios en formato ráster. C_R es el tamaño de píxel de los modelos ráster intermedios que son generados en la fase de densificación a partir de los puntos identificados como P_g en cada iteración. El valor por defecto es 1 m.</p> <p>Número máximo de iteraciones. I es el número máximo de repeticiones del proceso de densificación. El proceso terminará en el momento que no se clasifiquen nuevos puntos como P_g o se hayan realizado I iteraciones. El valor por defecto es 6.</p>
P. Variables	<p>Tamaño máximo del área sin puntos terreno. C se fija en función del lado de menor longitud de la mayor edificación presente en la zona de estudio. En zonas forestales con vegetación densa, donde el rayo láser no penetra a través de la vegetación y por tanto no llega al suelo, se identifica con la mayor distancia entre dos puntos terreno.</p> <p>Tamaño de la ventana para la selección de puntos semilla. C_S es el tamaño de la ventana móvil con solape para la selección de los P_S.</p> <p>Residual. δ_h es la distancia máxima permitida entre los puntos y la superficie del terreno para considerar que un punto es P_g.</p>
P. Automáticos	<p>Tamaño óptimo de celda. C_O es el tamaño de la celda cuadrada que contiene de media np puntos. Se obtiene a partir de la raíz cuadrada del cociente entre np y la densidad media ponderada de puntos (D).</p> <p>Umbral mínimo y máximo de pendiente. Sl_{min} y Sl_{max}. Algunos autores (Zhang y Lin, 2013) emplearon percentiles específicos para asignarle automáticamente un valor a determinados parámetros durante el proceso de filtrado, lo que permitía ajustar dicho parámetro a las características específicas que presenta cada área de estudio. En este caso, a partir de los valores de las celdas de un ráster de pendiente (φ_{slope}) se usa el percentil del 65% para fijar el valor del parámetro Sl_{min} y el percentil del 90% para fijar el del parámetro Sl_{max} (en el apartado 1.2.3.2 se describe el proceso para obtener el ráster de pendientes).</p>

relieve. Por otro lado, en zonas forestales complejas (superficies con diferentes densidades de vegetación en terreno con elevada pendiente), no será necesario usar un tamaño de ventana tan grande como en el caso anterior, pero tampoco lo suficientemente pequeño como para obtener

una representación del terreno con un elevado grado de detalle, pues las zonas con vegetación densa producen efectos negativos similares a los de las edificaciones. A fin de mitigar estas limitaciones se desarrolla la función **OWM**. Esta función está definida por 5 argumentos: datos de entrada (*Point Cloud*), tamaño de ventana para la selección de los LLP (w), tamaño de malla para la identificación de zonas sin LLP (W), solape longitudinal (O_F) y transversal (O_L) entre ventanas (en tanto por uno). El esquema de funcionamiento y el pseudo-código de esta función se incluyen en las Figuras 1.3 y 1.4, respectivamente. Los detalles de cómo opera son descritos a continuación.




Figura 1.3: Proceso de selección de LLP empleando la función **OWM**.

Esta función se inicia definiendo el ámbito de extracción de los LLP. Para ello, se identifican los valores máximos y mínimos de las coordenadas X e Y (x_{max} , x_{min} , y_{max} , y_{min}) a partir de *Point Cloud*. Para evitar el efecto borde en la selección de los LLP, la extensión de esta área se amplía aplicando un buffer exterior de magnitud $w \cdot O_F$ en el eje X y $w \cdot O_L$ en el eje Y. Así, las coordenadas de la esquina superior derecha (*top right corner* - TRC) son $x_{TRC} = x_{max} + w \cdot O_F$ y $y_{TRC} = y_{max} + w \cdot O_L$, mientras que las de la esquina inferior izquierda (*bottom left corner* - BLC) son $x_{BLC} = x_{min} - w \cdot O_F$ y $y_{BLC} = y_{min} - w \cdot O_L$. A continuación una ventana móvil de tamaño w se desplaza desde BLC siguiendo la dirección del eje X con un solape entre ventanas consecutivas de magnitud $w \cdot O_F$. Finalizada la primera *pasada*, la ventana w vuelve al extremo izquierdo e inicia una nueva *pasada*, cuyo origen se encuentra desplazado $w \cdot O_L$ en Y con respecto a la primera *pasada*. El proceso se repite hasta que la ventana w llega a la TRC (Figura 1.3a). En cada posición de dicha ventana se selecciona el punto con menor elevación, dando como resultado una colección de LLP.

Como consecuencia del solape entre ventanas, un mismo punto pudo ser seleccionado varias veces. De forma lógica, cuantas más veces un punto es seleccionado mayor será la probabilidad de que dicho punto sea P_g . Así, los puntos seleccionados más de una vez son los que finalmente se consideran LLP (Figura 1.3b). Sin embargo, se observó que en zonas con elevada pendiente es difícil que un mismo punto sea identificado como LLP más de una vez, ocasionando que la nube de puntos resultante presente zonas sin datos. Para mitigar esta falta de detalle, se superpone una malla de celdas cuadradas de tamaño W a la nube de puntos LLP (Figura 1.3c). En aquellas celdas donde no existan puntos se seleccionará el punto con menor elevación a partir de *Point Cloud* (Figura 1.3d) y será añadido a la nube de LLP final (Figura 1.3e).

Como ya se mencionó anteriormente, muchos de los algoritmos de filtrado que incluyen la selección de puntos semilla lo hacen mediante el método de mínimos locales (LMM). Como observación, resaltar que la función **OWM** puede funcionar como LMM si se establecen solapes por valor de 0.

La función PNT. En este estudio, la penetrabilidad se define como el porcentaje de P_g con respecto al número total de puntos. Para calcular esta variable se desarrolló la función **PNT** (Figura 1.5). Dicha función está definida por 4 argumentos: datos de entrada (*Point Cloud*), superficie terreno de referencia (φ), tamaño de malla (W) y residual a partir del cual un punto es considerado objeto (δ). Inicialmente se

Función OWM. Selección de LLP

Inputs: Point Cloud = $\{P\}$, tamaño ventana w , tamaño de malla zona sin LLP W , solape longitudinal O_L y transversal O_T

Definir una ventana cuadrada, tamaño= $w \rightarrow W_{LLP}$

Fijar ámbito geográfico de extracción a partir de $\{P\} \rightarrow \text{TRC}=(x_{\text{TRC}}, y_{\text{TRC}})$ and $\text{BLC}=(x_{\text{BLC}}, y_{\text{BLC}})$

Desplazamiento de W_{LLP} desde BLC a TRC, solape longitudinal= O_L , transversal= $O_T \rightarrow$ Lista de región $\{V\}$

```

for all  $\{V\}$  do
  Puntos disponibles en cada región  $\{P_{Vi}\}$ 
  if  $\{P_{Vi}\}$  is not empty do
    Seleccionar el punto de menor elevación en  $\{P_{Vi}\} \rightarrow P_{\text{min}}=(x_{\text{min}}, y_{\text{min}}, z_{\text{min}})$ 
     $P_{\text{min}} \xrightarrow{\text{insertar}} \{LLP\}, \{P_{Vi}\} \leftarrow \emptyset$ 
  end if
end for

  Seleccionar puntos que fueron identificados como mínimos más de una vez a partir de  $\{LLP\} \rightarrow \{P_g\}$ 

  Definir malla de celdas cuadradas, tamaño celdas= $W$ , ámbito  $\rightarrow \text{TRC}=(x_{\text{TRC}}, y_{\text{TRC}})$  and  $\text{BLC}=(x_{\text{BLC}}, y_{\text{BLC}})$ 
  Sobreponer malla a  $\{P_g\}$ 
  Seleccionar celdas que no contienen puntos  $\rightarrow$  Lista de región  $\{V\}$ 

  for all  $\{V\}$  do
    Puntos disponibles en cada región  $\{P_{Vi}\}$ 
    if  $\{P_{Vi}\}$  is not empty do
      Seleccionar el punto de menor elevación en  $\{P_{Vi}\} \rightarrow P_{\text{min}}=(x_{\text{min}}, y_{\text{min}}, z_{\text{min}})$ 
       $P_{\text{min}} \xrightarrow{\text{insertar}} \{P_g\}, \{P_{Vi}\} \leftarrow \emptyset$ 
    end if
  end for

Return  $\{P_g\}$ 

```

Figura 1.4: Pseudo-código de **OWM**.

Función PNT. Cálculo de la penetrabilidad.

Inputs: Point Cloud = $\{P\}$, superficie de referencia φ , tamaño de celda W , residual mínimo permitido δ

Cálculo del residual de los puntos a partir de $\{P\}$ y $\varphi \rightarrow p_i=(x_i, y_i, z_i, \delta_i)$

Encode $\{P\}$ from δ_i and $\delta \rightarrow$

```

if  $\delta_i < \delta$  then  $p_i=(x_i, y_i, z_i, \text{class}=G)$ 
else  $p_i=(x_i, y_i, z_i, \text{class}=NA)$  end if

Fijar ámbito geográfico a partir de  $\{P\} \rightarrow \text{TRC}=(x_{\text{TRC}}, y_{\text{TRC}})$  and  $\text{BLC}=(x_{\text{BLC}}, y_{\text{BLC}})$ 
Dividir el ámbito geográfico en una malla regular (resolución= $W$ )  $\rightarrow \varphi_{PNT}$ 
if  $N(P_i) > 0$  then  $\varphi_{PNT}(i,j) \leftarrow N(P_i(\text{which class}=G))/N(P_i)$ 
else  $\varphi_{PNT}(i,j) \leftarrow NA$  end if

Return  $\varphi_{PNT}$ 

```

Figura 1.5: Pseudo-código de **PNT**.

calcula la distancia entre *Point Cloud* y la superficie terreno de referencia φ . Aquellos puntos cuya distancia a dicha superficie sea inferior a δ son clasificados como terreno y codificados con el valor "G". A continuación, a la nube de puntos codificada se le superpone una malla de celdas cuadradas de tamaño W cuya extensión coincide con la de *Point Cloud*. A cada celda se le asigna el valor resultante de dividir el número de puntos codificados como "G" entre el número total de puntos en la celda. A las celdas que no contienen puntos se le asigna el valor NA. El resultado de esta función es un ráster (φ_{PNT}) donde cada celda almacena un valor de penetrabilidad según la definición citada anteriormente.

La función DebCloud. Dependiendo de las características de la zona de estudio, los filtros que incluyen un proceso de selección de LLP necesitan modificar el tamaño de la ventana de selección de dichos puntos a fin de evitar errores de comisión ante la presencia de objetos. Teóricamente, cuanto menor es esta ventana mayor es el número de LLP seleccionados, y en zonas urbanas con presencia de grandes edificaciones, mayor el riesgo de seleccionar erróneamente puntos P_{ng} como P_g . Sin embargo, en zonas rurales o forestales, donde las edificaciones son de menor tamaño, es posible usar un menor tamaño de la ventana de selección de LLP, lo que se traduce en un aumento del detalle con el que se representa el terreno. Si bien algunos autores

abordaron esta problemática seleccionando los LLP a diferentes escalas (Mongus y Žalik, 2012, Chen et al., 2013, Hu et al., 2014), en teoría el proceso de selección de dichos puntos sería más eficaz si el número de P_{ng} fuese reducido previamente a la selección de los LLP. Así, en entornos urbanos sería posible usar un tamaño de ventana semejante al empleado

Función DebCloud. Detección y eliminación de máximos locales.

Inputs: Point Cloud= P , tamaño de ventana W , ráster de penetrabilidad φ_{PNT} , umbrales de pendiente min. y max. S_{min} y S_{max} , residual máximo permitido δ

Cálculo de la densidad media ponderada a partir de $\{P\} \rightarrow D$
 Fijar $L=1$, Fijar $O=0.5$

```

while L ≤ 2 do
  if L=1 then R=W else R=0.75·W end if
  Definir ventana cuadrada, tamaño=R →  $W_C$ . Definir ventana cuadrada, tamaño=1.5·R →  $W_{WV}$ . Fijar  $N_{P_{WV}} \leftarrow D \cdot (1.5 \cdot R)^2$ 
  Fijar ámbito geográfico a partir de  $\{P\} \rightarrow TRC=(x_{TRC}, y_{TRC})$  y  $BLC=(x_{BLC}, y_{BLC})$ 
  Desplazamiento de  $W_{WV}$  desde  $BLC$  a  $TRC$ , solape=O → Lista de regiones  $\{V\}$ 
  for all  $\{V\}$  do
    Selección de los puntos en cada región →  $\{P_{Vj}\}$ 
    if  $N_{P_{Vj}} < 0.1 \cdot N_{P_{WV}}$  then  $\{P_{Vj}\} \xrightarrow{\text{eliminar}} \{P_D\}$ ,  $\{P_{Vj}\} \leftarrow \emptyset$  else
      while  $\{P_{Vj}\}$  is not empty do
        Selección máximo en  $\{P_{Vj}\} \rightarrow P_{max}=(x_{max}, y_{max}, z_{max})$ 
        Selección de los puntos de  $W_C$  ventana centrada en  $P_{max} \rightarrow \{P_C\}$ 
        Selección mínimo en  $\{P_C\} \rightarrow P_{min}=(x_{min}, y_{min}, z_{min})$ 
        Cálculo de la pendiente entre  $P_{min}$  y  $P_{max} \rightarrow S$ 
        if  $z_{max}=z_{min}$  or  $S \leq S_{min}$  then  $\{P_{Vj}\} \xrightarrow{\text{eliminar}} \{P_D\}$ ,  $\{P_{Vj}\} \leftarrow \emptyset$ 
        else if  $S \geq S_{max}$  then  $P_{max} \xrightarrow{\text{eliminar}} \{P_{Vj}\}$ 
        else
          Mínimos de  $\{P_C\} \cap$  celdas donde  $\varphi_{PNT}(i,j) > 0 \rightarrow \{P_R\}$ 
          Rasterizar  $\{P_R\} \rightarrow \varphi_{referencia}$ 
          Cálculo de residuales a partir de  $P_{max}$  y  $\varphi_{referencia} \rightarrow P_{max}=(x_{max}, y_{max}, z_{max}, \delta_{min})$ 
          if  $\delta_{min} > \delta$  then  $P_{max} \xrightarrow{\text{eliminar}} \{P_{Vj}\}$  else  $\{P_{Vj}\} \xrightarrow{\text{eliminar}} \{P_D\}$ ,  $\{P_{Vj}\} \leftarrow \emptyset$  end if
        end if
      end while
    end if
  end for
  Fijar  $L=(L+1)$ , fijar Point Cloud= $\{P_D\}$ 
  Eliminar puntos duplicados en  $\{P_D\}$ 
end while
Return  $\{P_D\}$ 

```

Figura 1.6: Pseudo-código de DebCloud.

en zonas forestales y reducir el riesgo de introducir erróneamente P_{ng} en la nube de LLP.

Para obtener una nube de puntos con un número reducido de P_{ng} , se tomaron como referencia los estudios de Chang (2010) y Zhang y Lin (2013) y se implementó la función DebCloud (el esquema de su funcionamiento se incluye en la Figura 1.7). El principio que rige esta función para detectar y eliminar P_{ng} de la nube de puntos es que las elevaciones de estos puntos son máximas en un entorno local. Dicha función está definida por 6 argumentos: datos de entrada (*Point Cloud*), tamaño de la ventana de depurado² (W), ráster de penetrabilidad (φ_{PNT}), umbrales de pendiente mínimo (S_{min}) y máximo (S_{max}) y residual máximo permitido (δ). Según la Figura 1.6, donde se incluye el pseudo-código de esta función, después de calcular la densidad media ponderada (D) a partir de los datos de entrada (*Point Cloud*), el depurado de la nube de puntos se realiza a dos niveles (L), donde las operaciones que se ejecutan para obtener la nube de puntos depurada (P_D) son las mismas para ambos niveles cambiando el tamaño de la ventana de análisis. Así, se empieza definiendo el tamaño de la ventana de análisis (W_C) en base al argumento W . En el primer nivel ($L=1$), el tamaño de W_C es W , mientras que en el segundo nivel ($L=2$) este valor se reduce un 25% a fin de eliminar máximos locales pertenecientes a objetos más pequeños. Por otro lado, para hacer más eficiente la identificación de máximos locales, se define una ventana de búsqueda (W_W) cuyo tamaño es 1.5 veces el tamaño de la ventana de análisis (W_C). Estos coeficientes fueron establecidos mediante el método de prueba y error y análisis de resultados. Adicionalmente se calcula la cantidad teórica de puntos que deberían encontrarse en cada ventana W_W ($N\bar{P}_W$) como el producto de D por el área que ocupa W_W . Esta cantidad se empleará como control a la hora de llevar a cabo el depurado de los puntos en las ventanas W_W .

A continuación, se identifican los límites geográficos sobre los que se ejecutará la función. Al igual que en el caso de la función OWM, los límites de esta área se amplían aplicando un buffer exterior de

²El tamaño de esta ventana se identifica con el tamaño máximo del área sin P_g , que a su vez se relaciona con el lado de menor longitud del edificio más grande presente en la zona de estudio

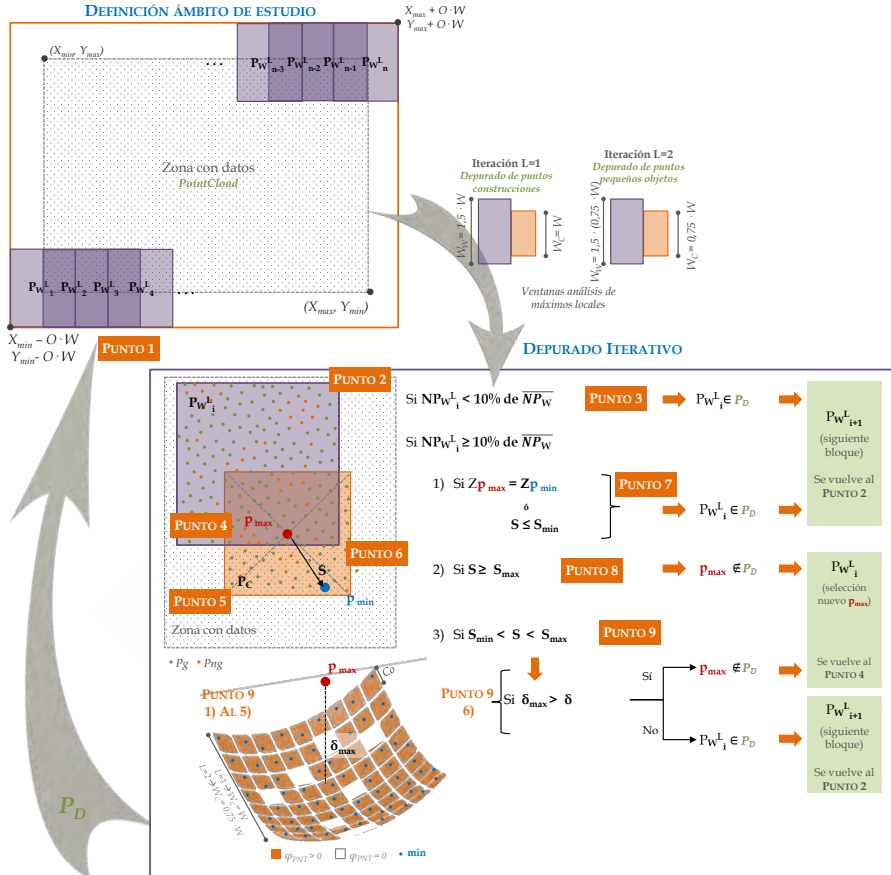


Figura 1.7: Esquema de funcionamiento de la función DebCloud.

magnitud $W \cdot O$. En este caso, O es el solape longitudinal y transversal entre ventanas y se fija en 0.5 (parámetro fijo de la función). Así, las coordenadas de la TRC son $x_{TRC} = x_{max} + W \cdot O$ y $y_{TRC} = y_{max} + W \cdot O$, mientras que las de la BLC son $x_{BLC} = x_{min} - W \cdot O$ y $y_{BLC} = y_{min} - W \cdot O$. A continuación la ventana de búsqueda W_W se desplaza desde BLC siguiendo el eje X con un solape entre ventanas consecutivas de magnitud $W \cdot O$. Finalizada la primera pasada, la ventana W_W vuelve al extremo izquierdo e inicia una nueva pasada, cuyo origen se encuentra desplazado $W \cdot O$ en Y con respecto a la primera. El proceso se repite hasta que la ventana W_W llega a la TRC. En cada posición, todos los puntos en su

interior son seleccionados (P_W). Si la cantidad de P_W es inferior al 10% de $N\bar{P}_W$, el depurado en esa ventana no se ejecuta por considerarse que no hay puntos suficientes. Entonces, P_W son seleccionados y pasan a formar parte de la nube de puntos depurada (P_D). La ventana W_W se desplaza hacia la derecha donde se seleccionan nuevos puntos. En caso contrario, si la cantidad de P_W es superior o igual al 10% de $N\bar{P}_W$, se selecciona el punto con elevación máxima (p_{max}).

Con el objeto de decidir si p_{max} es o no P_g , se considera un área local definida por W_C y centrada en p_{max} . En esta área, los puntos vecinos a p_{max} son identificados (P_C) y el punto con menor elevación es seleccionado (p_{min}). Finalmente, se calcula la pendiente entre p_{min} y p_{max} ³ (S). En este punto se pueden dar tres situaciones: 1) si las elevaciones de p_{min} y p_{max} son iguales o si la pendiente entre p_{min} y p_{max} es menor que S_{min} , los P_W (incluido p_{max}) pasan a formar parte de la nube de P_D . Entonces la ventana W_W se mueve una posición hacia la derecha, nuevos puntos son seleccionados (P_W) y la cantidad de P_W es evaluada nuevamente ...; 2) si la pendiente entre p_{min} y p_{max} es mayor que S_{max} , p_{max} es eliminado de P_W al considerarse que representa un P_{ng} , un nuevo máximo local es seleccionado y se repiten los pasos para comprobar si p_{max} es o no P_g ; 3) finalmente, si $S_{min} < S < S_{max}$, el criterio de pendiente no es suficiente para decidir si p_{max} pertenece o no al terreno, por ello se tiene en cuenta la diferencia de elevación (δ_{max}) entre dicho punto y una superficie de referencia⁴ ($\varphi_{reference}$). Entonces, si δ_{max} es mayor que δ , p_{max} es eliminado de P_W , un nuevo máximo local es seleccionado ... En caso contrario, los P_W (incluido p_{max}) pasan a formar parte de P_D . Entonces la ventana W_W se mueve una posición hacia la derecha, nuevos puntos son seleccionados (P_W) y la cantidad de P_W es evaluada nuevamente ...

En el segundo nivel ($L=2$), se repite el proceso anterior considerando

$$^3 S = \frac{z_{max} - z_{min}}{\sqrt{(x_{max} - x_{min})^2 + (y_{max} - y_{min})^2}}$$

⁴ $\varphi_{reference}$ se genera a partir de la interpolación de un conjunto de puntos mínimos P_R , los cuáles son seleccionados a partir de P_C en las celdas de φ_{PNT} cuyo valor es mayor que 0, empleando el código de R $lm(Z \sim (X + Y)^2 + I(X^2) + I(Y^2), data = P_R)$ obtenido de la función **scatter3d** (paquete *car* - v.2.1-2).

P_D , resultado del primer nivel, como *Point Cloud*. Finalmente, un punto puede ser seleccionado varias veces debido al solape entre W_W . En este caso, como el solape es del 50%, cada punto es analizado como máximo 4 veces y por tanto, éste es el máximo número de veces que puede estar repetido en P_D . A diferencia de lo que sucede con la aplicación de la función OWM, aquí no interesa conservar sólo aquellos puntos que se repiten más de una vez, sino también aquellos que fueron seleccionados una única vez, pues de no ser así, se eliminarían la gran mayoría de los puntos terreno de pasarelas o de límites de barrancos. Así, un punto es eliminado definitivamente si es identificado como máximo local y eliminado tantas veces como es incluido en la ventana W_W . Finalmente, los puntos duplicados de P_D son eliminados.

1.2.3.3 Operaciones e integración de funciones.

En la Figura 1.8 se ha incluido un resumen gráfico de las diferentes etapas y procesos del algoritmo DTMOFLabTe. De manera genérica se distinguen tres bloques de operaciones precedidos por la selección de los datos de entrada (P) y la asignación de valores a los parámetros variables (C , C_S , δ_h). El primer bloque incluye la obtención de la información auxiliar necesaria para el filtrado, como los valores de los parámetros automáticos o el cálculo de variables como la densidad de puntos o la penetrabilidad. El segundo bloque, incluye el proceso de depurado, la selección de los LLP y la interpolación de dichos puntos para obtener la primera superficie de referencia ($\varphi_{t=0}$). Por último, el tercer bloque se corresponde con la densificación de los modelos intermedios para obtener la nube de puntos terreno final.

Bloque 1. Cálculo de variables. El objetivo del primer bloque de operaciones es extraer información auxiliar a partir de los datos LiDAR (D - densidad de puntos y φ_{PNT} - penetrabilidad) que se usará para asignarle valores a los parámetros automáticos (C_O , Sl_{min} y Sl_{max}). En primer lugar, se calcula la densidad media ponderada de la nube de puntos LiDAR. Se obtiene a partir de una malla de celdas cuadradas (1x1m) cuyos límites vienen establecidos por los valores máximos y mínimos de las coordenadas X e Y de P (x_{max} , y_{max} , x_{min} , y_{min}). El

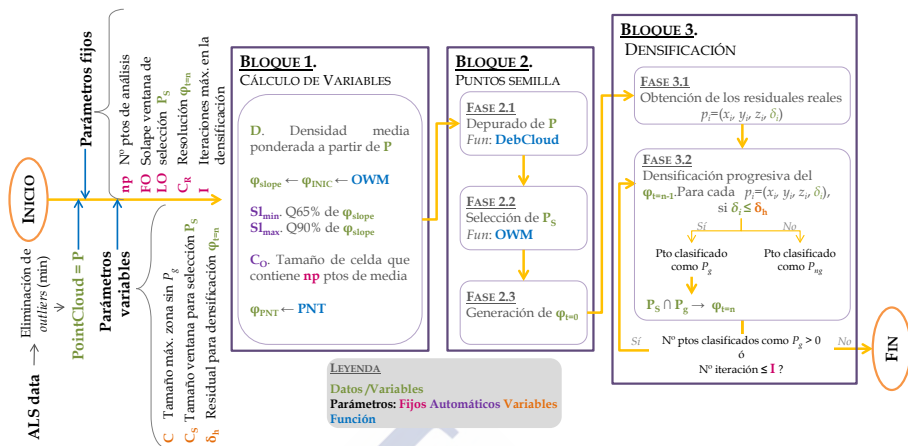


Figura 1.8: Esquema de funcionamiento de DTMofLabTe

valor que se le asigna a cada celda es el número de puntos que caen en su interior. A partir de estos valores se calcula la densidad media ponderada (ptos/ m^2). Dicho valor es asignado a la variable D . A continuación se establecen los parámetros SI_{min} y SI_{max} a partir del percentil⁵ del 65% y 90% de los valores de las celdas de una superficie de pendientes (φ_{slope}). Para obtener esta superficie en primer lugar se identifican un conjunto de LLP empleando la función **OWM**, donde los valores de sus argumentos son los siguientes: $PointCloud=P$, $w=W=C$, $O_F=FO=0.8$ y $O_L=LO=0.8$. A la nube de puntos resultante se le aplica un filtro estadístico⁶ para detectar y eliminar puntos con valores de elevación anormalmente elevados que pudieran producir una sobrestimación de los valores de los parámetros SI_{min} y SI_{max} . Tras este depurado, los puntos seleccionados se interpolan a partir de la función **Tps**⁷ (paquete *fields* - v.8.2-1 de R). El modelo resultante se transforma a formato ráster empleando la función **interpolate** (paquete *raster* - v.2.4-20), obteniéndose así φ_{INIC} . Por último, a partir de esta superficie y la

⁵Para controlar los valores asignados a estos parámetros se establece 0.1 y 0.35 como valor mínimo y máximo aceptable para SI_{min} ($0.1 \leq SI_{min} \leq 0.35$) y 0.2 y 0.75 para SI_{max} ($0.2 \leq SI_{max} \leq 0.75$).

⁶Este filtro elimina aquellos puntos que presentan un valor de elevación superior a $\mu_{zLLP} + 2 \cdot \sigma_{zLLP}$.

⁷No se modificaron los valores establecidos por defecto.

función **terrain** (paquete *raster* - v.2.4-20) se calcula φ_{slope} . Más detalles sobre el cálculo de una superficie empleando el método de interpolación TPS pueden ser consultados en Nychka et al. (1998) y en la documentación del paquete *fields* (Fields Development Team, 2006). Finalmente, se calcula el ráster con la información de la penetrabilidad (φ_{PNT}) a partir de la función **PNT**. Los valores de los argumentos de dicha función para este caso son: *Point Cloud*=P, $\varphi=\varphi_{INIC}$, $W=C_O$ y $\delta=\delta_h$. Previamente, el parámetro automático C_O se obtiene de forma automática como $\sqrt{\frac{np}{D}}$.

Bloque 2. Depurado y selección de puntos semilla. El objetivo de este segundo bloque es identificar los puntos semilla (P_S) a partir de una nube de puntos depurada de P_{ng} (P_D). Los P_S constituyen la base para obtener una primera aproximación de la superficie del terreno ($\varphi_{t=0}$) y para llevar a cabo la posterior identificación de nuevos puntos terreno. Tal y como se indica en la Figura 1.8, este bloque se divide en 3 fases: depurado de la nube de puntos empleando la función **DebCloud**, selección de los puntos semilla a partir de la función **OWM** e interpolación de dichos puntos para obtener $\varphi_{t=0}$.

Fase 2.1 Depurado de P. Antes de seleccionar los P_S , se detectan y eliminan la mayor cantidad posible de P_{ng} de la nube de puntos LiDAR. Para ello se emplea la función **DebCloud**. En este caso, los valores de los argumentos de dicha función son: *Point Cloud*=P; $W=C$; $\varphi_{PNT}=\varphi_{PNT}$; $S_{min}=SI_{min}$; $S_{max}=SI_{max}$ y $\delta=\delta_h$. Como resultado se obtiene la nube de puntos depurada (P_D). Aunque esta función se encuentre definida por 6 argumentos el usuario debe prestar atención únicamente a dos de ellos, los parámetros variables C y δ_h . El resto de argumentos no requieren la intervención directa del usuario, pues son datos o variables derivadas de ellos, parámetros fijos o automáticos.

Fase 2.2 Selección de P_S . Una vez obtenidos los P_D , se emplea la función **OWM** para seleccionar los P_S . Este método de selección de LLP es una de las principales diferencias que presenta **DTMofLabTe** con respecto a los filtros que incluyen la selección de puntos semilla. La función **OWM** incorpora como novedad el uso de una ventana móvil para la selección de puntos, la cual ejecuta su desplazamiento con un solape longitudinal entre ventanas consecutivas y transversal entre *pasadas*.

Este solape entre ventanas ocasiona que un punto pueda ser analizado y seleccionado más de una vez como LLP. Teóricamente, cuantas más veces un punto es seleccionado como mínimo local, mayor es la probabilidad de que dicho punto pertenezca al terreno. De esta forma, al tener en cuenta el número de veces que un punto es seleccionado, es posible usar un tamaño de ventana más pequeño que el que se usaría con el método clásico LMM, sin que con ello se aumenten los errores de comisión, incrementando el número de P_S y el nivel de detalle de la primera superficie de referencia y en consecuencia, el error de omisión final se verá reducido. En este caso, los valores de los argumentos de la función OWM fueron: *Point Cloud*= P_D , $w=C_S$, $W=C$, $O_F=O_L=FO = LO = 0.8$. Como resultado se obtuvieron los puntos semilla P_S (puntos identificados como mínimos locales más de una vez).

Fase 2.3 Generación de $\varphi_{t=0}$. La elección del método de interpolación es uno de los factores a tener en cuenta en el proceso de filtrado. En base al estudio llevado a cabo por Evans y Hudak (2007) y a la experiencia de otros autores en trabajos similares (Mongus y Žalik, 2012, Chen et al., 2013), en este estudio se empleó la función **Tps** para interpolar los puntos clasificados como P_g en cada iteración. Se usaron los valores de los parámetros establecidos por defecto, de forma que el parámetro de suavizado *lambda* es calculado automáticamente por la función. Finalmente, se empleó la función **interpolate**, para transformar el modelo generado con la función **Tps** a formato ráster con una resolución C_R (en este estudio $C_R=1$ m).

Bloque 3. Densificación. La finalidad de este último bloque es identificar nuevos P_g entre los puntos no clasificados. Para ello, primero se calcula la diferencia de elevación entre cada punto de P y una superficie de referencia ($\varphi_{t=0}$ en la primera iteración, actualizada iterativamente con la incorporación de nuevos puntos - $\varphi_{t=n}$). A diferencia de otros autores, que calcularon el residual de cada punto como la media de los valores de la celda central y las 8 celdas vecinas (Chen et al., 2013), en este estudio sólo se ha tenido en cuenta el valor de la celda central (función **extract**, opción *method="simple"*, paquete *fields* - v.8.2-1). De esta forma se evita sobrestimar el valor de los residuales en zonas heterogéneas o con elevada pendiente.

En segundo lugar, se compara el residual de cada punto con el máximo residual permitido (δ_h). Muchos estudios han usado los residuales como criterio para clasificar nuevos puntos como P_g . Hu et al. (2014), en base al estudio de Sithole y Vosselman (2004), manifestaron la necesidad de asignarle diferentes valores al parámetro que controla el proceso de densificación en función de las características del terreno, de forma que en zonas con pequeños objetos recomiendan emplear un umbral más pequeño que en zonas montañosas. Aunque aquí sería posible aplicar un mayor umbral a los puntos en zonas con elevada pendiente que a los situados en zonas más llanas, pues se podrían usar los valores de pendiente derivados de las superficies de referencia intermedias, se comprobó que los errores de comisión con origen en la selección de puntos semilla se agravaban, así como los errores de omisión en zonas de elevada pendiente como taludes y barrancos. Adicionalmente, también se plantea el problema de seleccionar la función que se emplearía para la asignación de residuales máximos permitidos (p. ej. lineal, polinómica, exponencial,...). Teniendo en cuenta lo expuesto y el elevado grado de detalle de $\varphi_{t=0}$ y las sucesivas superficies, en este estudio se optó por asignar un umbral único a toda la zona, el parámetro variable δ_h .

En resumen, los puntos de P cuyo residual es inferior o igual al parámetro δ_h son considerados P_g e interpolados para obtener una nueva $\varphi_{t=n}$. La obtención de los residuales y la posterior densificación de la nube de puntos se repite, bien hasta que no se añaden nuevos P_g bien hasta llegar al número máximo de iteraciones definido por el parámetro fijo I .

1.2.4 Evaluación de la precisión y análisis de resultados

La evaluación cuantitativa de los resultados del filtrado se realizó a partir de las métricas propuestas por Sithole y Vosselman (2004): el error Tipo I (TIE - error de omisión o porcentaje de puntos terreno que no han sido identificados como tal), el error Tipo II ($TIIe$ - error de comisión o porcentaje de puntos no-terreno identificados erróneamente como terreno) y el error Total (Te). Las ecuaciones que permiten

su cálculo se incluyen en la Tabla 1.4. Estas métricas, usadas en múltiples estudios (Mongus y Žalik, 2012, Zhang y Lin, 2013), se calculan a partir de cuatro parámetros: **a**, cantidad de P_g que han sido correctamente identificados como terreno; **b**, cantidad de P_g que han sido incorrectamente clasificados como no-terreno; **c**, cantidad de P_{ng} que han sido incorrectamente identificados como terreno; **d**, cantidad de P_{ng} que han sido correctamente identificados como no-terreno; y **e**, número total de puntos.

Tabla 1.4: *Cross-matrix* teórica y ecuaciones

Referencia	Filtrado		Errores	
	P_g	P_{ng}		
P_g	a	b	a+b	Tipo I= $\frac{b}{(a+b)}$
P_{ng}	c	d	c+d	Tipo II= $\frac{c}{(c+d)}$
	a+c	b+d	e=a+b+c+d	Total= $\frac{(b+c)}{e}$

Estadísticamente, cuando los datos son de tipo categórico y se pretende evaluar hasta qué punto dos conjuntos de observaciones coinciden en su medición, en este caso los datos de referencia y los obtenidos tras el filtrado, el estadístico más empleado es el coeficiente Kappa de Cohen (1960)(Ec.1.1).

$$K = \frac{e \cdot (a + d) - (((a + b) \cdot (a + c)) + ((c + d) \cdot (b + d)))}{e^2 - (((a + b) \cdot (a + c)) + ((c + d) \cdot (b + d)))} \quad (1.1)$$

El coeficiente Kappa es una medida estadística de concordancia inter-observador que cuantifica la precisión general de una clasificación teniendo en cuenta las distribuciones marginales. De esta forma permite conocer la probabilidad de que la concordancia entre la muestra de referencia y el resultado del filtrado se deba exclusivamente al azar. Por tanto, si $K = 0$ la concordancia observada es la que se espera a causa del azar. Si $K > 0$, la concordancia es mayor que la debida simplemente a causa del azar, mientras que si es menor, K tomará valores negativos. La máxima concordancia corresponde a $K = 100$ (en tanto por ciento)(Pingel et al., 2013). Este coeficiente se considera

una medida más robusta que un simple porcentaje (Hu et al., 2014) y ha sido empleado en trabajos previos similares al que se presenta aquí (Silván-Cárdenas y Wang, 2006, Véga et al., 2012, Chen et al., 2013, Hu et al., 2014).

Para llevar a cabo el análisis de los resultados del filtrado se realizó un ajuste de los parámetros variables de **DTMofLabTe**. Los resultados del filtrado de las 15 muestras de referencia empleando las diferentes combinaciones de parámetros permitieron evaluar internamente el funcionamiento de **DTMofLabTe** en base a tres aspectos: 1) la efectividad del proceso de depurado; 2) la validez del método de selección de puntos semilla (**OWM**); y 3) la influencia de los parámetros variables en el resultado final. Adicionalmente, empleando dichos datos y el paradigma de evaluación usado en el estudio de **Sithole y Vosselman (2004)** también se realizó una evaluación externa, de forma que se compararon los resultados de este estudio con los obtenidos en 23 trabajos previos. Este último análisis es una de las principales ventajas que presenta el empleo de estos datos de referencia, ya que permite realizar una comparación cuantitativa perfecta entre diferentes algoritmos.

1.3 Resultados y discusión

1.3.1 Ajuste de parámetros.

La selección de los parámetros de filtrado es uno de los desafíos más importantes al que se enfrentan, primero l@s diseñador@s de filtros y posteriormente, l@s usuari@s; considerándose al mismo tiempo una tarea determinante para la efectividad y eficiencia del proceso de filtrado (Susaki, 2012). En la mayoría de los casos, la selección de los parámetros óptimos se basa en el método de prueba y error, sustentado por el conocimiento que posee el usuario sobre el funcionamiento del filtro y las características de la zona de estudio. Por ejemplo, en el caso de emplear un algoritmo morfológico sobre una zona urbana, a la hora de establecer un umbral máximo de diferencia de elevación puede ser de

ayuda tener en cuenta la altura del edificio más bajo para asegurarse que no son seleccionados erróneamente como terreno (Zhang et al., 2003) o incluso la altura de los vehículos (Chang, 2010). Si el filtro empleado incluye un proceso de selección de puntos semilla es habitual que el tamaño de ventana para su identificación se establezca en función del tamaño de la mayor superficie sin P_g con el objetivo de disminuir el número de P_{ng} en la nube de puntos semilla. En este sentido, Feng et al. (2009) y Axelsson (2000) realizaron dicha selección en base al tamaño del mayor objeto presente en la zona a filtrar. También es habitual el empleo de estadísticos como la media (Axelsson, 2000) o el percentil i -ésimo (Zhang y Lin, 2013) estimados a partir de un conjunto de observaciones para asignar valores a los parámetros durante el filtrado. Adicionalmente, si de forma sencilla se busca la máxima efectividad aun a riesgo de perder cierto grado de eficiencia, una técnica muy extendida se basa en seleccionar una secuencia de posibles valores para cada parámetro; ejecutar el filtro tantas veces como combinaciones distintas de parámetros se pueden formar y finalmente seleccionar aquella que proporciona el resultado con la mayor precisión (Hu et al., 2014).

En este estudio, los valores de los parámetros fijos se establecieron en base a la experiencia práctica de los autores, donde $np=10$; $LO=FO=0.8$; $C_R=1$; y $I=6$. Por otro lado, los valores de los parámetros automáticos (C_O , Sl_{min} y Sl_{max}) se calcularon de manera automática durante el filtrado (los valores que tomaron estos parámetros para cada una de las muestras se incluyen en la Figura 1.9). Finalmente, con el propósito de minimizar los errores de filtrado, los valores de los parámetros variables (C , C_S y δ_h) se ajustaron en dos fases y se calcularon los errores TIE , $TIIe$ y Te junto con el coeficiente Kappa para cada combinación de parámetros. En la primera fase, se filtran las diferentes muestras manteniendo constante el parámetro δ_h (toma un valor de 0.5 m) y variando los parámetros C y C_S . Para las muestras urbanas, $C \in [12,32]$ en intervalos de 2 m; y para las muestras rurales $C \in [6,26]$ en intervalos de 2 m; mientras que $C_S \in [3,6]$ en intervalos de 1 m para todas las muestras. De esta forma, cada muestra se filtra 44 veces. El rango para cada parámetro fue determinado en base a la experiencia práctica de los autores. Así, el conjunto de parámetros que logró el menor Te para cada muestra se consideró el óptimo de esta fase. En la segunda fase, los parámetros C y C_S tomaron los valores óptimos

obtenidos en la fase previa, y se varió el valor del parámetro δ_h , donde $\delta_h \in [0.4, 0.8]$ en intervalos de 0.1 m. En este caso, cada muestra se filtra 4 veces. Finalmente, el conjunto de parámetros considerado óptimo es el que alcanza el menor Te . De esta forma se obtuvieron 48 resultados por muestra, frente a los 220 que se hubieran producido en el caso de ejecutar todas las combinaciones posibles de los parámetros C (11 niveles), C_S (4 niveles) y δ_h (5 niveles) (los resultados de todas las combinaciones de parámetros realizadas se han incluido en las Tablas A.5 a A.19 del Anexo A.3). Los valores óptimos de los parámetros variables se muestran en la Figura 1.9.

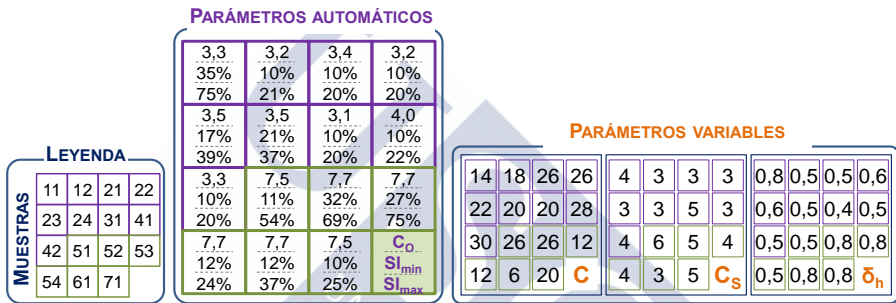


Figura 1.9: Valores de los parámetros automáticos y variables para la evaluación de DTMofLabTe.

Atendiendo a los resultados del ajuste de parámetros (Figura 1.9), el parámetro C_o toma valores entre 3 y 4 m en las muestras urbanas y cerca de los 7.7 m en las muestras rurales debido su dependencia de la densidad de los datos LiDAR (sobre 1 pto/ m^2 en las zonas urbanas y 0.2 pto/ m^2 en las rurales). Por otro lado, se observa que en términos generales el parámetro Sl_{min} toma valores del 10% (valor mínimo permitido) con la excepción de las muestras cuya pendiente es elevada (muestras 11, 24, 52 y 53). Sin embargo, el rango de valores entre los que oscila Sl_{max} es mucho mayor debido a la elevada pendiente del terreno.

En cuanto a los parámetros variables y en relación a las combinaciones identificadas como óptimas, no se identifica un patrón de comportamiento claro en cuanto a C . En referencia a los otros dos parámetros, en la mayoría de las muestras urbanas predomina el valor de 3 m para el parámetro C_S y de 50 cm para δ_h . Para las muestras rurales

el valor de C_S es más heterogéneo y el parámetro δ_h toma valores más elevados que en el caso anterior (80 cm). En el apartado 1.3.2.3 se realiza un análisis más detallado del comportamiento de estos parámetros en relación a los errores.

1.3.2 Evaluación interna de DTMofLabTe

1.3.2.1 Efectividad del proceso de depurado.

Tomando como supuesto que las elevaciones de los P_{ng} en un entorno local son máximas, la función DebCloud detecta estos puntos y los elimina si la pendiente entre dichos puntos y un mínimo local sobrepasa un umbral de pendiente establecido automáticamente. El objetivo de este proceso es equiparar el tamaño de la ventana de selección de P_S de las zonas urbanas al de las zonas rurales para aumentar el nivel de detalle con el que se representa la superficie de referencia inicial ($\varphi_{t=0}$) sin aumentar los *errores de comisión groseros*⁸.

Para comprobar la efectividad del proceso de depurado, en la Figura 1.10 se representa mediante un diagrama de barras el número de puntos original (en verde), los que se mantienen después del depurado (en naranja) y los seleccionados como puntos semilla (en fucsia) en función de si son P_g o P_{ng} . También se incluye para cada muestra los valores del Te y de K correspondientes (los resultados numéricos se incluyeron en la Tabla A.20, Anexo A.4). Adicionalmente, en las Figuras 1.11 y 1.12 se incluye la distribución espacial de los puntos originales (P), depurados (P_D) y semilla (P_S) para una selección de siete muestras, las cuales contienen edificios y vegetación en zonas con relieve complejo (muestra 11, Figuras 1.11a a 1.11c; muestra 12, Figura 1.11d a 1.11f; muestra 21, Figura 1.11g a 1.11i; muestra 41, Figura 1.12a a 1.12c; muestra 42, Figura 1.12d a 1.12f; muestra 52, Figura 1.12g a 1.12i; y muestra 53, Figura 1.12j a 1.12l). Los resultados incluidos en las Figuras 1.10, 1.11 y 1.12 se obtuvieron a partir de la combinación óptima

⁸Se denominan así a los errores producidos por puntos de edificaciones mal clasificados como terreno, pues éstos ocasionan en el modelo un impacto negativo mayor que el que produciría un punto de vegetación (Lu et al., 2008).

de parámetros para cada muestra (Tabla 1.9). En las Figuras A.7 a A.11 del Anexo A.4 se incluye para cada muestra y valor de C los resultados del depurado. El resultado para resto de muestras está incluido en las Figuras A.12 a A.26 del Anexo A.4.



Figura 1.10: Efectividad del proceso de depurado empleando la función `DebCloud`.

En términos generales, el depurado fue más efectivo en las muestras urbanas que en las rurales. Atendiendo a los resultados de la Figura 1.10 se tiene que en 6 de las 9 muestras urbanas, K es superior al 80%, y tan sólo el 15% de las muestras rurales superan esta precisión al tiempo que las diferencias entre resultados es mayor. Estos resultados eran los esperados ya que el principal objetivo del depurado es la eliminación de P_{ng} pertenecientes a edificaciones. Las zonas urbanas además de tener más cantidad de P_{ng} en relación a los P_g que las zonas rurales (en las zonas urbanas hay 1.1 P_g por cada P_{ng} mientras que en las zonas rurales de media hay 7.8 - Tabla 1.2) la mayoría se corresponde con edificaciones, donde el depurado es más efectivo, mientras que en las zonas rurales casi la totalidad de los P_{ng} se corresponden con vegetación.

La efectividad del depurado en las zonas urbanas queda patente donde el relieve es poco accidentado tanto si existen grandes edificaciones ($K_{S12}=89.53\%$ - Figura 1.11e y $K_{S42}=95.11\%$ - Figura 1.12e), como puentes ($K_{S21}=91.32\%$ - Figura 1.11h) o discontinuidades en los datos ($K_{S41}=96.29\%$ - Figura 1.12b). Sin embargo, este proceso no se encuentra libre de dificultades, pues zonas con orografía compleja y grandes edificaciones, terrazas y/o vegetación baja constituyen un serio desafío ($C=14$ y $K_{S11}=51.54\%$ - Figura 1.11b, $C=20$ y $K_{S24}=66.31\%$). En el caso particular de la muestra 11, donde grandes edificaciones se

encuentran a diferentes niveles sobre el terreno, los malos resultados pueden ser debidos a que al parámetro C toma un valor alto por el tamaño de las construcciones, y como el terreno se encuentra a diferentes niveles, en ocasiones el máximo local que se analiza pertenece al terreno y no a los objetos, aumentando simultáneamente los errores de omisión y comisión. Por el contrario, en la muestra 41 no se aprecia dicha limitación, donde si bien hay grandes edificaciones, éstas se localizan en una zona llana ($C=28$ y $K_{S41}=96.29\%$ - Figura 1.12b).

En las zonas rurales, el hecho de que un elevado porcentaje de P_{ng} que representan la vegetación, produce que el depurado no sea tan efectivo, fundamentalmente si dicha vegetación presenta poca altura, dando lugar a valores bajos de precisión en zonas con elevada pendiente ($K_{S51}=60.49\%$ y $K_{S52}=49.58\%$). Por otro lado, la falta de eficacia del depurado también se debe a errores de omisión, motivados por la eliminación errónea de P_g . Estos errores se localizan fundamentalmente en bordes de barrancos ($K_{S53}=45.87\%$ - Figura 1.12k y $K_{S61}=51.85\%$) o terraplenes junto a las vías de transporte ($K_{S71}=71.45\%$).



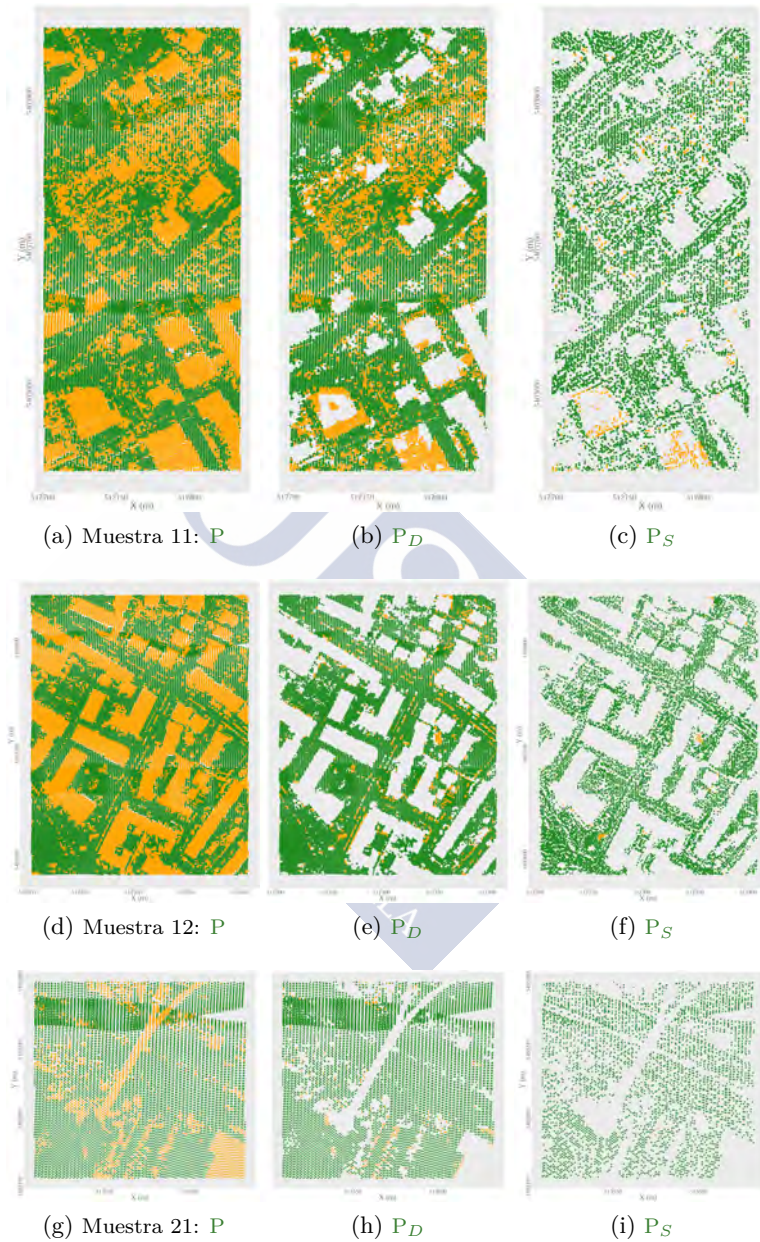


Figura 1.11: Efectividad del proceso de depurado (parte 1). Nota: en verde se representan los P_g y en amarillo los P_{ng} ; P , P_D y P_S nube de puntos original, depurada y con puntos semilla, respectivamente.

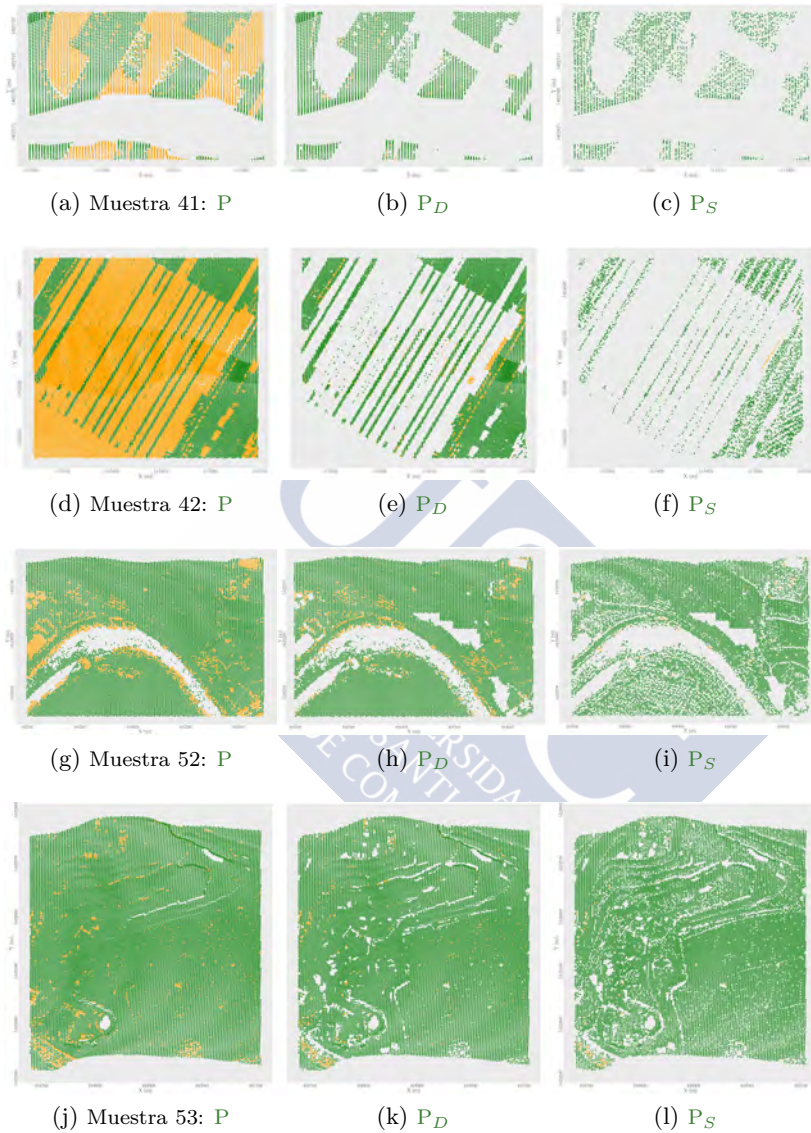


Figura 1.12: Efectividad del proceso de depurado (parte 2). Nota: en verde se representan los P_g y en amarillo los P_{ng} ; P, P_D y P_S nube de puntos original, depurada y con puntos semilla, respectivamente.

1.3.2.2 Influencia del método **OWM** en la selección de los P_S .

La selección de LLP es habitual en aquellos filtros que necesitan crear una superficie inicial de referencia. El entorno local en el que se seleccionan dichos puntos puede definirse por una ventana cuadrada como la empleada por el método LMM (Véga et al., 2012, Hu et al., 2014). Fijar su tamaño es una tarea clave, fundamentalmente en entornos urbanos, ya que un tamaño demasiado pequeño ocasionará elevados errores de comisión mientras que uno demasiado grande dará lugar a pérdida de detalle en la representación del terreno. Para mitigar este problema, en este estudio se desarrolló un método de selección de LLP empleando una ventana móvil con solape longitudinal y transversal. Este método se encuentra implementado en la función **OWM**. Así, para un solape del 80% cada punto será analizado 25 veces y se considerarán P_S aquellos puntos seleccionados como LLP más de una vez durante dicho proceso. De esta forma, el solape entre ventanas proporciona mayor cantidad de P_S que en el caso de emplear el método LMM pero sin aumentar los errores de comisión y en consecuencia, dando lugar a una primera aproximación del terreno más precisa. Adicionalmente, los resultados de **OWM** también se ven beneficiados por el depurado previo de la nube de puntos pues permite reducir el tamaño de ventana en zonas urbanas equiparándolo al de las zonas rurales, favoreciendo la selección de un mayor número de LLP.

Para respaldar estas afirmaciones, se tomaron como ejemplo las muestras 12 y 52. La función **OWM** se ejecutó con un solape longitudinal y transversal entre ventanas del 0% ($LO = FO = 0$), simulando así el funcionamiento de LMM. Adicionalmente se ejecutó con un solape del 80% ($LO = FO = 0.8$). Como datos de entrada, primero se tuvo en cuenta la nube de puntos sin depurar (P) y después los datos depurados (P_D). Los resultados cuantitativos de este experimento se han incluido en la Figura 1.13 y su distribución espacial en la Figura 1.14.

En la primera de las figuras, diferenciando entre P_g y P_{ng} se representa mediante un diagrama de barras el número de puntos originales (en verde) y los seleccionados como semilla empleando el LMM (en azul) y el **OWM** (en fucsia). En todos los casos, tanto si los datos




Figura 1.13: Resultados cuantitativos de la selección de puntos semilla empleando el método de mínimos locales con ventana móvil (LMM) empleado por Véga et al. (2012) ó Hu et al. (2014), y el método de mínimos locales a partir de una ventana móvil con solape (OWM) para las muestras 12 y 52.

de entrada están o no depurados, el OWM selecciona casi 4 veces más puntos que el LMM. Si bien es cierto que el número de P_{ng} que se seleccionan erróneamente también es más alto, la mayoría se corresponde con vegetación baja y en ningún caso pertenecen a edificaciones. Además el porcentaje medio de error (media del porcentaje de P_{ng} en función del número total de puntos semilla seleccionados) es muy similar empleando los dos métodos tanto si la nube de puntos se encuentra o no depurada (LMM- $\mu_{error}=1.1\%$ vs. OWM- $\mu_{error}=0.9\%$ y LMM- $\mu_{error-D}=0.65\%$ vs. OWM- $\mu_{error-D}=0.75\%$, respectivamente). En ambos casos se estarían mejorando los resultados obtenidos mediante otros métodos de selección de puntos semilla (en Jahromi et al. (2011) $\simeq 4\%$ de los puntos semilla seleccionados de forma automática eran P_{ng}).

En cuanto a su distribución espacial, en la Figura 1.14 se observa como en los bordes de las vías y patios interiores de edificaciones (Figura 1.14b vs. Figura 1.14c) o en el borde de los cursos de agua (Figura 1.14e vs. Figura 1.14f), el terreno queda mejor definido empleando OWM que LMM, lo que puede suponer invertir menos recursos en la posterior densificación del modelo. En cuanto a los datos de entrada, se comprueba la influencia positiva del proceso de depurado, multiplicando el número de P_S por 15 en la muestra 12 y por 20 en la muestra 52 en referencia a los resultados obtenidos empleando la nube de puntos sin depurar. Estos resultados fueron posibles gracias a que el tamaño de ventana se redujo de 18 m a 3 m en la muestra

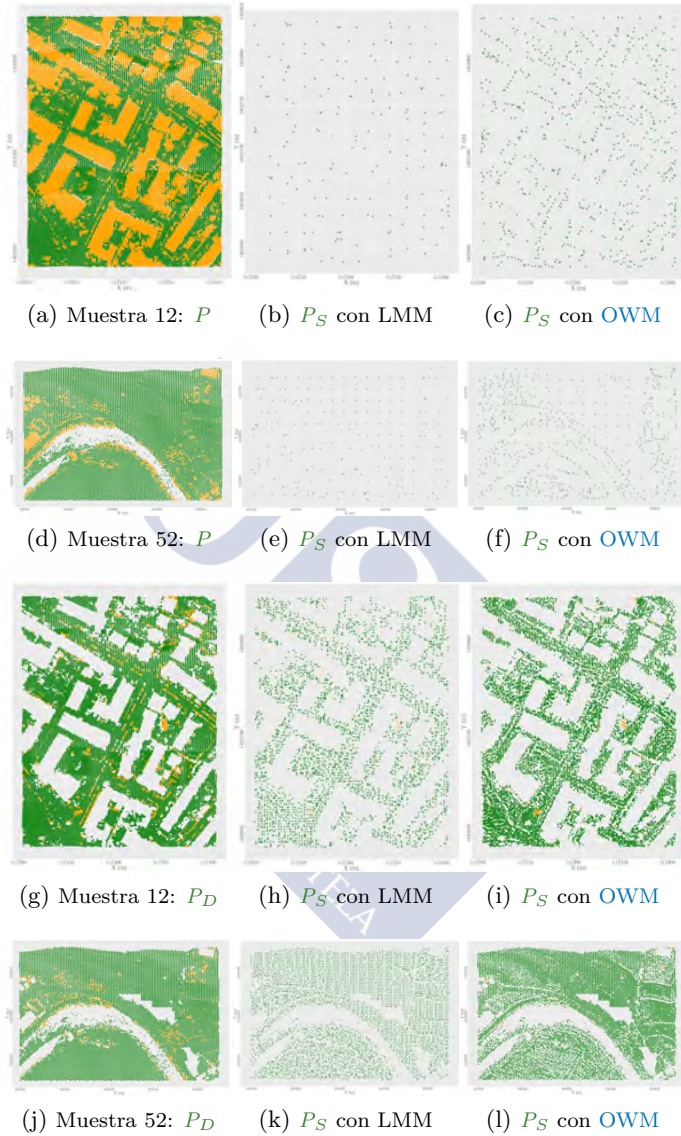



Figura 1.14: Ejemplos cualitativos de la efectividad en la selección de puntos semilla (P_S). Comparación de los resultados del LMM y OWM empleando la nube de puntos original (P) y la depurada (P_D) de las muestras 12 y 52. Nota: en verde se representan los P_g y en amarillo los P_{ng} .

12 y de 26 m a 5 m en la muestra 52. A pesar de que el tamaño de ventana en el primer caso (3 m) es casi la mitad que en el segundo caso (5 m) y que el número de P_g en la muestra 12 ($P_{g-S12} = 26654$ y $P_{gD-S12} = 26269$) es superior al de la muestra 52 ($P_{g-S52} = 20112$ y $P_{gD-S52} = 19300$), paradójicamente el número de P_S seleccionados en este último caso es mayor que en el primero (para el caso donde los datos de entrada es la nube de puntos depurada y se emplea el OWM, se tiene que $P_{gS-S12} = 11246$, $P_{ngS-S12} = 95$, $P_{gS-S52} = 15213$ y $P_{ngS-S52} = 99$). Esta situación puede deberse a que la escena de la muestra 12 es más compleja que la de la muestra 52. Además, la presencia en esta última de dos zonas relativamente llanas (parte superior e inferior de la escena) con un reducido número de P_{ng} pudo favorecer la selección de P_S .

Finalmente, se reflexiona sobre una posible mejora de **DTMofLabTe** relacionada con las creación de la superficie de referencia inicial ($\varphi_{t=0}$) a partir de los puntos semilla. Como ya se mencionó, se toman como P_S aquellos puntos que han sido seleccionados como mínimos locales más de una vez (hasta un máximo de 25 veces si el solape es del 80%). En la Figura 1.15 se incluyen las puntuaciones de los puntos semilla para las muestras 12 y 52. Se observa como los puntos con mayor puntuación se localizan hacia el centro de las vías (Figura 1.15a) y en las zonas más llanas (zona sur en la Figura 1.15b), mientras que los que poseen las puntuaciones más bajas se encuentran cerca de las edificaciones (Figura 1.15a) y en zonas con fuerte pendiente (zona central en la Figura 1.15b). En base a esta información, la mejora que se propone es generar la superficie $\varphi_{t=0}$ ponderando la elevación de los puntos semilla en función de su puntuación, de manera que los puntos con mayor puntuación tengan más influencia (mayores pesos) en la generación de dicha superficie que aquellos cuya puntuación es menor. Esta propuesta es similar a la densificación de los modelos intermedios llevada a cabo por Kraus y Pfeifer (1998), donde la elevación de cada punto era ponderada según una función lineal tomando como información base la diferencia de elevación entre los puntos y la superficie de referencia (residuales).



(a) Muestra 12: Puntos originales y puntuación de P_S . (b) Muestra 52: Puntos originales y puntuación de P_S .



Figura 1.15: Ejemplos de puntuaciones de los P_S tras la aplicación de OWM.

1.3.2.3 Influencia de los parámetros variables en el filtrado.

Para estudiar como influyen los parámetros variables en la identificación de los P_g se tuvieron en cuenta los resultados cuantitativos derivados del proceso de ajuste de parámetros descrito en el apartado 1.3.1.

En la Figura 1.16 se representa gráficamente la variación de los errores Te (Figura 1.16a), Tle (Figura 1.16b) y $Tlle$ (Figura 1.16c) (eje Y) en función de los valores que toman los parámetros C_S , C y δ_h (eje X) teniendo en cuenta todas las muestras (en gris), las muestras urbanas (en malva) y las muestras rurales (en verde). El valor de percentil del 68.3% para cada tipo de error se dibuja como una línea horizontal. En cuanto a la interpretación de estos gráficos y de manera simplificada, variaciones en los valores de cada factor (parámetros variables) tendrán menor influencia en los errores cuanto menor sea el recorrido de las líneas verticales que contienen los niveles de dichos factores.

Si se consideran los resultados empleando todas las muestras de manera conjunta (datos en gris en la Figura 1.16), se observa como

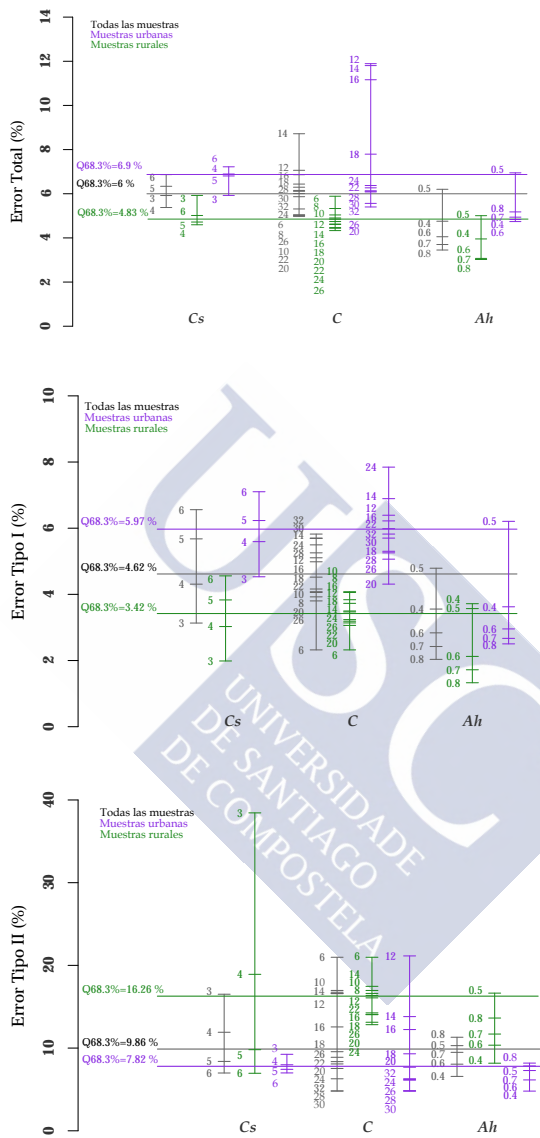


Figura 1.16: Influencia de los parámetros variables en la precisión del filtrado usando los resultados del ajuste de parámetros para todas las muestras (en gris), las urbanas (muestra 11 a muestra 42, en malva) y las rurales (muestra 51 a muestra 71, en verde).

fluctuaciones del parámetro C_S tienen menos repercusión en el Te que si éstas se dan en el parámetro C , mientras que la influencia de estos parámetros en los valores del $IIIe$ y $TIIe$ son similares pero sin perder de vista la diferencia de número de niveles que presenta cada parámetro. Tal como se esperaba, existe una relación directa entre los valores del parámetro C_S y el $TIIe$, de forma que cuanto menor es el valor de dicho parámetro menor es el $TIIe$ pues mayor es el número de puntos semilla seleccionados y por tanto mayor la probabilidad de seleccionar P_g . Sin embargo, como consecuencia directa de dicha circunstancia también aumenta la probabilidad de seleccionar erróneamente como puntos terreno aquellos puntos clasificados como P_{ng} , aumentando así el $IIIe$. Este hecho se refleja en la gráfica que relaciona los diferentes parámetros con el $IIIe$, donde los valores del parámetro C_S se disponen en orden decreciente a medida que el $IIIe$ aumenta.

En el caso del $TIIe$ los niveles del parámetro C no se distribuyen de forma ordenada, sin embargo sí es posible identificar un patrón de comportamiento en el caso del $IIIe$, de forma que se establece una relación inversa entre el $IIIe$ y el parámetro C . La lógica de esta relación puede residir en la influencia que dicho parámetro tiene en la fase de depurado, donde es necesario que tome valores elevados con el fin de eliminar los puntos pertenecientes a grandes edificios.

El análisis de la influencia del parámetro δ_h sobre los diferentes errores debe llevarse con cautela, pues en total se tienen 660 resultados variando los parámetros C y C_S y manteniendo constante el parámetro δ_h (valor 0.5), frente a los 64 resultados donde se varió este último parámetro manteniendo constantes los dos primeros. Es posible que este sea el motivo por el que los niveles del parámetro δ_h no se disponen de manera ordenada a lo largo de la línea vertical sobre la que se representan. Sin embargo, si prescindimos del nivel 0.5 se observa que cuanto mayor es el valor del δ_h menor es el $TIIe$ y el Te , y mayor el $IIIe$. La lógica de este comportamiento es la misma que se expuso para explicar la influencia del parámetro C_S sobre los diferentes errores.

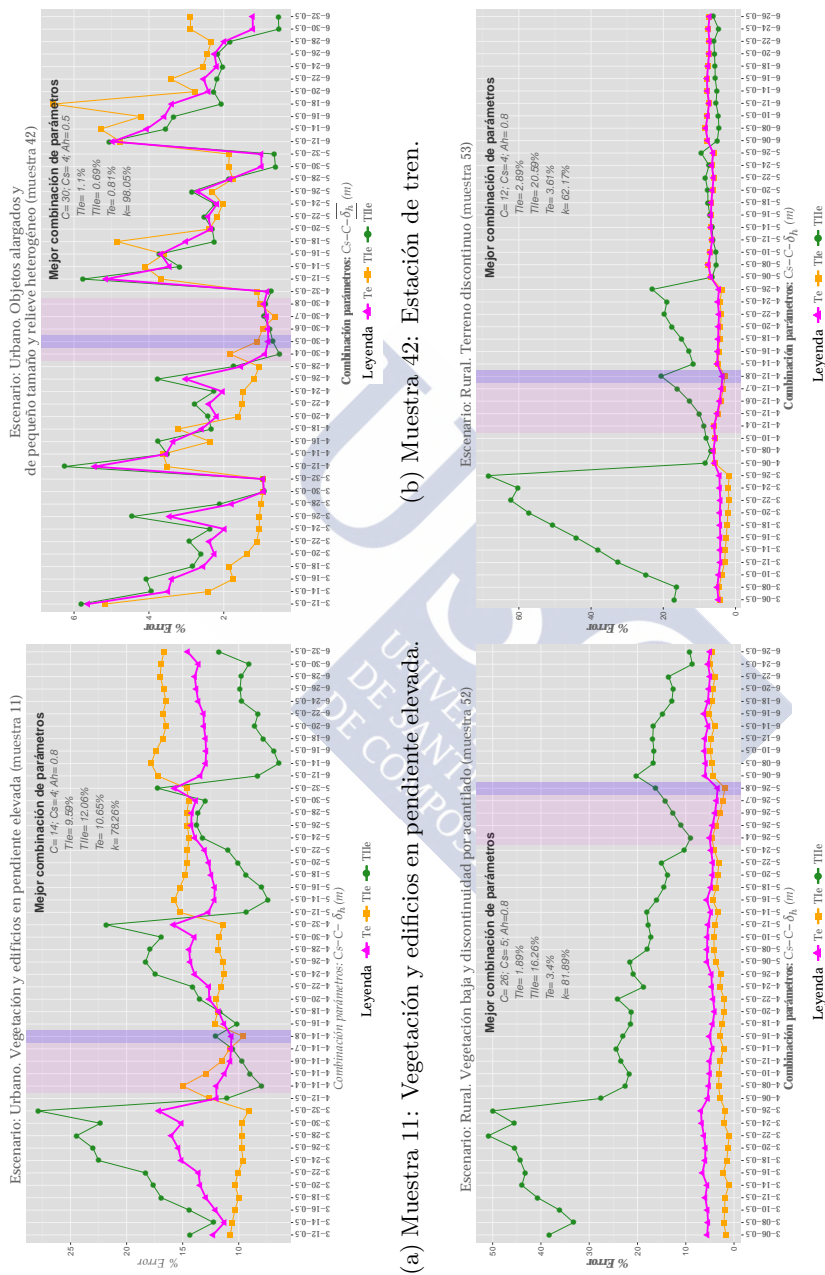
Para comprobar si el tipo de entorno genera diferentes relaciones entre los parámetros variables y los tres tipos de error o hace más evidentes las que fueron identificadas teniendo en cuenta todas las

muestras, se realizó el mismo análisis contemplando por un lado las muestras urbanas (muestra 11 a muestra 42 - en malva en la Figura 1.16) y por otro las muestras rurales (muestra 51 a muestra 71 - en verde en la Figura 1.16). Considerando las muestras urbanas se aprecia un comportamiento similar al que se observó considerando todas las muestras, aunque es más evidente la influencia que ejercen sobre el Te las variaciones del parámetro C . Sin embargo, no sucede lo mismo en el caso de las muestras rurales, pues la influencia del parámetro C_S no se diferencia mucho de la que ejerce C en los valores del Te . Si bien al tener en cuenta todas las muestras no fue posible establecer una relación clara entre C y el Te , al considerar por separado las muestras urbanas de las rurales sí se observa una relación inversa entre ellos, donde el Te disminuye a medida que el valor de C aumenta.

Atendiendo al $TIIe$, la influencia de los parámetros variables sobre dicho error no se diferencia mucho de lo descrito anteriormente. Sin embargo, sí existen ciertas diferencias en cuanto a la influencia de los diferentes parámetros sobre el $TIIe$. En zonas urbanas, variaciones de C tiene mucha más repercusión sobre dicho error que si las variaciones se dan en C_S . En las zonas rurales sucede lo contrario, variaciones en ambos parámetros influyen en el Te casi por igual, mientras que variaciones de C_S afectan en mayor medida al $TIIe$ que variaciones de C . Una explicación puede ser que en las zonas urbanas la mayor parte de los P_{ng} pertenecen a grandes edificaciones, en cambio en las zonas rurales éstos representan la vegetación o edificaciones de pequeño tamaño. En las zonas urbanas, si el valor del parámetro C es inferior al tamaño de la mayor edificación existente en la zona se desencadenarán una serie de sucesos: primero, el proceso de depurado fallará en las cubiertas de los edificios cuyo tamaño es mayor que el valor de C ; a continuación, algunos de estos P_{ng} no depurados serán seleccionados como puntos semilla y finalmente, en el proceso de densificación, la gran mayoría de los puntos de dichas cubiertas serán clasificados como puntos terreno. De esta forma, el volumen de puntos erróneamente clasificados como terreno será mucho mayor que si el error se produce en una edificación de menor tamaño o en una zona con vegetación (característico de las zonas rurales), ocasionando que el $TIIe$ alcance valores muy elevados casi con independencia del valor que tome C_S . Esta circunstancia deja de cumplirse cuando el valor del parámetro C es mayor que el tamaño de

las edificaciones presentes en la zona, de esta forma su influencia sobre el $TIIIe$ disminuye considerablemente.

Los resultados incluidos en la Figura 1.17, donde se representan de manera individual para cada muestra los valores de los tres tipos de error en función de los parámetros C y C_S , respaldan la deducción anterior. En las muestras urbanas (Figura 1.17a y 1.17b), la representación gráfica del $TIIIe$ y consecuentemente del Te , muestran una apariencia *dentada*, reflejo de la influencia de la variación del parámetro C . Por el contrario, las Figuras 1.17c y 1.17d, representantes de muestras rurales, se aprecia una disminución progresiva y suave de los errores a medida que C_S aumenta casi con independencia del valor que toma C . En estos últimos casos no se aprecia como valores altos del $TIIIe$ repercuten negativamente en el Te cuya variación es mínima en paralelo a los valores del $TIIe$ (en las Figuras A.27 a A.41 del Anexo A.5 se han incluido los resultados individuales para cada muestra.). Esta diferencia de comportamiento entre las muestras urbanas y rurales tomadas como ejemplo puede deberse a la proporción de P_g en la nube de puntos. En el caso de los ejemplos urbanos, en la muestra 11 hay 1.3 P_g por cada P_{ng} y en la muestra 42, 0.4 P_g por cada P_{ng} . Sin embargo, para los ejemplos rurales la situación es muy distinta, pues la proporción de P_g es mucho mayor (en la muestra 52 hay 8.5 P_g por cada P_{ng} y en la muestra 53, casi 24 P_g por cada P_{ng}). Esta reflexión también podría extenderse al comportamiento de otros filtros durante el proceso de la selección de los puntos semilla (Chen et al., 2013, Hu et al., 2014).



(d) Muestra 53: Terreno discontinuo.

(c) Muestra 52: Pendiente.

Figura 1.17: Influencia de la variación de los parámetros C y S en los errores Tle , Tt e Tt .

1.3.3 Evaluación externa y comparación con otros filtros

1.3.3.1 Resultados de DTMOFLabTe

La Tabla 1.5 contiene los resultados de la precisión del filtrado empleando DTMOFLabTe a partir de las 15 muestras de referencia proporcionadas por el ISPRS y las métricas propuestas por Sithole y Vosselman (2004). En esta tabla se indican los valores óptimos de los parámetros variables para cada muestra, los errores TIE , $TIIe$ y Te y el coeficiente Kappa que les corresponde, así como los obtenidos a partir de la combinación única. En este último caso: $C_S = 4$ m y $\delta_h = 0.5$ m; y en las zonas urbanas $C = 30$ m mientras que en las zonas rurales es de 20 m. En la última fila se incluyen los valores generales de los errores teniendo en cuenta todas las muestras. En estudios previos, el cálculo de la precisión global del filtrado se obtuvo a partir de la media de los errores de las 15 muestras (Pingel et al., 2013, Zhang y Lin, 2013, Hu et al., 2014). Aunque esta forma de representar los errores globales es la más simple, no tiene en cuenta las proporciones de puntos de cada tipo frente al total. Así, para intentar mitigar esta limitación y calcular los errores y coeficiente Kappa genéricos, en este estudio se empleó el número total de puntos de todas las áreas de referencia clasificados correcta e incorrectamente como P_g y P_{ng} (parámetros a, b, c y d en la Tabla 1.4). Complementariamente, las Figuras 1.18 y 1.19 muestran la distribución espacial de los errores para las muestras 11, 12, 21, 41, 42, 52 y 53 mediante la representación de los verdaderos positivos (TP - parámetro a); falsos positivos (FP - parámetro b); falsos negativos (FN - parámetro c) y verdaderos negativos (TN - parámetro d). Los resultados para el resto de muestras se incluyen en las Figuras A.42 - A.56 en el Anexo A.7 y los enlaces a las gráficas 3D en las Tablas A.24 y A.25 del Anexo A.7.

Tabla 1.5: Resultados de la evaluación de **DTMofLabTe** empleando los datos de referencia de la **ISPRS** y la combinación óptima de parámetros variables. Los valores de los parámetros variables de la combinación única son $C_S=4$, $\delta_h=0.5$ y $C=30$ para las muestras urbanas, y $C=20$ para las muestras rurales.

Muestra	P. variables			Resultados óptimos (%)			R. combinación única (%)			
	C	C_S	δ_h	$Tlle$	Tll_e	Te	$Tlle$	Tll_e	Te	K
Muestra 11. Pendiente elevada.	14	4	0.8	9.59	12.06	10.64	11.76	16.90	13.95	71.44
Muestra 12. Edificios y coches.	18	3	0.5	2.33	2.65	2.49	3.06	3.16	3.11	93.78
Muestra 21. Pendiente elevada.	26	3	0.5	0.22	3.76	1.00	0.21	3.90	1.03	96.99
Muestra 22. Puentes y pasarela.	26	3	0.6	3.80	7.84	5.06	5.86	6.90	6.19	85.82
Muestra 23. Edificios y terreno discontinuo.	22	3	0.6	5.49	5.86	5.67	11.16	4.30	7.91	84.19
Muestra 24. Rampa.	20	3	0.5	2.74	9.18	4.51	5.43	7.82	6.09	85.03
Muestra 31. Grandes edificios.	20	5	0.4	0.80	1.72	1.22	0.53	2.41	1.40	97.19
Muestra 41. Outliers (efecto multi-path).	28	3	0.5	2.12	1.23	1.67	2.71	1.05	1.88	96.24
Muestra 42. Estación de tren.	30	4	0.5	1.10	0.69	0.81	1.10	0.69	0.81	98.05
Muestra 51. Vegetación en pendiente.	26	6	0.5	0.47	6.42	1.77	0.18	18.95	4.28	86.59
Muestra 52. Pendiente elevada.	26	5	0.8	1.89	16.26	3.40	2.01	21.30	4.04	78.14
Muestra 53. Terreno discontinuo.	12	4	0.8	2.89	20.59	3.60	4.17	17.64	4.72	56.25
Muestra 54. Edificios de baja resolución.	12	4	0.5	1.93	2.79	2.39	1.73	4.58	3.26	93.45
Muestra 61. Bordes agudos y zanjas.	6	3	0.8	0.62	11.77	1.00	3.03	2.90	3.03	67.37
Muestra 71. Puente y terreno discontinuo.	20	5	0.8	0.59	7.18	1.34	1.23	6.84	1.87	90.81
Todas las muestras ^a				2.62	4.70	3.34	3.94	5.63	4.52	90.04

^a Estadísticos obtenidos a partir de todos los puntos correcta e incorrectamente clasificados como P_g y P_{ng} (a, b, c y d -Tabla 1.4).

En relación a los *resultados óptimos*, en el 80% de los casos el Te es inferior al 4.5% y el coeficiente Kappa superior al 88%. Si se tienen en cuenta todas las muestras, el Te y K son 3.34% y 92.62%, respectivamente. Los mismos estadísticos empleando la combinación única de parámetros muestran resultados ligeramente peores, 4.52% y 90.04%, respectivamente. En función del tipo de muestra, se observa que **DTMofLabTe** logra mejores resultados en las zonas urbanas, donde $K=92.18\%$, que en zonas rurales ($K=88.73\%$) (Tabla 1.7). En las primeras, la mayoría de los resultados son muy satisfactorios, principalmente en entornos que presentan grandes edificios y pequeños objetos ($K_{M12}=95.02\%$, Figura 1.18b - ver gráfico 3D y $K_{M31}=97.54\%$ - ver gráfico 3D); puentes ($K_{M21}=97.06\%$, Figura 1.18c - ver gráfico 3D) o discontinuidad en los datos ($K_{M41}=96.65\%$, Figura 1.19a - ver gráfico 3D y $K_{M42}=98.05\%$, Figura 1.19c- ver gráfico 3D). Estos resultados se deben fundamentalmente a la efectividad del proceso de depurado eliminando los P_{ng} pertenecientes a grandes edificaciones. Prueba de ello es el coeficiente Kappa calculado a partir de la nube de puntos depurada (Figura 1.10): $K_{M12-D}=89.53\%$, $K_{M21-D}=91.32\%$, $K_{M31-D}=90.63\%$, $K_{M41-D}=96.29\%$ y $K_{M42-D}=95.11\%$. De esta forma, fue posible disminuir el tamaño de ventana C_S en la selección de los puntos semilla dando lugar a una primera aproximación de la superficie del terreno muy precisa. En cambio, las zonas rurales no presentan grandes edificaciones, punto donde reside la fortaleza del proceso de depurado y motivo por el que no fue tan determinante en estas zonas como en las urbanas. Además, se produjeron algunos errores en áreas con elevada pendiente, eliminando erróneamente puntos P_g y creando huecos en la nube de puntos, caso de la muestra 52 (Figura 1.12h).

Por otro lado, las muestras 11 y 53 son las que presentan los peores resultados. Empleando la combinación óptima de parámetros, $Te_{M11} = 10.64\%$ y $K_{M53} = 62.21\%$. En el caso de la muestra 11 (Figura 1.18a - ver gráfico 3D), los errores se deben principalmente al elevado número de falsos positivos ubicados en las cubiertas con poca pendiente de algunas edificaciones (zona sur de la muestra), mientras que en la zona más al norte el problema se centra en la identificación errónea de puntos que representan pequeños objetos y/o vegetación baja, todo ello unido a una orografía compleja. Estos errores tienen su origen en la baja efectividad del proceso de depurado (Figura 1.10 y

Figura 1.11b). También existe un elevado número de falsos negativos situados principalmente en las líneas de rotura, como es el caso de algunas cunetas, donde se produce un cambio brusco de pendiente. La muestra 53 (Figura 1.19d - ver gráfico 3D) representa una zona rural donde el 95% de los puntos son P_g distribuidos sobre un terreno escarpado sin edificaciones. El elevado porcentaje de P_g presentes en la muestra (23.8 P_g por cada P_{ng} - Tabla 1.2) ocasiona que los errores de omisión ($TIE_{M53} = 2.89\%$) tengan mucha más influencia en la magnitud de Te y K que el $TIIe$, aunque éste supere el 20%. Los principales errores de omisión se encuentran en las líneas de rotura en barrancos. Estos errores probablemente se deben a una sucesión de fallos durante el filtrado. Primero en la selección de los puntos semilla, pues en estas zonas dichos puntos se seleccionan en la parte inferior del barranco y no en el borde superior. En segundo lugar, durante el proceso de densificación, pues el interpolador TPS tiende a suavizar estas zonas de transición produciendo un modelo con una elevación inferior a la real en dichas zonas. Así, los puntos en el borde superior del barranco tienen residuales mucho mayores que el permitido, y por tanto dichos puntos no son seleccionados. Estos errores pueden reducirse aumentando el valor del parámetro δ_h , a riesgo de producir un aumento de los errores de comisión debido a la presencia de vegetación baja. Las características de estas áreas, vegetación y edificaciones en pendiente elevada y regiones escarpadas, provocan que la mayoría de los filtros analizados presenten dificultades en estos entornos (Figura 1.20).

1.3.3.2 Comparación con otros algoritmos de filtrado

Para llevar a cabo el análisis comparativo entre los resultados de **DTMofLabTe** y los obtenidos a partir de otros filtros, se han tenido en cuenta 23 estudios desarrollados entre 1998 y 2016. En la Tabla 1.6, para cada uno de los estudios y muestras de referencia, se incluyen los valores del coeficiente Kappa, mientras que en la Figura 1.20 se representa mediante diagramas de barras los errores TIE , $TIIe$ y Te (en el caso de los estudios de [Shao y Chen \(2008\)](#), [Chang \(2010\)](#) y [Hu et al. \(2014\)](#)), al igual que para **DTMofLabTe**, se han tomado los resultados obtenidos al emplear la combinación óptima de parámetros).

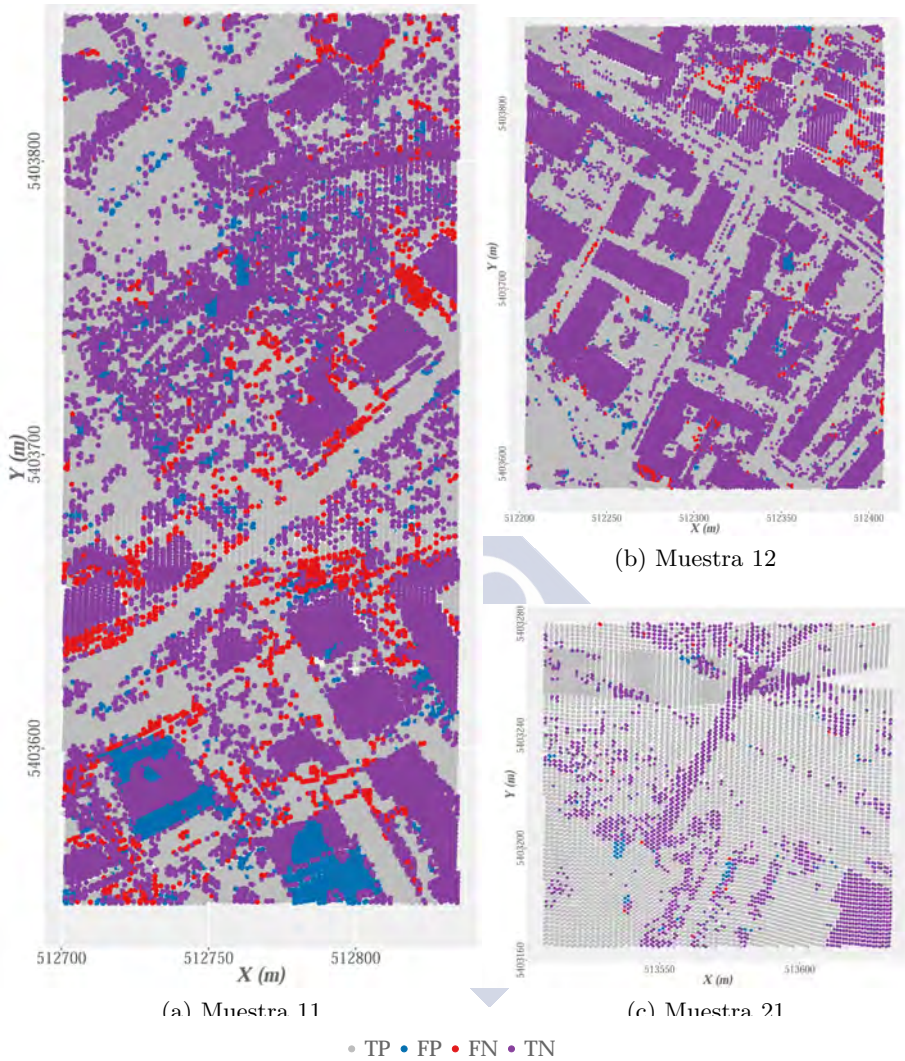


Figura 1.18: Resultados cualitativos del proceso de filtrado (parte 1).

Adicionalmente, en la Tabla 1.7 se incluyen los resultados genéricos para cada uno de los 23 estudios, teniendo en cuenta todas las muestras y diferenciando entre muestras urbanas y rurales. Los valores de K y los estadísticos genéricos para los 23 estudios considerados en este análisis se han recalculado a partir de los valores de los errores incluidos en dichos

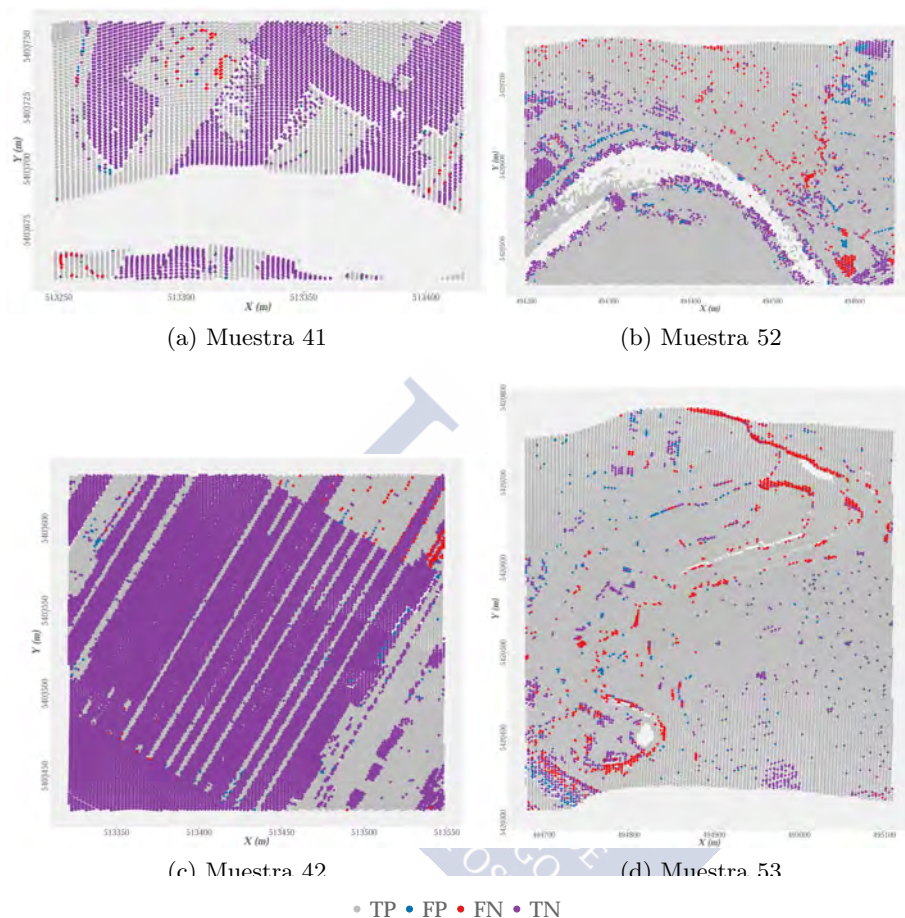


Figura 1.19: Resultados cualitativos del proceso de filtrado (parte 2).

estudios y el número de P_g y P_{ng} de cada muestra (datos incluidos en la Tabla 1.2). Finalmente, en la Figura 1.21 se comparan los resultados de varios estudios empleando una combinación única de parámetros.

Los resultados de las Tablas 1.6 y 1.7 demuestran la efectividad general de **DTMofLabTe**, el cual se encuentra entre los tres que ofrecen las mayores precisiones. Teniendo en cuenta todos los puntos de las 15 muestras y empleando la combinación óptima de parámetros se tiene que $Te = 3.34\%$ y $K = 92.62\%$. Estos resultados sólo son

mejorados por los del algoritmo morfológico de [Pingel et al. \(2013\)](#) ($Te = 3.01\%$ y $K = 93.33\%$) y los del algoritmo de superficie adaptativa de [Hu et al. \(2014\)](#) ($Te = 2.87\%$ y $K = 93.63\%$). En función del tipo de muestra, todos los algoritmos logran mejores resultados en las áreas urbanas que en las rurales, a excepción del filtro implementado en *TerraScan* ($K_{Urb} = 79.8\%$ y $K_{Rur} = 85.7\%$). [Mongus y Žalik \(2012\)](#) atribuyó el mejor funcionamiento del algoritmo de *TerraScan* en zonas rurales a la calidad de los datos de entrada, concretamente a la densidad de puntos, mucho menor en las zonas rurales que en las urbanas. Sin embargo, es posible que tenga más que ver con la selección de los parámetros de filtrado que con la densidad de puntos, ya que el algoritmo implementado en *TerraScan* es una adaptación del algoritmo propuesto por [Axelsson \(1999\)](#) y éste obtiene un K en las zonas urbanas mucho mayor que el obtenido por *TerraScan* ($K_{Axelsson-Urb} = 90.1\%$ y $K_{TerraScan-Urb} = 79.8\%$).



Tabla 1.6: Comparación del coeficiente Kappa para cada muestra de referencia con 23 trabajos previos. Las celdas en color lila indican los mejores resultados para cada muestra entre todos los métodos.

Autor	S11	S12	S21	S22	S23	S24	S31	S41	S42	S51	S52	S53	S54	S61	S71
Pfeifer et al. (1998)	66.3	91.1	92.8	85.2	83.7	79.2	96.4	78.6	93.8	89.6	41.2	31.1	90.1	47.1	66.8
Axelsson (1999)	78.6	93.6	86.2	91.4	92.0	88.8	90.5	72.4	96.2	91.7	83.7	39.4	70.7	74.5	91.5
Elmqvist et al. (2001)	58.9	84.2	54.9	69.3	76.6	52.1	88.7	84.8	93.6	30.1	3.3	0.6	88.9	0.7	6.9
Roggero (2001)	59.9	86.9	75.7	54.7	54.9	54.5	95.7	75.8	89.7	91.2	60.8	25.8	50.1	21.8	78.3
Sithole (2001)	55.5	79.9	80.2	59.4	55.8	50.7	93.7	51.3	90.8	80.7	31.1	10.6	84.5	19.2	40.8
Brovelli et al. (2002)	32.2	67.9	76.6	56.6	46.1	35.8	74.6	67.2	84.2	50.4	15.9	6.0	87.2	19.2	25.5
Sohn y Dowman (2002)	59.5	83.2	76.1	82.3	80.2	68.6	87.1	77.6	95.7	75.5	55.0	20.3	93.5	67.5	89.1
Wack y Wimmer (2002)	54.1	86.9	87.6	83.5	78.3	74.3	95.6	81.9	91.6	71.4	36.4	16.8	88.5	29.7	48.3
Lu et al. (2008)	43.2	80.5	69.1	72.9	78.7	64.6	89.8	73.9	88.3	82.8	57.2	17.9	86.9	46.2	62.9
Shao y Chen (2008)	76.0	92.0	87.2	87.6	90.4	87.7	97.6	90.1	94.8	88.9	85.6	55.0	94.5	80.7	84.7
Shao y Chen (2008) ^a	75.9	92.0	87.2	85.9	90.4	87.7	97.5	90.1	94.8	88.4	85.6	55.0	93.8	80.7	82.6
Chang (2010) (SMSM)	72.2	93.0	96.4	93.9	91.9	84.3	97.5	85.9	96.8	90.5	79.6	60.8	94.4	82.9	89.3
Chang (2010) (SMSM) ^a	68.9	91.2	95.3	90.9	91.9	83.9	93.4	85.0	95.0	88.2	77.5	52.2	93.5	72.4	87.7
Chang (2010) (SSA)	78.1	94.3	95.0	92.2	90.6	86.7	97.9	93.9	96.6	89.3	84.9	69.5	91.4	81.0	88.2
Mongus y Žalik (2012)	77.3	89.7	94.1	84.7	88.3	80.0	93.3	92.6	87.0	92.2	68.4	42.1	86.6	65.1	85.0
TerraScan ^b	68.4	77.0	71.4	76.8	84.0	71.0	82.6	74.2	91.9	98.9	78.4	62.8	83.1	78.4	90.9
Yan et al. (2012)	62.8	86.7	82.0	75.4	68.8	55.7	92.3	71.9	87.8	81.6	57.5	24.4	84.1	33.9	52.7
Chen et al. (2013)	74.1	93.2	96.1	89.0	89.5	84.5	97.8	88.8	95.8	95.2	78.9	46.7	93.8	77.4	93.2
Li (2013)	74.3	92.5	92.8	90.6	87.7	86.1	95.0	86.6	92.8	88.5	47.1	33.1	92.1	50.0	79.2
Pingel et al. (2013)	83.1	94.1	96.8	92.2	90.7	91.1	98.2	88.2	96.5	95.8	81.0	68.2	95.4	87.3	91.8
Zhang y Lin (2013)	63.4	88.2	84.9	70.1	76.0	55.6	95.3	59.1	90.3	83.9	50.6	44.8	87.2	25.0	59.5
Hu et al. (2014)	83.0	94.8	97.2	92.4	91.2	90.4	98.2	88.2	98.3	93.9	86.2	59.6	95.3	86.8	92.6
Hu et al. (2014) ^a	82.8	94.0	94.3	91.8	90.5	89.5	93.4	87.5	97.1	91.5	83.7	53.1	94.6	71.1	90.5
Mongus y Žalik (2014)	79.0	93.4	96.0	90.1	87.6	88.8	92.9	91.9	93.2	80.1	75.6	55.6	90.8	60.1	82.5
Hui et al. (2016)	72.9	93.0	93.4	87.6	89.7	81.9	97.3	78.8	95.4	85.1	69.5	41.8	91.6	67.8	79.9
Zhang et al. (2016)	75.2	94.0	90.5	77.7	90.4	92.7	96.8	89.7	96.2	91.1	77.1	46.9	93.6	78.1	68.0
DTMofLabTe	78.3	95.0	97.1	88.2	88.6	88.6	97.5	96.7	98.1	94.7	81.9	62.2	95.2	85.3	93.3
DTMofLabTe ^a	71.4	93.8	97.0	85.8	84.2	85.0	97.2	96.2	98.1	86.6	78.1	56.3	93.5	67.4	90.8

^a Resultados empleando un conjunto de parámetros único. Para **DTMofLabTe**: $C_S=4$, $\delta_h=0.5$ y $C=30$ para las muestras urbanas, y $C=20$ para las muestras rurales.

^b in Mongus y Žalik (2012).

Tabla 1.7: Comparativa y resumen de los resultados generales del **DTMofLabTe** (en naranja) con 23 trabajos previos. En color lila se indican los mejores resultados empleando los parámetros optimizados y una combinación única.

Autor	Muestras Urbanas (%)			Muestras Rurales (%)			Todas las muestras (%)					
	TTe	Tle	Te	TTe	Tle	Te	TTe	Tle	Te			
Pfeifer et al. (1998)	11.00	1.88	6.72	86.59	10.79	5.40	10.18	62.41	10.90	2.28	7.93	83.20
Axelsson (1999)	7.02	2.63	4.96	90.07	4.21	9.63	4.82	78.28	5.69	3.43	4.91	89.32
Elmqvist et al. (2001)	18.55	2.79	11.16	77.82	81.04	0.96	71.93	4.80	47.99	2.58	32.32	40.88
Roggero (2001)	22.29	1.36	12.48	75.29	14.72	4.67	13.58	54.49	18.73	1.74	12.86	73.65
Stthole (2001)	24.75	1.22	13.72	72.88	26.43	2.98	23.76	37.46	25.54	1.42	17.22	65.72
Brovelli et al. (2002)	34.91	1.63	19.31	62.07	38.53	2.11	34.39	25.82	36.62	1.69	24.56	53.17
Sohn y Dowman (2002)	10.43	7.83	9.21	81.55	10.03	7.01	9.68	63.34	10.24	7.74	9.37	79.82
Wäck y Wimmer (2002)	15.33	1.48	8.84	82.42	20.41	2.53	18.37	45.82	17.72	1.60	12.16	75.00
Lu et al. (2008)	20.22	3.47	12.37	75.44	9.86	15.56	10.51	58.88	15.34	4.86	11.72	75.48
Shao y Chen (2008)	6.40	3.29	4.94	90.10	2.33	9.96	3.20	84.67	4.49	4.06	4.34	90.51
Shao y Chen (2008) ^a	6.60	3.31	5.06	89.86	2.33	10.73	3.29	84.20	4.59	4.16	4.44	90.27
Chang (2010) (SMSM)	2.25	6.89	4.42	91.10	1.00	14.55	2.54	87.02	1.66	7.77	3.77	91.57
Chang (2010) (SMSM) ^a	2.13	9.12	5.41	89.10	2.52	13.09	3.72	82.06	2.31	9.57	4.82	89.21
Chang (2010) (SSA)	4.03	3.70	3.87	92.23	0.79	14.59	2.36	87.84	2.51	4.95	3.35	92.59
Mongus y Žalik (2012)	3.72	8.67	6.04	87.84	4.73	10.47	5.38	76.07	4.20	8.87	5.81	87.12
TerraScan ^b	16.91	2.52	10.17	79.78	2.59	6.72	3.06	85.67	10.17	3.00	7.69	83.61
Yan et al. (2012)	16.81	2.81	10.25	79.62	13.77	4.23	12.69	56.59	15.38	2.97	11.10	76.89
Chen et al. (2013)	6.00	3.29	4.73	90.52	3.23	6.62	3.62	83.41	4.70	3.67	4.34	90.51
Li (2013)	6.01	4.44	5.27	89.43	8.42	8.43	8.43	66.55	7.15	4.90	6.37	86.19
Pingel et al. (2013)	2.89	4.28	3.54	92.89	1.26	7.87	2.02	90.09	2.12	4.69	3.01	93.33
Zhang y Lin (2013)	14.78	4.14	9.79	80.48	9.58	14.75	10.17	60.02	12.33	5.36	9.92	78.94
Hu et al. (2014)	2.47	4.27	3.31	93.34	0.96	10.47	2.04	89.74	1.76	4.98	2.87	93.63
Hu et al. (2014) ^a	2.27	5.75	3.91	92.14	2.66	8.99	3.38	84.06	2.46	6.13	3.72	91.74
Mongus y Žalik (2014)	3.43	6.08	4.67	90.61	2.11	20.41	4.19	78.83	2.81	7.72	4.51	89.98
Hui et al. (2016)	5.94	4.48	5.25	89.46	3.71	14.85	4.98	76.73	4.89	5.67	5.16	88.68
Zhang et al. (2016)	2.80	7.57	5.03	89.87	2.11	15.70	3.66	81.90	2.47	8.50	4.55	89.83
DTMofLabTe	3.63	4.19	3.89	92.18	1.49	8.64	2.30	88.73	2.62	4.70	3.34	92.62
DTMofLabTe^a	5.15	4.78	4.97	90.02	2.59	12.16	3.68	82.39	3.94	5.63	4.52	90.04

^a Resultados empleando un conjunto de parámetros único. Para **DTMofLabTe**: $C_S=4$, $\delta_h=0.5$ y $C=30$ para las muestras urbanas, y $C=20$ para las muestras rurales.

^b in Mongus y Žalik (2012).

Desde el estudio realizado por [Sithole y Vosselman \(2004\)](#) hace más de una década, la precisión de los algoritmos no ha hecho más que aumentar y prueba de ello es que en los últimos cinco años se han mejorado los resultados en el 75% de las muestras (en la Tabla 1.6, las celdas sombreadas en lila indican los mejores resultados). El algoritmo **DTMofLabTe** empleando la combinación óptima de parámetros mejoró los resultados de los 23 trabajos previos en 3 de las 15 muestras (muestras 12, 41 y 71, valores sombreados en lila en la Tabla 1.6). [Sithole y Vosselman \(2004\)](#) también reflexionaron en su estudio sobre qué error debería ser reducido para mejorar la calidad del filtrado y aumentar la eficiencia de las tareas de corrección posteriores. Concluyeron que debería minimizarse el *TIE* basándose en el coste de cometer dicho error en relación a la aplicación del modelo final; y desde un punto de vista más operativo, en el coste de depurado manual de dichos errores, afirmando que así el *Te* también se vería reducido. Esta premisa se cumple fundamentalmente en áreas donde el número de P_g es significativamente superior al número de P_{ng} ($P_g/P_{ng} \gg 1$). En estos casos, el *TIE* influye mucho más que el *IIIe* en la precisión general del filtrado que si el número de P_g y P_{ng} estuviese más equilibrado ($P_g/P_{ng} \simeq 1$). En el primer caso se encuentran las muestras 53 y 61 (en la Tabla 1.2 se indica que presentan los ratios más elevados, 23.8 y 28.1 P_g por cada P_{ng} , respectivamente), en donde más del 95% de los puntos pertenecen a la clase terreno. Con respecto a la muestra 53, los algoritmos desarrollados hasta 2004 presentan un *TIE* mucho más elevado que el resto de casos y un *IIIe* bajo, mientras que éste es mucho más elevado en los algoritmos desarrollados en la última década (Figura 1.20). Como resultado para esta muestra y aquellas que presentan características similares, se tiene que el *Te* es tanto más alto cuanto más lo sea el *TIE*.

Posiblemente la reflexión anterior se deba a que los algoritmos incluidos en el estudio de [Sithole y Vosselman \(2004\)](#) no buscaron minimizar los *TIE*, sino los *IIIe*. Sin embargo, los filtros desarrollados en la última década sí lo han hecho aunque a costa de aumentar los errores de comisión. Considerando conjuntamente los resultados de los 8 primeros algoritmos se tiene que la media de los errores de omisión y comisión es de 21.68% y 2.81%, respectivamente, frente al 5.91% y 5.42% teniendo en cuenta los filtros desarrollados desde 2004. Esta

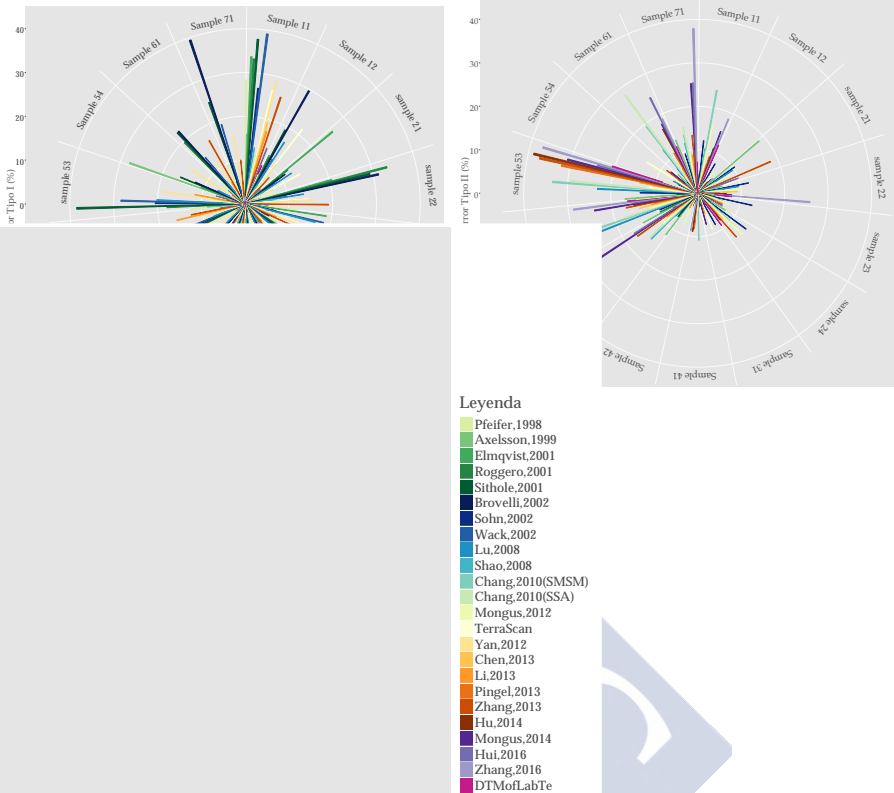


Figura 1.20: Resultados de los errores TIE , $TIIe$ y Te obtenidos en este estudio y en 23 trabajos previos para cada muestra de referencia.

circunstancia se aprecia en los dos primeros gráficos de la Figura 1.20, donde en tonos verde y azul oscuro se representan los resultados incluidos en el estudio de Sithole y Vosselman (2004) y en tonos azul claro, tierra y malva los resultados de los algoritmos desarrollados después de 2004. En el gráfico que representa el Te en la Figura 1.20 se observa como el primer grupo de filtros presentan errores mucho mayores que los algoritmos más recientes, diferencia que no se aprecia en los $TIIe$. Dentro del grupo de los algoritmos posteriores al estudio de Sithole y Vosselman (2004) existen algunas excepciones como la de Lu et al. (2008), donde en muchos casos los $TIIe$ son inferiores a los TIE (teniendo en cuenta todas las muestras: $TIE_{Lu}=15.34\%$ y $TIIe_{Lu}=4.86\%$).

La idea que los llevó a minimizar los errores de comisión fue que consideraron que estos errores producen efectos más negativos en el modelo final que los errores de omisión, los cuales simplemente reducen el nivel de detalle con el que se representa la superficie del terreno. Esto se debe a que los *TIIe* modifican de manera abrupta la superficie colindante siendo mucho más evidente la presencia de este tipo de errores en el modelo final que los errores de omisión, fundamentalmente si los puntos pertenecen a edificaciones (Pingel et al., 2013). A pesar de que este planteamiento es contrario a la tendencia que se observa en los últimos años, estos autores hacen una observación muy interesante que refuerza su postura. Exponen que un punto mal clasificado como terreno tiene más impacto en el modelo final si éste pertenece a un tejado que si representa vegetación baja. Este impacto será dramáticamente mayor si el punto es añadido en la fase de selección de puntos semilla que en el proceso de densificación. Por tanto, la reflexión de Sithole y Vosselman (2004) podría matizarse de forma que, para aumentar la precisión general del filtrado se recomienda minimizar los *TIIe* aún a riesgo de aumentar los *TIIe* pero siempre y cuando los errores de comisión no se deban a la incorrecta selección de puntos pertenecientes a la cubierta de edificaciones. **DTMofLabTe** cumple con esta regla gracias a la efectividad del proceso de depurado en las zonas edificadas. Como última nota, añadir que en el caso de Sithole y Vosselman (2004) su reflexión va encaminada a mejorar la precisión del filtrado, mientras que la de Lu et al. (2008) está centrada en mejorar la precisión del modelo. Si bien en la mayoría de los casos un aumento de la precisión del filtrado lleva aparejado un aumento de la precisión del modelo final, aun a riesgo de parecer contradictorio, no siempre sucede así.

Otros autores (Hu et al., 2014) también hicieron alusión a esta tendencia en sus estudios, indicando que esta circunstancia se da fundamentalmente en aquellos filtros que incluyen un proceso de densificación (Chang, 2010, Mongus y Žalik, 2012). Por un lado achacaron el aumento del *TIIe* al hecho de que el número de P_{ng} era muy inferior al de P_g en alguna de las muestras (por ejemplo, las muestras 53 y 61), provocando que pocos P_{ng} clasificados erróneamente como P_g ocasionen un elevado *TIIe*. Sin embargo, es posible que el motivo principal no sea la cantidad de puntos sino la cobertura que representan, en la mayoría de los casos vegetación baja, unido a su

emplazamiento en terrenos con elevada pendiente. Probablemente, si estos P_{ng} representasen edificaciones, el $THIe$ sería mucho menor, pues en las zonas rurales las construcciones tienen un tamaño menor que las de las zonas urbanas. También vincularon estos errores con la estrategia de densificación de los filtros, razón que está estrechamente ligada a la anterior. En terrenos con elevada pendiente, los filtros que incluyen un proceso de densificación basado en diferencias de elevación entre las superficies intermedias y la nube de puntos, tienden a asignarle valores altos al parámetro que regula este proceso con el propósito de disminuir los errores de omisión. Por ejemplo, en el caso de **DTMofLabTe** para la muestra 53, el parámetro δ_h alcanzó su valor máximo (0.8 m) al igual que el $THIe$ (20.59%). Para la misma muestra, el parámetro THI en Chang (2010) también tomó el valor más alto ($THI = 2.6$ m) y $THIe$ alcanzó el valor máximo de 33.5%; de forma similar, el filtro de superficie adaptativa de Hu et al. (2014) produjo un error de comisión del 38.75% cuando el parámetro *max-bend-gain* toma el valor máximo de 1 m.

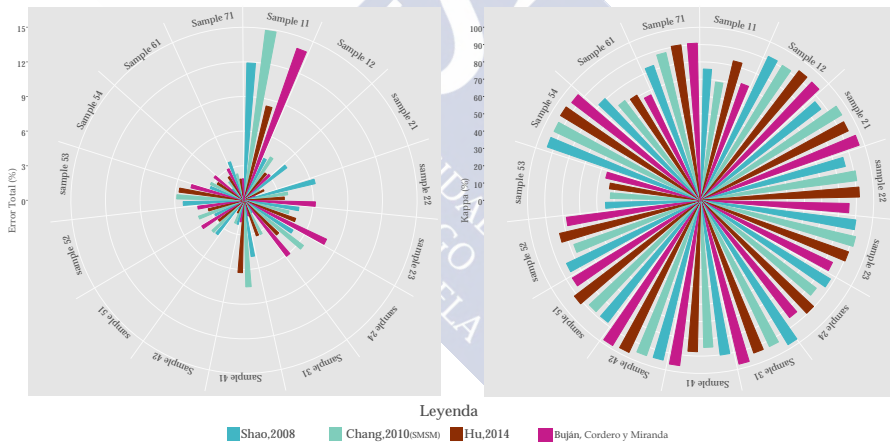


Figura 1.21: Comparación del error Te y el coeficiente Kappa de cada muestra de referencia con los resultados de Shao y Chen (2008), Chang (2010), Hu et al. (2014) a partir de una combinación única de parámetros.

Para comprobar la robustez del filtro ante diferentes entornos, en este estudio, al igual que hicieron previamente Shao y Chen (2008), Chang (2010) ó Hu et al. (2014), también se calculó la precisión del algoritmo **DTMofLabTe** a partir de una combinación única de

parámetros ($C_S=4$, $\delta_h=0.5$ y $C=30$ para las muestras urbanas, y $C=20$ para las muestras rurales). Adoptando dicha combinación de parámetros se confirma la robustez del algoritmo **DTMofLabTe** frente a diferentes características del terreno ($K=90.04\%$). Sin embargo, existen ciertas diferencias en función del tipo de muestra, de forma que las muestras urbanas presentan menores oscilaciones con respecto a los resultados óptimos que las muestras rurales (dif-media- $K_{Urb}=2.2\%$ y dif-media- $K_{Rur}=6.7\%$, datos obtenidos a partir de los resultados de la Tabla 1.6). Esta tendencia también se aprecia claramente en los estudios de Chang (2010) y Hu et al. (2014), pero no en el caso de Shao y Chen (2008), donde las diferencias son mínimas constatando su fortaleza ante variaciones de los parámetros. También se observa de manera clara con estos ejemplos, al igual que empleando la combinación óptima de parámetros, como la muestra 11 es la que presenta el mayor Te mientras que el menor valor de K se da en la muestra 53 (Figura 1.21).

Finalmente, al igual que Hu et al. (2014), para reafirmar la robustez de **DTMofLabTe** se representaron mediante un histograma de frecuencias los Te obtenidos a partir de las 48 combinaciones de parámetros por muestra (Figura 1.22). Adicionalmente, para verificar si hay diferencias en el comportamiento del filtro en función del tipo de muestra, en el histograma se representaron de manera independiente los resultados de las zonas urbanas (malva) y rurales (naranja). Los errores en las zonas urbanas presentan mayor dispersión que los Te de las zonas rurales, que en su mayoría están concentrados entre el 1% y el 5.5% (más del

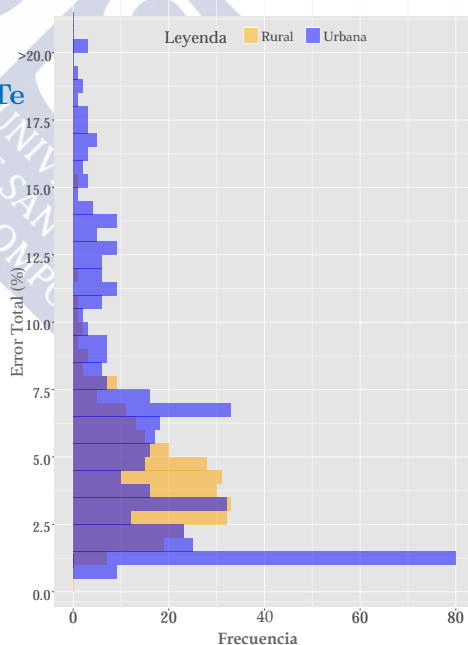


Figura 1.22: Distribución de los Te a partir de todas las combinaciones de parámetros para las muestras urbanas (malva) y rurales (naranja).

75% de todas las muestras rurales), mientras que sólo el 50% de las muestras urbanas presentan un Te inferior al 5%. Estos datos indican que el **DTMofLabTe** es más robusto en las zonas rurales que en las urbanas en relación al Te , aunque paradójicamente es en estas últimas donde se obtienen las mayores precisiones ($K_{Urb}=90.0\%$ y $K_{Rur}=82.4\%$) y las menor diferencia con respecto a los resultados empleando las combinaciones óptimas de parámetros en el caso del coeficiente Kappa. Finalmente, sin diferenciar el tipo de entorno, 662 muestras de 724 presentan un Te inferior al 12%. Estos resultados son muy similares a los aportados por [Hu et al. \(2014\)](#) en donde el 95% de las combinaciones presentaban un Te inferior al 10%.

1.4 Conclusiones

La identificación de P_g en una nube de puntos LiDAR es un proceso extraordinariamente difícil y complejo. A pesar de la gran cantidad de recursos invertidos para abordar esta problemática, hoy en día sigue considerándose un desafío, tanto desde el punto de vista de la efectividad y eficiencia como de la *usabilidad* y accesibilidad. En este artículo se presenta un nuevo algoritmo de filtrado, **DTMofLabTe**, compuesto por varias funciones implementadas en el programa libre R. Se trata de un filtro híbrido que combina un proceso de depurado, mediante el que se busca eliminar P_{ng} de edificaciones (función **DebCloud**), con un nuevo método de selección de puntos semilla (función **OWM**) y un proceso iterativo de densificación de la nube de puntos terreno. El empleo de estas funciones presenta una serie de ventajas. El depurado permite reducir el tamaño de la ventana móvil en la selección de los puntos semilla, principalmente en aquellas zonas que presentan edificaciones; y la reducción del tamaño de ventana, unido a su desplazamiento con solape longitudinal y transversal, permite seleccionar un mayor número de puntos semilla, dando lugar a una primera aproximación del terreno que es más precisa que la que se obtendría empleando los métodos tradicionales de selección de puntos semilla. Las principales conclusiones de este estudio se han agrupado en 6 bloques coincidentes con los diferentes puntos analizados en el apartado de resultados y discusión.

Estos son:

En cuanto al ajuste de parámetros ...

La tarea de identificación de los parámetros óptimos de filtrado es difícil, consume mucho tiempo y es muy laboriosa si no se cuenta con datos de referencia. Si bien todo ello es cierto, este esfuerzo puede verse compensado por un aumento de la efectividad y de la eficiencia del filtrado en trabajos posteriores. En este estudio se han optimizado los parámetros variables filtrando cada zona con diferentes combinaciones de parámetros. Se tomó como combinación óptima aquella que minimizó el Te . En general, este proceso permitió aumentar la precisión general del filtrado más de 2.5 puntos porcentuales (teniendo en cuenta todas las muestras, $K_{Opt}=92.62\%$ y $K_{Uni}=90.04\%$ para las combinaciones óptimas y única de parámetros, respectivamente). Con este proceso no sólo se pretendía aumentar la efectividad sino también mejorar la eficiencia de posteriores estudios. De este modo, se representó gráficamente y analizó el comportamiento del filtro ante variaciones de los parámetros en zonas con diferentes características. Este análisis puede servir como punto de partida al usuario final para optimizar los parámetros en otras regiones y simplificar esta tarea.

En cuanto a la efectividad del proceso de depurado ...

Se implementó la función [DebCloud](#) para eliminar los puntos de las edificaciones, más que los de la vegetación como paso previo a la selección de los puntos semilla. Esta función tiene un doble propósito: 1) disminuir el tamaño de ventana en la posterior selección de puntos semilla aumentando la cantidad de estos puntos 2) sin aumentar los errores de comisión producidos por la selección errónea de P_{ng} como terreno. Debido a su naturaleza, esta función es más efectiva en las zonas urbanas que en las rurales. Mientras que en las primeras en $\simeq 70\%$ de los casos el valor de K se encuentra por encima del 80%; en las segundas sólo se logra esta precisión en el 15% de las muestras.

Por otro lado, tras analizar los resultados de este proceso se han identificado las siguientes limitaciones:

- *Presencia de vegetación baja.* Aunque la función [DebCloud](#) incluye una fase para la eliminación de vegetación, ésta se centra en la

vegetación alta, donde la pendiente y diferencia de elevación entre un punto terreno y uno objeto es evidente. En el caso de la vegetación baja los valores de estas variables pueden confundirse con las debidas a variaciones del relieve. Se ha comprobado que este tipo de errores no dependen de la pendiente del terreno, pues se dan tanto en zonas llanas como abruptas.

- *Considerar puntos P_{ng} de edificaciones como puntos terreno.* Este tipo de errores se debe fundamentalmente a la existencia de edificaciones en zonas de elevada pendiente, donde la pendiente entre un punto P_g y uno P_{ng} es similar a la que se espera encontrar entre dos puntos terreno.
- *Eliminación errónea de puntos P_g .* Este tipo de fallos se producen principalmente en líneas de rotura, bordes de barrancos o en zonas de terraplén junto a carreteras, donde la pendiente del terreno es superior al parámetro automático Sl_{max} . En este caso sucede lo contrario a lo descrito en el punto anterior, el comportamiento del terreno en relación a la pendiente es similar al que se espera encontrar entre un punto P_{ng} y uno P_g .

Finalmente, en base a los resultados de este proceso se considera que en general el método de depurado ha demostrado su efectividad y su integración con otros algoritmos de filtrado puede repercutir positivamente en sus resultados (Anexo A.2).

En cuanto a la selección de los puntos semilla ...

A diferencia del método tradicional de selección de puntos semilla (LMM), el método OWM selecciona los mínimos locales a partir de una ventana móvil que se desplaza por el área de estudio manteniendo un solape longitudinal con respecto a la ventana anterior y otro transversal con respecto a las ventanas de la fila inmediatamente inferior. De esta forma, si el solape es del 80% cada punto es analizado 25 veces. Este proceso produce una redundancia en la nube de puntos semilla, puesto que un mismo punto puede ser seleccionado hasta un máximo de 25 veces siguiendo el ejemplo anterior. En base al supuesto de que los puntos seleccionados más veces tienen una mayor probabilidad de pertenecer al terreno, se han tomado como P_S aquellos puntos que han

sido seleccionados como mínimos dos veces. Adicionalmente, para evitar huecos en la nube de puntos semilla en zonas con elevada pendiente, estas zonas son detectadas automáticamente y nuevos mínimos locales son añadidos a la nube de puntos semilla.

La función **OWM** ha demostrado su versatilidad en cuanto a la posibilidad de ser ejecutado como LMM y su efectividad en la selección de P_S al seleccionar hasta 4 veces más puntos que el LMM. Además, la aplicación de **OWM** conjuntamente con **DebCloud** permitió seleccionar hasta 20 veces más P_S que en el caso de considerar la nube de puntos no depurada. Adicionalmente, el empleo de este método ha sido fundamental para la representación del terreno en zonas complejas y abordó satisfactoriamente alguna de las dificultades donde los filtros tienden a fallar, como es el caso de los patios interiores de edificaciones o zonas próximas a líneas de rotura o barrancos.

Al igual que en caso anterior, se considera que el resultado de gran variedad de filtros puede ser mejorado empleando este método de selección de mínimos locales, desde aquellos que requieren dichos puntos para generar una primera superficie de referencia hasta aquellos que los emplean como base para clasificar nuevos puntos terreno a partir de diferencias de elevación.

En cuanto a la influencia de los parámetros variables en la precisión del filtrado...

A partir de los resultados del proceso de optimización de parámetros, se han representado gráficamente y analizado los diferentes errores frente a la variación de los parámetros C_S , C y δ_h . En todos los casos se cumple la relación directa entre el $TIIe$ y el parámetro C_S y su relación inversa con el $TIIIe$. Por tanto, constituye un desafío encontrar un valor de C_S que logre el equilibrio entre el $TIIe$ y el $TIIIe$. Del análisis llevado a cabo para verificar si el tipo de entorno genera diferentes relaciones entre los parámetros variables y los errores, se observaron indicios de que los resultados teniendo en cuenta todas las muestras difieren de los que se obtienen en caso de hacer distinción en muestras urbanas y rurales. Como principal conclusión del análisis realizado y como recomendación para potenciales usuarios se tiene que en las zonas urbanas se debe prestar especial atención al valor del parámetro C por su influencia sobre

el Te , mientras que en el caso de las zonas rurales será el parámetro C_S el más relevante en relación al $TIIe$.

En cuanto a los resultados del filtrado ...

Los resultados teniendo en cuenta las 15 muestras de referencia de la ISPRS muestran la alta efectividad del algoritmo **DTMofLabTe**. Considerando las combinaciones óptimas de parámetros, $Te_{Opt} = 3.34\%$ y $K_{Opt} = 92.62\%$, mientras que si se emplea una combinación única, $Te_{Uni} = 4.52\%$ y $K_{Uni} = 90.04\%$. En cuanto a su comportamiento frente a diferentes tipos de entorno, se observan mejores resultados en las zonas urbanas ($K_{Urb-Opt} = 92.18\%$) que en las rurales ($K_{Rur-Opt} = 88.73\%$), siendo el comportamiento del algoritmo más robusto ante oscilaciones de los parámetros variables en las primeras ($K_{Urb-Uni} = 90.02\%$) que en las segundas ($K_{Rur-Uni} = 82.39\%$).

En cuanto al origen y localización espacial de los errores, se tiene que con independencia del tipo de entorno, la mayoría de los errores de filtrado se producen en zonas de línea de rotura como barrancos, cunetas y/o terraplenes. Pero si diferenciamos entre zonas urbanas y rurales, en las primeras los fallos se deben principalmente a los elevados errores de comisión provocados por la incorrecta selección de puntos en las cubiertas de edificaciones ubicadas en terrenos con elevada pendiente. En el caso de las muestras rurales, la mayoría de los fallos se deben a errores de omisión por la eliminación de P_g en zonas de elevada pendiente durante el proceso de depurado; o a los errores de comisión producidos por la clasificación errónea de puntos en vegetación baja situados también en terreno con elevada pendiente.

Finalmente, algunos de los errores de omisión cometidos pueden tener su origen en la definición de lo que es terreno y lo que son objetos adoptada en este estudio. En este caso se encuentran los puentes y rampas. Mientras que los puentes o pasos elevados son considerados objetos, las rampas se consideran terreno. [Sithole \(2005\)](#) en base a los resultados que obtuvo con anterioridad ([Sithole y Vosselman, 2004](#)) puso de manifiesto que esta definición podría no ser del todo adecuada, pues algunas aplicaciones podrían querer considerar las rampas como objetos o los puentes como terreno, o viceversa. Exponía por tanto la necesidad de detectar explícitamente estos elementos y permitir que sea el usuario

el que establezca si los puentes o rampas pertenecen o no al terreno.

En cuanto a la comparación con otros algoritmos de filtrado...

En los últimos cinco años se han mejorado los resultados de casi el 75% de las muestras, y el 30% de éstos se lograron a partir del **DTMofLabTe** con las combinaciones óptimas de parámetros. En general, este algoritmo ha resultado muy efectivo, pues se encuentra entre los tres que ofrecen las mejores precisiones entre un total de 23 estudios analizados.

La tendencia actual en el desarrollo de algoritmos de filtrado pasa por minimizar los *TIE*. En este sentido, el algoritmo **DTMofLabTe** sigue dicha tendencia obteniendo un $TIE=2.62\%$ y un $TIIe=4.70\%$ considerando los resultados de todas las muestras y empleando las combinaciones óptimas de parámetros. En línea con la reflexión sobre qué error minimizar y considerando los resultados y comparaciones realizadas en este estudio, la conclusión sobre minimizar los *TIE* a la que llegaron [Sithole y Vosselman \(2004\)](#) podría matizarse de forma que, para aumentar la precisión general del filtrado se recomienda minimizar los *TIE* aún a riesgo de aumentar los *TIIe* siempre y cuando los errores de comisión no se deban a la incorrecta selección de puntos pertenecientes a la cubierta de edificaciones.

Llegados al final de este estudio y teniendo en cuenta las ventajas, y sobre todo las limitaciones del algoritmo propuesto, se proponen una serie de mejoras a futuro encaminadas a hacer más competitivo el filtro **DTMofLabTe** pero sin renunciar a la posibilidad de emplearlo como complemento de otros algoritmos. Las mejoras que se proponen son:

Compromiso con la *usabilidad* ... Con el propósito de ayudar al usuario a seleccionar los parámetros de filtrado más apropiados para su zona de estudio se pretende desarrollar una función que sugiera los valores de los parámetros variables en función de las respuestas a un cuestionario.

Compromiso con la *accesibilidad y la eficiencia* ... Aunque las diferentes funciones que forman parte del algoritmo **DTMofLabTe** se

encuentran implementadas en el programa libre R es necesario adaptar la sintaxis de dichas funciones para su inclusión como *plugin* en una plataforma libre. Esta tarea también tendrá como objetivo optimizar las diferentes funciones para reducir los costes de computación.

Compromiso con la efectividad ... En este punto se encuentra el grueso de las propuestas de mejora. En primer lugar, se pretende modificar el proceso de depurado para mejorar el resultado de la eliminación de los P_{ng} , principalmente ante la presencia de edificaciones en zonas de elevada pendiente. Esta mejora permitirá el empleo de menores tamaños de ventana en la selección de los puntos semilla sin aumentar los errores de comisión. Por otro lado, se pretende explorar la posibilidad de emplear una función de pesos para generar la primera superficie de referencia tomando como base la puntuación de los puntos semilla. Al final de la cadena de efectos que provocarían estas mejoras, se tendría una reducción del número de iteraciones en la densificación debido fundamentalmente a la mayor calidad de la primera superficie de referencia. Finalmente, se propone mejorar el proceso de densificación desarrollando un umbral de diferencia de elevación que no sea fijo, sino que varíe en función de las características del relieve y de la cobertura del suelo.

Una breve reflexión como punto final. En una sociedad que avanza hacia la democratización real de la información y la inmersión en procesos colaborativos, es evidente que l@s creador@s de funciones como son los algoritmos de filtrado, además de centrar nuestros esfuerzos en mejorar la efectividad y la eficiencia, deberíamos ponernos del lado del usuario, la *usabilidad* y la accesibilidad, y desarrollar herramientas que satisfagan dichas demandas al tiempo que facilitan la obtención de productos a partir de datos procedentes de sensores remotos.

Agradecimientos

Este trabajo fue realizado en el Grupo de Investigación Laboratorio del Territorio (GI.-1934-Te-Bio) de la Universidad de Santiago de Compostela, en el Instituto de Estudios de Régimen Seccional del Ecuador de la Universidad del Azuay y con fondos de los proyectos *Red de Tecnologías LiDAR e de Información Xeoespacial* (Plan Galego 2011-2015 (Plan I2C): Programa Consolidación e Estructuración (Redes) - CN 2012/323).

A mis compañer@s en el [LaboraTe](#) y en el IERSE, gracias por vuestro esfuerzo, sin vosotr@s no hubiera sido posible.







CAPÍTULO 2

Factores que afectan a la precisión de los MDT

En el marco de los estudios coste-beneficio de la captura de datos LiDAR, una de las estrategias adoptadas para analizar la influencia que la densidad de puntos tiene sobre la calidad de los modelos obtenidos a partir de esta tecnología es reducir artificialmente la densidad de las nubes de puntos. Si bien existen varios métodos para llevar a cabo dicha reducción, una evaluación comparativa sobre su funcionamiento, así como un análisis de la influencia de dichos métodos en la calidad final de los modelos, no se ha realizado. En este estudio se presenta un nuevo método de reducción de la densidad, el método *Proportional per Cell (PpC)* y se lleva a cabo una comparación con otros tres métodos de reducción y un análisis de la influencia que este tipo de métodos tiene en la precisión de los Modelos Digitales del Terreno. En este último análisis, también se han tenido en cuenta otros 6 factores: la pendiente del terreno, el coeficiente de variación de la elevación, la cobertura del suelo, la resolución, el tipo de entorno y la propia densidad de puntos. Los resultados muestran que el método *PpC* es el que mejor conserva las características de la nube de puntos original en comparación con los otros métodos de reducción. Finalmente se comprueba que el tipo de entorno, el coeficiente de variación, la pendiente y la resolución son los factores que más influyen en la calidad de los modelos. Si bien el método de reducción se encuentra entre los factores que menos incidencia tienen en la precisión de los modelos, su influencia se hace más evidente cuanto más se reduce la densidad de puntos original.

Palabras clave: Modelo Digital del Terreno, factores de error, reducción de la densidad de puntos.

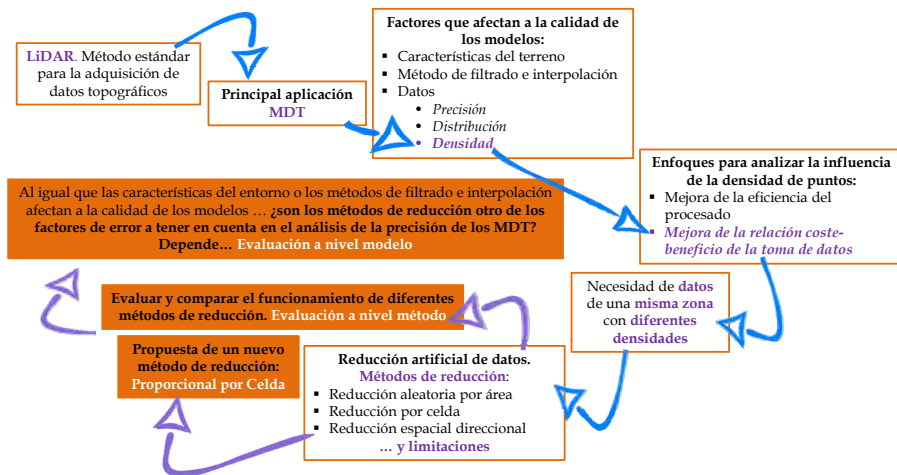


Figura 2.1: Resumen gráfico

2.1 Introducción

Airborne Light Detection and Ranging (LiDAR) es un sistema activo que se basa en la emisión de pulsos láser para medir la distancia que separa el sensor de los puntos donde impacta el láser. Esta información unida a la posición del sensor en el momento de la emisión del láser permiten obtener nubes de puntos georreferenciados que representan tanto el terreno como los objetos situados sobre él. La precisión y cobertura de los datos adquiridos con esta tecnología, su independencia de las condiciones climáticas y capacidad para penetrar a través de la vegetación y obtener datos del terreno, la han llevado a ser considerada como uno de los métodos estándar de adquisición de datos topográficos (Ullrich et al., 2007).

Al mismo tiempo que cada avance tecnológico (sistemas de referencia, cámaras, sistemas de posicionamiento global, aviación,...) reforzaba el papel de la tecnología LiDAR como método de referencia para la captura de datos geospaciales, se producía una mejora

significativa en la calidad de los Modelos Digitales del Terreno (MDT) generados a partir de estos datos, aumentando de forma exponencial su nivel de utilidad e importancia. Así, estos modelos se vinculan con una amplia variedad de aplicaciones científicas y comerciales, en sectores como el forestal (Khosravipour et al., 2015) o el urbanístico (Yan et al., 2015); para la gestión de recursos y riesgos naturales (Gueudet, 2004) o para análisis hidrológicos y recursos marinos (Zhao et al., 2010), entre otros.

Muchos estudios han centrado la atención en este tipo de modelos, bien desarrollando métodos de filtrado cada vez más sofisticados y eficientes al amparo de la mejora de prestaciones de los sistemas informáticos (Chang, 2010, Véga et al., 2012) bien centrándose en analizar la influencia que ciertos factores tienen sobre su precisión. En relación a este último punto, Li et al. (2005) y Hodgson et al. (2005) enumeraron y describieron algunos de estos factores. Tomando como referencia este último estudio, en la Figura 2.2 se incluye un resumen de los factores que influyen en la calidad de los MDT. Según estos autores, la precisión de los MDT es el resultado de combinar el efecto de varios factores individuales, entre los que se incluyen: 1) el proceso de captura de datos, donde se diferencia entre el sistema de navegación, el avión y el sensor (Hyypä et al., 2005, Su y Bork, 2006); 2) las características del entorno, donde la pendiente del terreno se identifica como una de las variables que presenta correlación positiva con el error global de los modelos (Hollaus et al., 2006); 3) los métodos empleados para la construcción de los modelos, analizados por medio de concienzudos estudios comparativos tanto de métodos de filtrado (Sithole y Vosselman, 2004), en constante actualización (Lu et al., 2008, Mongus y Žalik, 2012, Hu et al., 2014), como de métodos de interpolación (Yilmaz, 2007, Polat et al., 2015); y 4) los atributos de los datos (precisión, distribución y densidad).

En cuanto a las características del entorno, la variabilidad topográfica se considera la principal fuente de error de los MDT. Existen muchas formas de representar este factor, destacan la dimensión fractal, el semi-variograma, la pendiente y el coeficiente de variación de la elevación. Generalmente se selecciona una de ellas para representar la variabilidad pues dichas variables suelen ser colineales (Anderson et al.,



Figura 2.2: Actualización de la lista de factores que influyen en la calidad de los MDT incluidos en el estudio de [Hodgson et al. \(2005\)](#) (en naranja factores no incluidos en [Hodgson et al. \(2005\)](#) y sombreados los que se tienen en cuenta en este estudio).

2006). En este sentido, varios estudios han empleado la pendiente del terreno debido a la correlación positiva que presenta con el error global de los modelos ([Aguilar et al., 2005](#), [Hollaus et al., 2006](#)), mientras que en un menor número de casos se usó el coeficiente de variación ([Anderson et al., 2006](#)). Otras investigaciones también señalan la cobertura del suelo ([Gould et al., 2013](#), [Barreiro-Fernández et al., 2016](#)) o las características de una cobertura en particular, como por ejemplo el tipo, la densidad o la distribución espacial de la vegetación como variables que también presentan correlación positiva con la precisión de los MDT ([Evans y Hudak, 2007](#), [Salleh et al., 2015](#)).

Por otro lado, desde la publicación del primer estudio comparativo de algoritmos de filtrado para la identificación de puntos terreno ([Sithole y Vosselman, 2004](#)), se han sucedido los estudios que lo completan, añadiendo los resultados proporcionados por nuevos y mejorados algoritmos de filtrado ([Lu et al., 2008](#), [Mongus y Žalik, 2012](#), [Hu et al., 2014](#)). Aunque en la mayoría de estos estudios no se ha analizado la

influencia de los métodos de interpolación en la calidad de los MDT, sí lo han hecho otros muchos investigadores (Yilmaz, 2007, Polat et al., 2015) y si bien no existe un método de interpolación universal para todo tipo de datos y escenarios, algunos investigadores coinciden en señalar el *Thin Plate Spline* como el método de interpolación más apropiado para generar modelos continuos a partir de datos LiDAR (Evans y Hudak, 2007, Erdogan, 2009), aunque tienden a simplificar la superficie en exceso en zonas con cambios bruscos de elevación.

Finalmente, aunque algunos estudios han evaluado la precisión de los modelos empleando datos procedentes de diferentes técnicas de captura (Rayburg et al., 2009), en general no es fácil sacar conclusiones sobre la influencia individual de los diferentes atributos de los datos (Treitz et al., 2012). Por ejemplo, en el caso de la distribución, si se quiere analizar cómo diferentes patrones de datos (malla regular, TIN, líneas de rotura, puntos irregulares,...) influyen en la precisión de los modelos es necesario o bien emplear datos procedentes de diferentes sistemas de captura o sensores (Næsset, 2009), lo que implicaría variar el resto de atributos, o bien emplear un único sistema y variar las condiciones de la toma de datos, lo cual se ha hecho en muy pocos casos debido a su elevado coste (Goodwin et al., 2006, Lim et al., 2008). Esta reflexión también es aplicable a la precisión de los datos, estrechamente dependiente del método de captura empleado, sus parámetros y la densidad (Li et al., 2005).

Aun teniendo presentes las limitaciones anteriores, la comunidad científica destina muchos esfuerzos al análisis de la influencia que los diferentes atributos de los datos tienen sobre la calidad de los modelos, fundamentalmente la densidad. La densidad de puntos es uno de los factores más empleados para evaluar su influencia sobre la precisión de los MDT. Dichos análisis se han abordado desde dos puntos de vista diferenciados (Figura 2.3). Por un lado, diferentes campos de aplicación demandan modelos a distintas escalas. Cuanto menor es la escala mayor la necesidad de reducir la cantidad de datos. Así, como respuesta al desafío que suponen las nubes de puntos con elevadas densidades de puntos, producto del continuo avance en las técnicas de captura de datos impulsado en los últimos años por el desarrollo de drones, la comunidad científica ha centrado sus esfuerzos en mejorar la eficiencia del procesado.

Para ello se ha buscado el balance óptimo entre el número y distribución de los puntos y la resolución/precisión deseada del modelo a fin de reducir los costes computacionales y el volumen de datos, y con ello las necesidades de almacenamiento (*enfoque 1*). El supuesto de partida en este punto es que *el terreno se encuentra definido por un número infinito de puntos, sin embargo no todos juegan el mismo papel a la hora de caracterizar la superficie del terreno (Liu et al., 2015)*. En base a esta sentencia, la reducción de la densidad de puntos debe llevarse a cabo de tal forma que se preserven los elementos críticos mientras que los elementos menos importantes son descartados (Liu y Zhang, 2008).

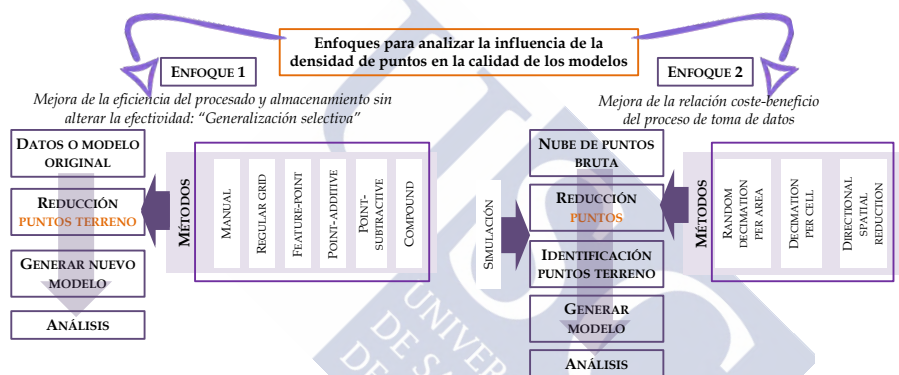


Figura 2.3: Esquema de los enfoques seguidos para analizar la influencia de la densidad de puntos en la calidad de los modelos.

Este planteamiento abre la puerta a la aplicación de un proceso de *generalización selectiva*. Así, los puntos que duplican información son descartados y aquéllos que definen elementos fundamentales del terreno, como cumbres, pozos o puentes, son preservados. El método más preciso de generalización es el manual, sin embargo, sus elevados costes de mano de obra, materiales y de tiempo lo hacen inviable para la gran mayoría de aplicaciones. De ahí la necesidad de disponer de métodos automáticos, que sin hacer concesiones en relación a la precisión de los modelos, permitan mejorar la eficiencia del procesamiento tanto en relación al almacenamiento como al tiempo de ejecución (Liu y Zhang, 2008). En esta línea, la generalización de los modelos se ha abordado de múltiples formas, prueba de ello es la cantidad clasificaciones propuestas para agrupar estos métodos (Lee, 1991, Zhou y Chen, 2011, Chen et al.,

2015a). Una de las más recientes es la realizada por Chen et al. (2016b), diferenciando 5 tipos de métodos: *regular grid*, *feature-point*, *point-additive*, *point-subtractive* y *hybrid (compound)*.

Tradicionalmente, los métodos incluidos en el grupo *regular grid* (por ejemplo, *resampling*, *low-pass filtering* o *wavelet transformation*) se han aplicado en el procesado y compresión de imágenes, y se les considera los métodos más comunes y simples en relación a la generalización de MDT (Chen et al., 2015b). En términos generales, este tipo de métodos se encuentran más orientados a la *compresión de datos* que a la *abstracción de información* siendo poco efectivos a la hora de preservar las características estructurales del terreno (Ai y Li, 2010). Los métodos *feature-point* abordan dicha limitación mediante la identificación y selección de un conjunto de puntos considerados críticos, los cuales se considera definen las principales características del relieve. A continuación, estos puntos se emplean para generar un modelo simplificado. La efectividad de estos métodos depende fundamentalmente del algoritmo empleado para la identificación de los puntos críticos y sus parámetros de tolerancia (Chen et al., 2016b), pues una mala elección puede introducir errores en zonas extensas y/o con orografía compleja (Sun et al., 2017). Por otro lado, se encuentran los dos grupos de métodos iterativos, los *point-additive*, también denominados *maximum z-tolerance*, y los *point-subtractive*, también llamados *decimation* o *drop heuristic*. En el primer caso, se crea una superficie de referencia a partir de un grupo reducido de puntos. Esta superficie se vuelve a calcular añadiendo aquellos puntos de la nube original cuya diferencia de elevación es máxima con respecto a dicha superficie de referencia. Este proceso finaliza cuando el modelo presenta un error inferior al permitido o se alcanza el número máximo de puntos establecido por el usuario. Por su parte, los métodos *point-subtractive* operan de forma inversa. A partir de un modelo creado empleando todos los puntos disponibles, se van eliminando aquellos puntos con menor error, de manera que se generan nuevos modelos hasta alcanzar el valor de tolerancia fijado por el usuario.

Si bien los métodos iterativos representan de manera fiable la morfología del terreno, tienden a ignorar la forma y las relaciones topológicas de las redes de drenaje, particularmente en zonas llanas

(Zhou y Chen, 2011). Adicionalmente, los métodos *point-subtractive* consumen mucho tiempo y recursos computacionales debido a la gran cantidad de puntos que procesan, limitación que los hace ineficientes para reducir densas nubes de puntos LiDAR (Chen et al., 2015b). Debido a la complejidad de los retos a los que tienen que hacer frente los métodos de generalización, la tendencia actual es combinar varios de los métodos anteriores, dando lugar a los denominados *métodos compuestos* (Zhou y Chen, 2011, Chen et al., 2016a). Aunque su nivel de sofisticación es mayor que el de los métodos más tradicionales y sus resultados mejoran los obtenidos hasta el momento, la demanda computacional sigue siendo elevada y alcanzar precisiones aceptables en zonas complejas sigue considerándose un desafío.

A pesar del potencial de la tecnología LiDAR como fuente de información para multitud de aplicaciones y las iniciativas llevadas a cabo desde el plano científico para proporcionar directrices encaminadas a conciliar los costes de adquisición, almacenamiento y tiempo de procesado con la cobertura y la calidad de los productos obtenidos mediante esta tecnología (Jakubowski et al., 2013, Wu et al., 2016), se considera que han sido pocos los esfuerzos destinados al desarrollo de protocolos y guías que vinculen los parámetros de la captura y procesado de este tipo de datos con sus posibles aplicaciones (Maune, 2011, Croneborg et al., 2015). Algunos autores afirman que este tipo de iniciativas podrían funcionar como catalizadores para que gobiernos y entidades privadas exploten de forma rentable esta tecnología (Treitz et al., 2012). Este sería uno de los contextos donde podría enmarcarse el segundo enfoque de análisis de la influencia de la densidad de puntos, ya que una de las formas de reducir los costes asociados con la adquisición de datos LiDAR es reducir la densidad de puntos (Takahashi et al., 2008). Así, en el caso del segundo enfoque, la comunidad científica persigue *mejorar la relación coste-beneficio del proceso de toma de datos, buscando el balance óptimo entre el tamaño de la nube de puntos original y el grado de detalle y precisión con el que se requiere representar el terreno (enfoque 2)*.

Para realizar este tipo de análisis se necesitan nubes de puntos con diferentes densidades, tomadas sobre una misma zona de estudio y manteniendo fijos el mayor número de parámetros de captura. Una

de las formas más simples para reducir la densidad de puntos dada una velocidad de vuelo, frecuencia de pulso y ángulo de escaneo fijos, es aumentar la altura de vuelo. Al realizar esta modificación de altura de vuelo y si la divergencia del rayo no varía, también se aumenta el tamaño de la huella (*footprint*). Si bien los resultados de algunos estudios no muestran que este aumento del tamaño de huella influya en la precisión de los MDT en zonas llanas (Persson et al., 2002, Yu et al., 2004), estos resultados pueden no darse en zonas de elevada pendiente, pues un aumento del tamaño de huella hace que el valor de elevación asignado a cada punto sea representativo de una mayor superficie de terreno que en el caso de una huella de menor tamaño. Este efecto sería comparable al que se produce tras remuestrear una imagen y aumentar el tamaño de píxel. Sin embargo, el problema que sí se asocia al aumento de la altura de vuelo es la pérdida de capacidad del sensor para registrar retornos superada cierta altura. En este caso, los ratios de penetración de los pulsos láser tienden a disminuir y en consecuencia, en zonas con presencia de vegetación se producirá una reducción de la precisión de los MDT (Takahashi et al., 2008).

La reflexión anterior muestra la complejidad ligada al análisis y extracción de conclusiones sobre el efecto individual que ciertos factores vinculados a la toma de datos tienen sobre la precisión de los productos derivados de datos LiDAR. Dicha circunstancia, unida al elevado coste de este tipo de estudios han impulsado tanto el desarrollo de simuladores de nubes de puntos (Lovell et al., 2005, Gastellu-Etchegorry et al., 2015, Qin et al., 2017) como el uso de métodos para reducir de forma *artificial* la densidad de nubes de puntos (Figura 2.3). En este último caso se distinguen 3 tipos de métodos de reducción: *random decimation per area*, *decimation per cell* y *directional spatial decimation*.

El método más simple y el más empleado para reducir *artificialmente* la densidad de puntos LiDAR bajo el *enfoque 2* es el método *random decimation per area* (de los 40 estudios analizados, casi el 50% empleó este método). Su funcionamiento se basa en la selección aleatoria de un subconjunto de puntos LiDAR a partir de la nube original de puntos. Esta selección puede realizarse en base a puntos (Polat et al., 2015), puntos terreno (Guo et al., 2010) o pulsos (Watt et al., 2013) a fin de alcanzar una densidad reducida establecida previamente (Wu et al.,

2016), obtener un porcentaje específico de puntos/pulsos con respecto a la nube original de puntos (Singh et al., 2015) o cumplir con una distancia mínima entre puntos (Magnusson et al., 2007). Este método se encuentra implementado en diferentes programas comerciales, como por ejemplo en ENVI versión 5.3 (Exelis Visual Information Solutions, Boulder, Colorado) a través de la herramienta *Decimate LAS File* de la extensión *BCAL Lidar tools* (<https://bcal.boisestate.edu/tools/lidar>) o mediante el módulo *ESRI Geostatistical Analysis* incluida en ArcGIS (Environmental Systems Research Institute, Redlands, California, pero también es posible simularlo mediante la función *sample* incluida en el paquete *base* del programa libre R (R Development Core Team, 2010).

En general, este método mantiene la distribución original de los puntos, sin embargo algunos autores reconocen que pueden darse sesgos al usar un único conjunto aleatorio de datos por cada nivel de reducción (Anderson et al., 2006, Wu et al., 2016). Otra de las limitaciones que se identifica, concretamente en aquellos procesos donde la reducción se realiza en base al establecimiento de porcentajes de reducción, es que el empleo de porcentajes dificulta la comparación de resultados obtenidos a partir de diferentes estudios, pues en estos casos la densidad reducida depende de la densidad de la nube de puntos original. Por ejemplo, en el caso de querer comparar los resultados de los estudios de Anderson et al. (2006), Immelman y Scheepers (2011) y Asal (2016), donde se analiza cómo la reducción de puntos afecta a la precisión de los MDT, se debería actuar con cautela ya que las densidades de las nubes de puntos originales son de 0.03 ptos/m^2 , 1.26 ptos/m^2 y 0.27 ptos/m^2 respectivamente y si consideramos los resultados de las nubes de puntos reducidas al 25%, estaríamos comparando nubes con densidades de 0.008 ptos/m^2 , 0.3 ptos/m^2 y 0.07 ptos/m^2 respectivamente. También se debería prestar especial atención en el caso de que la reducción se realice sobre la nube de puntos terreno y no sobre la nube de puntos original como en el caso del estudio de Guo et al. (2010).

A diferencia de los métodos anteriores, los *decimation per cell* toman celdas cuadradas como unidad espacial para llevar a cabo la reducción de puntos, de manera que la zona con datos es dividida en subzonas. Una vez hecha esta división, se procede a realizar la reducción propiamente dicha. La forma más simple es seleccionar aleatoriamente

un número determinado de puntos en cada celda. Este proceso puede realizarse ajustando el tamaño de celda de tal forma que se seleccione un único punto en cada una (Gobakken y Næsset, 2008) o manteniendo el tamaño de ventana fijo y calculando el número de puntos que es necesario seleccionar en función del área de la celda y la densidad deseada (González-Ferreiro et al., 2012, Leitold et al., 2015). En el primer caso, la nube de puntos resultante tendrá una proporción de primeros retornos superior a la de los datos originales, no conservando el efecto de múltiple retorno. Con respecto al segundo tipo, si la nube de puntos original no presenta una densidad homogénea en toda la zona y el valor de la densidad reducida es relativamente próxima al valor de la densidad media original, puede ocurrir que dicha densidad no sea alcanzada. Esta situación se dio en el estudio realizado por Ruiz et al. (2014), de forma que tras el proceso de reducción descartaron aquellas parcelas cuya densidad no coincidía con el valor de densidad deseado. En su caso, el mayor número de descartes se dio en los niveles donde el porcentaje de reducción de la densidad era más elevado. Al reducir la densidad al 60%, se descartaron el 10% de las parcelas, mientras que dicho porcentaje de descartes superó el 50% al reducir a la mitad la densidad de puntos original. Finalmente, en ambos casos el resultado es una nube de puntos cuya distribución es homogénea, evitando la existencia de zonas sin datos o con demasiados, sin embargo esto significa no conservar la distribución de la nube de puntos original ni ser fiel al patrón de escaneo original sobretodo cuando la densidad final es muy pequeña (Wilkes, 2016). Este método se encuentra implementado en la herramienta *lasthin* incluida en el programa gratuito LAsTools (<http://www.cs.unc.edu/isenburg/lastools/>), empleado en múltiples estudios debido a su nivel de eficiencia (Kandare et al., 2016, Sibona et al., 2017). Otra opción disponible para emplear este método es la función *ThinData* implementada en el programa gratuito FUSION (McGaughey, 2010).

Otros autores realizaron la reducción a nivel celda intentando replicar el efecto de múltiple retorno. Jakubowski et al. (2013) emplearon un tamaño de celda de 100 m identificando en cada una los primeros retornos. Teniendo en cuenta que la cantidad de primeros retornos es equivalente al número de pulsos, emplearon esta información para calcular un factor de reducción a nivel celda y calcular el número de

puntos a seleccionar de forma aleatoria en dicha celda. Aumentando la complejidad, Wilkes (2016) también buscó imitar la captura multi-retorno y simuló una adquisición cercana al nádir con un patrón de escaneo regular. Para ello empleó dos atributos de los datos LiDAR: el número de retorno y la cantidad de retornos. En primer lugar se divide la zona en celdas cuadradas, cuyo tamaño depende de la densidad deseada y se selecciona el punto de primer retorno más cercano al centro de cada celda. A continuación, a partir de una ventana cuadrada cuyo tamaño se fija en función de un ángulo de escaneo máximo y la altura máxima estimada de la vegetación en dicha celda, se seleccionan tantos puntos como *número de retornos* tiene el pulso al que pertenece el punto seleccionado. La aplicación de este método requiere disponer del campo *número de retornos*, información que no siempre está disponible. Una de las limitaciones identificadas por el autor es que en algunos casos la densidad deseada no se alcanza. Esta circunstancia se debe a que la distancia entre puntos es irregular, limitando la capacidad de la ventana de búsqueda de retornos para identificar y seleccionar puntos. Por otro lado, Magnussen et al. (2010) también implementó un método de reducción a nivel celda. Tomando como datos de entrada el número de puntos en cada celda, la densidad original y la densidad reducida empleó una distribución binomial para calcular el número de puntos que se debe seleccionar aleatoriamente en cada celda. Según dicho estudio y a diferencia de lo que sucede en los métodos descritos en el párrafo anterior, este método conserva a una resolución de 1 m^2 la distribución de los pulsos en la nube de puntos original (Watt et al., 2014, Manuri et al., 2017).

Otro grupo de investigadores abordaron la limitación de la no simulación de los patrones de escaneo mediante una reducción sistemática del número de puntos teniendo en cuenta el orden en que fueron capturados de manera que se mantiene la distribución original de los datos (*directional spatial decimation*) (Gueudet, 2004, Takahashi et al., 2010, Treitz et al., 2012). Takahashi et al. (2010) aplicaron este método dividiendo sistemáticamente la nube de puntos original en puntos impares y pares, descartando en cada iteración uno de ellos. Este proceso se repite hasta alcanzar la densidad de puntos deseada. Aplicar este método sobre nubes de puntos capturadas en zonas forestales y que por cada pulso se registre solo el primer y último retorno, puede producir

nubes de puntos reducidas que poco o nada tienen que ver con la original. Así, al no tener en cuenta el tipo de retorno, con la primera división se estarán separando los datos en puntos de primer retorno (impares) y de último retorno (pares). Sin embargo, el procedimiento más empleado consiste en disponer los puntos en orden de captura y a continuación seleccionar un punto cada n , donde n se fija en función de la densidad deseada. Aunque en algunos casos la selección se realizó por puntos sin tener tampoco en cuenta el tipo de retorno (Gueudet, 2004, Pirotti y Tarolli, 2010), la gran mayoría de los autores realizaron dicha selección teniendo en cuenta los pulsos, incluyendo en la nube de puntos reducida todos los puntos pertenecientes al pulso seleccionado (Raber et al., 2007, Treitz et al., 2012).

El empleo de este tipo de métodos requiere que la nube de puntos original se disponga en el archivo LAS en el mismo orden en que los puntos son registrados o que incorporen como atributo el tiempo GPS o el número de pulso, circunstancias que no siempre se cumplen. Pirotti y Tarolli (2010) indicaron que el uso de los métodos *directional spatial decimation* simula la captura de datos a una mayor altura de vuelo. Sin embargo, esta afirmación no es del todo cierta, pues se esperaría que un aumento de la altura de vuelo fuese acompañado por un aumento del tamaño de huella debido a la divergencia del rayo láser, y al aumentar el tamaño de huella se espera un mayor índice de impacto de los rayos con la vegetación, dificultando el registro de puntos terreno (Khosravipour et al., 2014). Sin embargo, la reducción artificial de la nube de puntos por este método no simula este efecto, para ello sería necesario recurrir a simuladores de nubes de puntos.

Mientras que la naturaleza de los estudios vinculados al primer enfoque los lleva a analizar y cuantificar el efecto que las diferentes estrategias de reducción tienen sobre los modelos (Yilmaz y Uysal, 2016), en el caso del segundo enfoque no se ha encontrado ningún estudio donde se analice y compare el funcionamiento de diferentes métodos de reducción ni su influencia sobre los productos derivados de datos LiDAR y esto a pesar de la gran cantidad de estudios que han evaluado como la densidad de puntos influye en la calidad de los modelos. El empleo de uno u otro método de reducción puede afectar al análisis de la influencia que el factor densidad puede ejercer en la precisión de los modelos bien

porque la densidad obtenida artificialmente no coincide exactamente con la deseada bien porque la distribución de los puntos difiere de la distribución original bien porque algunas de las características de los datos originales, como el número de retornos, no se conservan tras la reducción. En consecuencia, las conclusiones a las que se llega en los estudios donde además de la densidad de puntos se analiza la influencia de otros factores como la pendiente, la resolución de los modelos o las coberturas del suelo pueden estar comprometidas por no haber tenido en cuenta que el propio método de reducción de los datos pudiera ser un componente más del error de los MDT.

Las cuestiones que se plantean tras la revisión realizada y a las que se pretende dar respuesta con este estudio son: partiendo de una misma nube de puntos LiDAR, ¿existen diferencias entre nubes de puntos reducidas al emplear diferentes métodos de reducción? y ¿el método de reducción de la densidad influye en la precisión de los modelos? Para contestar a dichas preguntas se han fijado los siguientes objetivos:

- Propuesta de un nuevo método de reducción, *Proportional per Cell (PpC)*, incluido junto con otros dos métodos de reducción en la función **DecimaTe** implementada en el programa gratuito y colaborativo R.
- Evaluación del funcionamiento del método *PpC* y comparación con otros métodos de reducción de la densidad de puntos LiDAR (evaluación a nivel método).
- Análisis de la influencia de los métodos de reducción de la densidad, junto con otros factores como la propia densidad de puntos, la pendiente, el coeficiente de variación de la elevación, la cobertura del suelo y la resolución, en la precisión de los MDT (evaluación a nivel modelo).

La estructura que presenta este capítulo es la siguiente: en el apartado 2.2 se incluye la descripción de los datos empleados (sección 2.2.1); una descripción detallada de la función **DecimaTe** donde se incluyen tres métodos de reducción de puntos (sección 2.2.2); la

descripción de la función ThinData de reducción de la densidad de nubes de puntos incluida en el programa libre FUSION (sección 2.2.3) y por último se describe la metodología de evaluación adoptada (sección 2.2.4) tanto para valorar el funcionamiento de los diferentes métodos de reducción (sección 2.2.4.1 - evaluación interna) como para analizar si dichos métodos junto con otros factores influyen en la precisión de los MDT obtenidos a partir de datos LiDAR (sección 2.2.4.2 - evaluación externa). Los resultados de esta investigación se incluyen en el apartado 2.3. Dicho apartado se divide en dos secciones. En la primera se incluyen los resultados de la evaluación interna, donde se compara el funcionamiento de los diferentes métodos de reducción mediante el empleo de indicadores (sección 2.3.1). En la segunda se encuentran los resultados de la evaluación externa (sección 2.3.2), concretamente los análisis cuantitativos relativos a la influencia de los diferentes factores sobre la precisión de los modelos (sección 2.3.2.1) y los correspondientes al análisis de sensibilidad y predictivo (sección 2.3.2.2). Finalmente, en el apartado 2.4 se encuentran las principales conclusiones que se desprenden de esta investigación. Los anexos de este capítulo se incluyen en el CD adjunto.



2.2 Material y métodos

2.2.1 Datos LiDAR

Para llevar a cabo este estudio se emplearon los datos LiDAR de referencia de la *International Society of Photogrammetry and Remote Sensing (ISPRS Commission III, the Working Group III/3 "3D Reconstruction from Airborne Laser Scanner and InSAR Data")*. Estos datos fueron capturados por un escáner Optech ALTM en la ciudad de Stuttgart y en una zona rural en el sur de Alemania (libre descargar en la web: <http://www.itc.nl/isprswgIII-3/filtertest/>).

Aunque se dispone de datos en zonas rurales y urbanas, únicamente se usaron los de estas últimas debido a que los datos de las zonas rurales presentan una densidad de puntos muy baja (una media de $0.34 \text{ ptos}/\text{m}^2$). Los datos de las zonas urbanas están divididos en 4 grupos (*Sites 1-4*) donde se delimitaron un total de 9 áreas de referencia. En cada una de ellas, combinando técnicas de filtrado automáticas y manuales, los puntos LiDAR fueron clasificados en dos clases: terreno (*ground points*, P_g - codificado como 0) y no-terreno (*non-ground points*, P_{ng} - codificado como 1) (P_{gC} , P_{ngC}) (Vosselman, 2003). Sin embargo, sólo la mitad de los datos originales disponibles en estas áreas de referencia han sido clasificados, reduciendo así la densidad de puntos original. En este estudio, esta situación se corrigió mediante un proceso automático de clasificación. Para ello se consideró la distancia entre retornos de un mismo pulso para asignarles una clase a los puntos no clasificados, de forma que: 1) si ninguno de los retornos de un mismo pulso tiene clase, ambos son eliminados; 2) si uno está clasificado y la distancia entre ellos es inferior a 30 cm, el punto no clasificado toma la misma clase que el punto clasificado, en caso contrario el punto no clasificado se codifica como perteneciente a la otra clase (P_{gO} , P_{ngO}). En la Tabla 2.1 se indican algunas de las características de las áreas de referencia y de los datos. Del mismo modo, en las Figuras B.1 a B.9 del Anexo B.1 se incluyen más detalles sobre dichas muestras de referencia.

Tabla 2.1: Características de las zonas de análisis y los datos LiDAR.

Muestra	% Sup. sin ptos	Pendiente (Q95)	P_{gC}	P_{ngC}	D_C	P_{gO}	P_{ngO}	D_O	$\frac{P_{gO}}{P_{ngO}}$
M11. Vegetación y edificios en pendiente elevada.	33.1	52.5	21786	16224	0.93	37939	38060	1.86	1
M12. Edificios y coches.	33.6	19.8	26691	25428	0.95	47319	56919	1.91	0.83
M21. Vegetación y edificios en pendiente elevada.	36.4	11.3	10085	2875	0.89	16851	9069	1.77	1.85
M22. Puentes y pasarela.	38.3	26.8	22504	10202	0.96	42236	23176	1.91	1.82
M23. Grandes edificios y discontinuidades.	39.1	41.9	13223	11872	0.82	24947	25243	1.65	0.99
M24. Rampa.	39.3	39.3	5434	2059	0.83	9483	5501	1.64	1.72
M31. Grandes edificios.	29.4	6.9	15556	13306	1.01	27547	30177	2.02	0.91
M41. Outliers (efecto multi-path).	62.3	18.4	5602	5629	0.63	10935	11527	1.27	0.95
M42. Estación de tren.	35.6	16.0	12443	30027	0.91	23993	60947	1.83	0.39

Nota: P_{gC} y P_{ngC} , cantidad de puntos terreno y no-terreno clasificados por la ISPRS; D_C densidad de las nubes de puntos anteriores; P_{gO} y P_{ngO} , cantidad de puntos terreno y no-terreno originales y clasificados para este estudio; D_O densidad de las nubes de puntos anteriores; P_{gO}/P_{ngO} , ratio entre puntos terreno y no-terreno empleando las nubes de puntos reclasificadas en este estudio.

2.2.2 Descripción de la función **DecimaTe**

DecimaTe es una función desarrollada en el programa gratuito R ([R Development Core Team, 2010](#)). A partir de esta función se puede reducir la densidad de puntos de las nubes LiDAR. Esta función se encuentra definida por 3 argumentos: *PointCloud*, nube de puntos LiDAR original (S); D_D , densidad reducida; y *metodo*, donde se indicará el método de reducción de la densidad que se quiere emplear. En cuanto a este último argumento y considerando la revisión realizada en el apartado 2.1 de este estudio, la herramienta **DecimaTe** incorpora tres métodos de reducción: dos de ellos usados en estudios previos, *Random per Area (RpA)* ([Magnusson et al., 2007](#), [Singh et al., 2015](#)) y *Semi-Random per Cell (SRpC)* ([Magnussen et al., 2010](#), [Ruiz et al., 2014](#)); y como novedad se incluye un tercer método de reducción, *Proportional per Cell (PpC)*, desarrollado para paliar alguna de las limitaciones de los métodos actuales. Los diagramas de flujo de estos métodos se muestran esquemáticamente en la Figura 2.4 y en la Figura B.10 del Anexo B.2 se incluye en pseudo-código de la función **DecimaTe**.

2.2.2.1 Random per Area (**RpA**).

El método *Random per Area (RpA)*, empleado por [Anderson et al. \(2006\)](#) o [Puetz et al. \(2009\)](#), reduce la densidad de puntos de manera aleatoria sin tener en cuenta ni la distribución de los puntos ni el tipo de retorno. La unidad de reducción es toda la superficie que contiene datos. El diagrama de flujo del método *RpA* se muestra de forma esquemática en la Figura 2.4. Una vez seleccionados los datos de entrada, se calculan una serie de parámetros para llevar a cabo la reducción. En primer lugar, a partir de la nube de puntos original (S) se obtiene el número de puntos (N) y la densidad media ponderada original (\bar{D}). El valor de la densidad se obtiene rasterizando la nube de puntos original, donde el valor de cada celda se corresponde con el número de puntos en su interior. El conjunto de valores de las celdas de este ráster permiten elaborar una tabla resumen donde a cada densidad de puntos $D=\{d_1, d_2, d_3, \dots, d_n\}$ le corresponde una cantidad de celdas con dicha densidad $M=\{m_1, m_2, m_3, \dots, m_n\}$. A partir de los valores de esta tabla

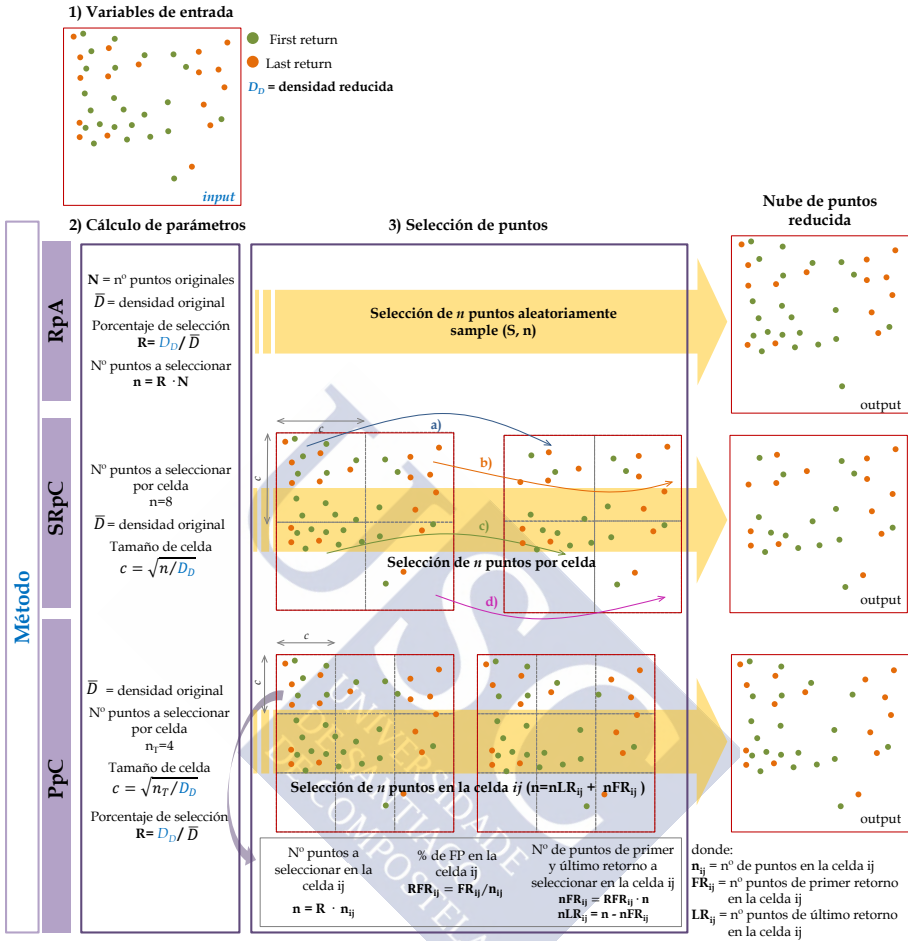


Figura 2.4: Diagrama de flujo de los métodos de reducción incluidos en DecimaTe.

y la Ecuación 2.1, se calcula la densidad media ponderada original.

$$\bar{D} = \frac{\sum_{i=1}^n d_i \cdot m_i}{\sum_{i=1}^n m_i} \quad (2.1)$$

En segundo lugar, se calcula el porcentaje de puntos de la nube original que serán seleccionados (R) para cumplir con el valor de la densidad reducida deseada (D_D) y se obtiene la cantidad de puntos que

finalmente serán seleccionados (n). El valor de R viene dado por el cociente entre el parámetro D_D y la densidad original de puntos (\bar{D}) (Ecuación 2.2), mientras que el valor de n se obtiene a partir del producto de R y N (Ecuación 2.3). Por último, empleando la función *sample* (paquete *base* - v.3.5.0 de R) se seleccionan aleatoriamente n puntos (R Development Core Team, 2004).

$$R = \frac{D_D}{\bar{D}} \quad (2.2)$$

$$n = R \cdot N \quad (2.3)$$

2.2.2.2 Semi-Random per Cell (*SRpC*).

El método *Semi-Random per Cell* (*SRpC*) es una adaptación del método de reducción empleado en Buján et al. (2013b). Este método no tiene en cuenta la distribución de los puntos durante el proceso de reducción pero sí el tipo de retorno. Su esquema de funcionamiento se ha incluido en la Figura 2.4. En primer lugar, la superficie con datos se divide en celdas cuadradas, de forma que la reducción de puntos se hará a nivel celda y no a nivel área como en el caso del método *RpA*. A continuación, se establece el número de puntos que serán seleccionados en cada celda (n). El valor de este parámetro se fijó tras ejecutar el método *SRpC* con diferentes valores de n . Mediante inspección visual de los resultados, $n = 8$ es el valor que proporcionó los mejores resultados. A continuación, a partir de la nube de puntos original (S), se calcula la densidad media ponderada original (\bar{D}) (Ecuación 2.1). También se calcula en este punto, el tamaño de celda (c) que se tomará como base para realizar la reducción (Ecuación 2.4).

$$c = \sqrt{\frac{n}{D_D}} \quad (2.4)$$

El cálculo de c en función de la densidad reducida y estableciendo un valor de n relativamente elevado, busca asegurar la presencia de puntos

de primer y último retorno en cada celda. No se estableció la condición de que ambos puntos pertenezcan al mismo pulso ya que en muchos casos no se dispone del atributo *número de pulso*. El establecimiento automático de c es la principal diferencia que existe entre el método *SRpC* y el empleado en Buján et al. (2013b), donde dicho parámetro lo establecía el usuario. Si D_D era demasiado pequeña, se daba con frecuencia que sólo se seleccionase un punto por celda. Generalmente esto se debía a que a c se le asignaba un valor fijo con independencia del valor de D_D . A partir de dicho método, se seleccionaba un punto de primer retorno si la mayoría de puntos en la celda eran de primer retorno y de último retorno si la mayoría eran de este tipo. Por el contrario, el método *SRpC* contempla 4 casuísticas para seleccionar los puntos en cada celda:

- a) Si $n_{ij} \geq n$, $FR_{ij} \geq n/2$ y $LR_{ij} \geq n/2$, se seleccionan aleatoriamente $n/2$ puntos de cada tipo (flecha azul, gráfico *SRpC* en Figura 2.4).
- b) Si $n_{ij} \geq n$, $FR_{ij} < n/2$ y $LR_{ij} \geq n - FR_{ij}$, se seleccionan todos los puntos de primer retorno y $n - FR_{ij}$ puntos de último retorno (flecha naranja, gráfico *SRpC* en Figura 2.4).
- c) Si $n_{ij} \geq n$, $LR_{ij} < n/2$ y $FR_{ij} \geq n - LR_{ij}$, se seleccionan todos los puntos de último retorno y $n - LR_{ij}$ puntos de primer retorno (flecha verde, gráfico *SRpC* en Figura 2.4).
- d) Si $0 < n_{ij} < n$, se seleccionan todos los puntos en la celda ij (flecha rosa, gráfico *SRpC* en Figura 2.4).

donde n_{ij} es el número de puntos en la celda ij ; y FR_{ij} y LR_{ij} representan la cantidad de puntos de primer y último retorno en la celda ij , respectivamente.

2.2.2.3 Proportional per Cell (PpC).

El método *Proportional per Cell (PpC)* se desarrolló con el propósito de simular de manera realista la captura real de puntos sin necesidad de

contar con datos adicionales (p. ej. el ángulo de escaneo de cada punto, secuencia de captura, ...). De esta forma se busca minimizar la influencia del método de reducción en la precisión de los MDT (en caso de existir). Mediante este método, la reducción de puntos se realiza a nivel celda teniendo en cuenta tanto la distribución de los puntos como el tipo de retorno. El diagrama de flujo del método *PpC* se incluye en la Figura 2.4. En primer lugar, se calcula la media ponderada de la densidad de puntos (\bar{D}) (Ecuación 2.1) y se fija en 4 el número teórico de puntos que se seleccionarían en cada celda (n_T) si la densidad de la nube de puntos original fuese homogénea. Dicho valor se estableció por prueba y error y tras el análisis visual de los resultados. El parámetro n_T junto con la densidad de puntos reducida (D_D) se emplean para calcular el tamaño de celda (c) sobre la que se llevará a cabo la reducción (Ecuación 2.4, donde $n=n_T$). Para finalizar la parte de cálculo de parámetros se obtiene el ratio de selección (R) a partir de la Ecuación 2.2.

A continuación, se sobrepone una malla de celdas cuadradas de tamaño c a la nube de puntos original. Para cada celda ij se obtiene el número de puntos que se encuentran en su interior (n_{ij}). A partir de este valor, R y la Ecuación 2.3, donde $N=n_{ij}$, se calcula el número de puntos a seleccionar en dicha celda (n). De esta forma, se busca respetar la distribución original de los puntos LiDAR. Posteriormente, para mantener la proporción original de retornos se calcula la cantidad de puntos de cada tipo de retorno que se debe seleccionar en la celda ij . Así, se obtiene el porcentaje de puntos de primer retorno en la celda ij (RFR_{ij}) mediante la Ecuación 2.5 y se calcula el número de puntos a seleccionar de este tipo en dicha celda (nFR_{ij}) redondeando al entero más próximo (Ecuación 2.6). En consecuencia, la cantidad de últimos retornos que se debe seleccionar (nLR_{ij}) vendrá dado por la diferencia entre n y nFR_{ij} . Así, en la celda ij se seleccionarán aleatoriamente nFR_{ij} puntos de primer retorno y nLR_{ij} puntos de último retorno, y ambos sumarán n puntos. Este proceso se repetirá para cada celda.

$$RFR_{ij} = \frac{FR_{ij}}{n_{ij}} \quad (2.5)$$

$$nFR_{ij} = RFR_{ij} \cdot n \quad (2.6)$$

2.2.3 Descripción de la función *ThinData* (FUSION).

La función *ThinData* se encuentra implementada en el programa libre FUSION (McGaughey, 2010). Dicha función está definida por 4 argumentos: *DataFile*, archivo que contiene la nube de puntos LiDAR; *OutputFile*, archivo de salida que contiene la nube de puntos reducida; *Density*, densidad de puntos deseada por unidad cuadrada; y *CellSize*, tamaño de celda empleada para el cálculo de la densidad deseada en unidad cuadrada. Esta función fue diseñada para obtener una nube de puntos con densidad uniforme. Para lograrlo, en primer lugar se calcula la densidad original de los datos empleando una malla de celdas cuadradas. Esta función emplea el algoritmo de muestreo de Bernoulli, de manera que la probabilidad de incluir un determinado punto se determina a partir de la densidad objetivo en un área determinada en función de la densidad original (Strunk et al., 2012). De esta forma, para cada celda, cuya área viene dada por el argumento *CellSize*, se calcula la proporción de pulsos que serán seleccionados aleatoriamente a partir del valor de densidad original de los datos y del argumento *Density*. Más información sobre el funcionamiento de esta función puede encontrarse en McGaughey (2010).

Esta función fue usada recientemente en varios estudios para reducir la densidad de puntos con el propósito de analizar el efecto de este factor en el cálculo de métricas de bosques tropicales o para inventarios forestales, o para el modelado de hábitats (Watt et al., 2014, Hansen et al., 2015, Johnston y Moskal, 2017).

2.2.4 Metodología de evaluación

La metodología de evaluación adoptada en este estudio consta de dos tipos de análisis. En primer lugar, se realiza una evaluación a nivel método para comparar el funcionamiento de los diferentes métodos de

reducción considerados en este estudio. En segundo lugar, se realiza una evaluación a nivel modelo con el propósito de analizar si los métodos de reducción, junto con otros factores, influyen en la calidad de los MDT obtenidos a partir de datos LiDAR.

2.2.4.1 Evaluación a nivel método.

Para evaluar y comparar el funcionamiento de los métodos de reducción *RpA*, *SRpC* y *PpC* y el algoritmo *ThinData*, se lleva a cabo una evaluación basada en indicadores. Un indicador puede definirse como una variable representativa de una característica o propiedad de un fenómeno asociado a un objeto, es decir, se trata de una imagen o abstracción del atributo de un objeto (Gallopín, 1997). Una de las principales funciones de los indicadores es la de facilitar la realización de estudios comparativos entre situaciones, motivo por el que su empleo se consideró adecuado para realizar la evaluación a nivel método. Para tal propósito se definieron cuatro indicadores atendiendo a los puntos críticos identificados en la bibliografía consultada: 1) distribución de los puntos; 2) proporción entre retornos; 3) proporción entre puntos terreno y no-terreno y 4) acuerdo entre la densidad deseada y la calculada. En la Tabla 2.2 se incluye un resumen de estos indicadores y criterios para evaluar su grado de cumplimiento.

Tabla 2.2: Indicadores usados en la evaluación a nivel método.

Indicador (I)	Descripción	Grado de cumplimiento
I1-Distribución de los puntos	Análisis de la dependencia lineal entre las celdas del ráster con la distribución original de puntos y el obtenido tras la reducción. Cálculo del coeficiente de determinación (R^2).	<p>Bueno $\leftarrow R^2 \in [0.8, 1]$</p> <p>Regular $\leftarrow R^2 \in [0.6, 0.8)$</p> <p>Malo $\leftarrow R^2 \in [0, 0.6)$</p>
I2-Proporción entre retornos	Diferencia absoluta entre el ratio FR/LR obtenido a partir de los datos originales y tras la reducción ($D_{D^O_{FR:LR}}$).	<p>Bueno $\leftarrow D_{D^O_{FR:LR}} \in [0, 5\%*FR_O : LR_O]$</p> <p>Regular $\leftarrow D_{D^O_{FR:LR}} \in (5\%*\frac{FR_O}{LR_O}, 10\%*\frac{FR_O}{LR_O}]$</p> <p>Malo $\leftarrow D_{D^O_{FR:LR}} \in (10\%*FR_O : LR_O, +\infty]$</p>
I3-Proporción entre P_g y P_{ng}	Diferencia absoluta entre el ratio P_g/P_{ng} obtenido a partir de los datos originales y tras la reducción ($D_{D^O_{P_g:P_{ng}}}$).	<p>Bueno $\leftarrow D_{D^O_{P_g:P_{ng}}} \in [0, 5\%*P_{gO} : P_{ngO}]$</p> <p>Regular $\leftarrow D_{D^O_{P_g:P_{ng}}} \in (5\%*\frac{P_{gO}}{P_{ngO}}, 10\%*\frac{P_{gO}}{P_{ngO}}]$</p> <p>Malo $\leftarrow D_{D^O_{P_g:P_{ng}}} \in (10\%*P_{gO} : P_{ngO}, +\infty]$</p>
I4-Acuerto entre la deseada y la calculada	Diferencia absoluta entre la densidad deseada y la calculada (D_{R^D}).	<p>Bueno $\leftarrow D_{R^D} \in [0, 5\%*D_D]$</p> <p>Regular $\leftarrow D_{R^D} \in (5\%*D_D, 10\%*D_D]$</p> <p>Malo $\leftarrow D_{R^D} \in (10\%*D_D, +\infty]$</p>

Nota: R^2 , coeficiente de determinación; FR primer retorno; LR último retorno; D^O , diferencia entre los ratios originales y los deseados; FR_O y LR_O cantidad de primeros y últimos retornos originales; P_{gO} y P_{ngO} , cantidad de puntos terreno y no-terreno originales y clasificados para este estudio; D^D_R , diferencia entre la densidad deseada y la obtenida tras reducción; D_D , densidad deseada; D_R , densidad real de las nubes de puntos reducidas.

Algunos investigadores afirman que la calidad de los datos empleados para generar los MDT es uno de los factores que más incide en su precisión (Li et al., 2005). Concretamente, tres atributos de los datos son determinantes: la precisión, la densidad y la distribución. Teniendo en cuenta que lo óptimo sería que un método de reducción conserve fielmente las características de los datos originales, la distribución de los datos se tomó como base para la definición del primer indicador. Así, el *indicador 1 (I1)*, *distribución de los puntos*, pretende medir la concordancia entre la distribución de los puntos de la nube original y la de los puntos de las nubes reducidas. Para ello, se crea un ráster de densidad para cada conjunto de puntos, de forma que en cada celda se almacena el número de puntos que caen en su interior (x_{ij}). Posteriormente, cada ráster es normalizado a un rango entre 0 y 1 aplicando el método *min-max scaling*¹ usado por Han (2012). A continuación, se realiza un ajuste lineal a partir de los valores de las celdas del ráster que representa la densidad original y los obtenidos de las nubes de puntos reducidas, todos ellos normalizados. Finalmente, se calcula el coeficiente de determinación para cada densidad (R^2). Los umbrales que se fijaron para evaluar el grado de cumplimiento de este indicador se incluyen en la Tabla 2.2.

Otros autores como Hyypä et al. (2008) o Næsset (2009), además de considerar estos atributos de los datos, identificaron el tipo de retorno como una de las características específicas de los datos LiDAR que también puede afectar a la calidad de los MDT. En base a esta característica, se definió el segundo indicador (*I2*): *proporción entre retornos*. Este indicador representa la diferencia absoluta entre el ratio *FR:LR* obtenido a partir de los datos originales y los reducidos. Para ello se calcula la diferencia absoluta entre ambos, $D_{D^{FR:LR}}^O$, donde $D \in [1.5, 1, 0.5, 0.25, 0.1, 0.05, 0.025, 0.01]$ (valores de densidad deseada). En este caso se consideró que el grado de cumplimiento es *bueno* si la diferencia entre ratios varía menos del 5% con respecto al valor del ratio calculado a partir de los datos originales ($FR_O:LR_O$); *regular* si se encuentra entre el 5% y el 10% del ratio $FR_O:LR_O$ y *malo* si se encuentra por encima del 10% (Tabla 2.2).

¹A partir de $x'_{ij} = x_{ij} - \min(x_{ij}) / \max(x_{ij}) - \min(x_{ij})$ se obtiene el valor normalizado de cada píxel (x'_{ij}).

El cálculo del tercer indicador (I_3), *proporción entre P_g y P_{ng}* , fue posible gracias a que los datos empleados están clasificados (terreno y no-terreno). Este indicador controla la diferencia entre el ratio $P_g:P_{ng}$ obtenido a partir de los datos originales y los reducidos. Para ello se calcula la diferencia absoluta entre ambos, $D_{D_{P_g:P_{ng}}}^O$, donde una vez más $D \in [1.5, 1, 0.5, 0.25, 0.1, 0.05, 0.025, 0.01]$. Al igual que en el caso anterior, se considerará que el grado de cumplimiento es *bueno* si la diferencia entre ratios difiere menos del 5% del valor del ratio $P_{gO}:P_{ngO}$ (calculado a partir de los datos originales y clasificados en este estudio); *regular* si dicha diferencia se encuentra entre el 5% y el 10% de dicho ratio y *malo* si la diferencia es superior al 10% (Tabla 2.2).

Finalmente, como consecuencia de las operaciones que realizan los diferentes métodos de reducción para disminuir la densidad de puntos, puede suceder que la densidad de puntos que se obtiene (D_R) y la deseada (D_D) no coincidan exactamente. Esta situación se dio el estudio realizado por Ruiz et al. (2014), donde se tuvieron que descartar parte de las muestras de nubes de puntos reducidas por no alcanzar la densidad fijada. Algunos desarrolladores de estos métodos, como por ejemplo McGaughey (2010), indican que la densidad final puede variar con respecto a la densidad fijada. En el caso particular de la función *ThinData*, esta variación se encuentra entre el 1% y el 3%. Por tanto, para comprobar el nivel de acuerdo que alcanzan los métodos de reducción en relación a este aspecto, se define el cuarto indicador (I_4), *acuerdo entre la densidad fijada y la calculada*. Este indicador se obtiene a partir de la diferencia absoluta entre la densidad deseada y la obtenida tras la aplicación del método de reducción correspondiente. En la Tabla 2.2 se incluyen los umbrales utilizados para evaluar el grado de cumplimiento de este indicador.

2.2.4.2 Evaluación a nivel modelo.

Una gran cantidad de estudios han demostrado la dependencia entre la calidad de los MDT obtenidos a partir de la tecnología LiDAR y algunas características de la toma de datos (por ejemplo, la altura y/o velocidad de vuelo, *field of view*, la estación del año,...) (Hodgson

et al., 2005), la densidad de puntos (Polat et al., 2015), el método de filtrado e interpolación (Sithole y Vosselman, 2004), la resolución del modelo (Montealegre et al., 2015a), el tipo de cobertura (Barreiro-Fernández et al., 2016) o la orografía (Estornell et al., 2011). Sin embargo, son escasos los estudios que han analizado la influencia del método de reducción en la calidad de los modelos, realizándose todos ellos desde el punto de vista de la generalización (Yilmaz y Uysal, 2016) y en ningún caso enfocados a la mejora de la relación coste-beneficio de la toma de datos. Por ello, en este estudio se analiza si los métodos de reducción, junto con los factores *densidad* (calidad de los datos), *pendiente* (morfología del terreno), *coeficiente de variación* (variabilidad topográfica), *tipo de entorno*, la *cobertura y resolución*, influyen en la calidad de los MDT. Un esquema del procesado de los datos LiDAR y el análisis resultados se incluyen en la Figura 2.5.

Durante el procesado de datos (Figura 2.5), se generaron 193 MDT y 5 capas de información por cada muestra de referencia. Los MDT proceden de la interpolación de los P_g de la nube de puntos original con una resolución de 1 m (MDT_O) y de los P_g de las nubes de puntos reducidas obtenidas a partir de 4 métodos de reducción y empleando diferentes resoluciones (MDT_{M-D-R} donde $M \in [RpA, SRpC, ThinData, PpC]$, $D \in [1.5, 1, 0.5, 0.25, 0.1, 0.05, 0.025, 0.01]$ y $R \in [1, 2, 5, 10, 15, 30]$). En este estudio, los MDT_O se consideran la representación más precisa del terreno que es posible obtener a partir de los datos originales. Tanto los valores de densidad como los de resolución se seleccionaron en base a estudios previos. El algoritmo de interpolación empleado es el *Grid-SurfaceCreate* incluido en el programa FUSION (detalles sobre el funcionamiento de esta función pueden consultarse en McGaughey (2010)).

En cuanto a las capas de información, a partir de los MDT_O se obtiene el ráster de pendiente y del coeficiente de variación. Por otro lado, a partir de la nube de puntos original de cada muestra de referencia se crea un ráster de penetrabilidad que refleja el grado de permeabilidad de las superficies. Se obtiene calculando para cada celda la proporción de P_g con respecto al total de puntos (resolución=3 m). También se obtiene un ráster que almacena la proporción de P_g en relación al de P_{ng} en celdas de 3x3 m (ratio $P_{gO} : P_{ngO}$). Finalmente, a partir de estas dos capas y una serie de reglas de decisión incluidas en la Tabla 2.3 se

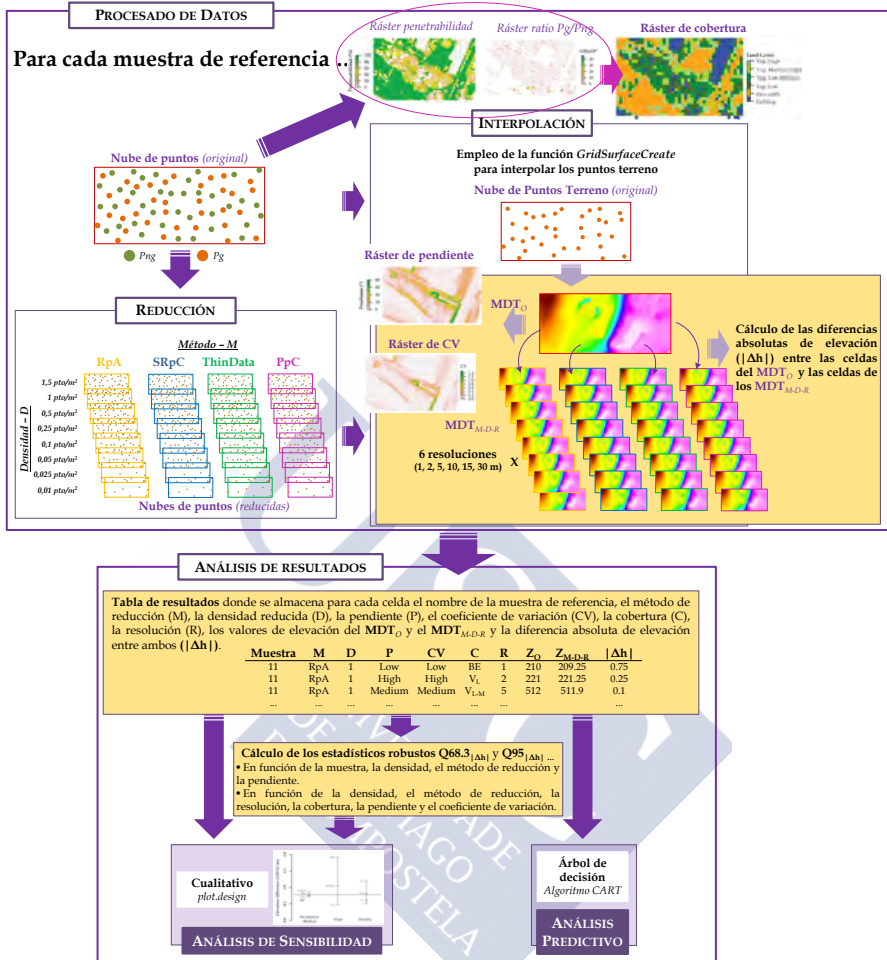


Figura 2.5: Evaluación a nivel modelo. Esquema de procesado y análisis de datos.

obtiene el ráster de coberturas donde se diferencian 6 clases de cobertura (Ed - edificaciones; Sd - suelo desnudo; V_{ad} - vegetación de alta densidad; V_d - vegetación densa; V_{md} - vegetación medio densa; V_{pd} - vegetación poco densa). En la Tabla 2.3 se incluye un resumen de los factores analizados (en negrita), su descripción, la metodología empleada para su cálculo y sus niveles.

Tabla 2.3: Indicadores usados en la evaluación a nivel método.

Factor	Descripción	Se calcula ...	Niveles	Referencias
D Densidad (ptos/m ²)	Esta variable refleja el número de puntos por m ² .	La asignación del valor de esta variable a cada elemento de la <i>tabla de resultados</i> se realiza en bloque a nivel ráster.	1.5; 1; 0.5; 0.25; 0.1; 0.05; 0.025; 0.01	Anderson et al. (2006), Immelman y Scheepers (2011), Hansen et al. (2015), Polat et al. (2015), Assal (2016)
P Pendiente (°)	La pendiente representa la tasa máxima de cambio del valor de elevación.	...a partir de cada MDTo y la función <i>terrain</i> (paquete <i>raster-v.2.5-8</i> de R) (formato: ráster, resolución ^a : 3 m).	Low \Leftarrow P \leq 5° Medium \Leftarrow 5° < P \leq 10° High \Leftarrow P > 10°	Estornell et al. (2011), Gould et al. (2013), Barreiro-Fernández et al. (2016), Ismail et al. (2016)
CV Coefficiente de variación	El CV representa la variabilidad del terreno. En combinación con la pendiente refleja el nivel de homogeneidad.	...a partir de los valores de elevación de las celdas de cada MDTo y la ecuación ^b $CV_{ij} = \frac{\sigma(Z_{ij})}{\mu(Z_{ij})}$ (formato: ráster, resolución ^a : 3 m).	Low \Leftarrow CV \leq 0.05 Medium \Leftarrow 0.05 < CV \leq 0.15 High \Leftarrow CV > 0.15	Guo et al. (2010)
Rt Ratio $P_g O : P_{ng} O$	Este ratio representa la permeabilidad de los objetos. Se define como la proporción de P_g en relación al número total de P_{ng} dividiendo el número de P_g entre el número de P_{ng} . El cálculo se hace a nivel celda (formato: ráster, resolución ^a : 3 m).	$P_g \Leftarrow P_{ng} O : P_{ng} O = \infty$ $P_g + P_{ng} \Leftarrow \infty > P_g O : P_{ng} O > 0$ $P_{ng} \Leftarrow P_g O : P_{ng} O = 0$	-
Pn Penetrabilidad (%)	La penetrabilidad y el ratio $P_g O : P_{ng} O$ se unen para definir el grado de permeabilidad de las superficies, principalmente la vegetación).	... dividiendo el número total de P_g entre el número total de puntos. El cálculo se hace a nivel celda (formato: ráster, resolución ^a : 3 m).	0% \Leftarrow Pn = 0 100% \Leftarrow Pn = 100 Low \Leftarrow Pn \leq 25 Low-Medium \Leftarrow 25 < Pn \leq 50 Medium-High \Leftarrow 50 < Pn \leq 75 High \Leftarrow Pn > 75	Reutebuch et al. (2003), Montealegre et al. (2015a), Salleh et al. (2015)

continúa en la página siguiente

Tabla 2.3 – Indicadores usados en la evaluación a nivel método (continuación).

Factor	Descripción	Se calcula ...	Niveles	Referencias
Cobertura	Esta variable proporciona información sobre el tipo de cobertura del suelo.	...estableciendo reglas de decisión en base a las variables penetrabilidad y ratio $P_g O : P_{ng} O$ (formato: ráster, resolución ^a ; 3 m).	$Ed \Leftarrow Rt = P_{ng}$ ó $Pn = 0\%$ $Sd \Leftarrow Rt = P_g$ ó $Pn = 100\%$ $V_{ad} \Leftarrow Rt = P_g - P_{ng} \& Pn = Low\%$ $V_d \Leftarrow Rt = P_g - P_{ng} \& Pn = Low-Medium$ $V_{md} \Leftarrow Rt = P_g - P_{ng} \& Pn = Medium-High$ $V_{pd} \Leftarrow Rt = P_g - P_{ng} \& Pn = High$	Su y Bork (2006), Bater y Coops (2009), Spaete et al. (2011), Gould et al. (2013)
M	Esta variable representa el método empleado para reducir la densidad original de puntos.	La asignación del valor de esta variable a cada elemento de la <i>tabla de resultados</i> se realiza en bloque a nivel ráster.	RpA; SRpC; ThinData; PpC	-
R	La resolución es el tamaño de las celdas de los MDT_{M-D-R} .	La asignación del valor de esta variable a cada elemento de la <i>tabla de resultados</i> se realiza en bloque a nivel ráster.	1; 2 5; 10; 15; 30	Anderson et al. (2006), Samii (2008), Pirotti y Tarolli (2010), Stereńczak et al. (2013), Hansen et al. (2015)

a En este estudio se empleó una resolución espacial de 3 m en base a la observación realizada por Salleh et al. (2015), donde se establece la resolución para el cálculo de ratios como $P_g O : P_{ng} O$ o la penetrabilidad debe ser como mínimo 4 veces la media del *point spacing* ($PS = \sqrt{1/D}$).
b CV_{ij} es el valor del coeficiente de variación del MDT_O en la fila i y columna j ; Z_{ij} representa los valores de elevación de las celdas incluidas en una ventana de 3x3 con centro en la celda ij .

Después de obtener las diferentes capas de información, se crea una base de datos con tantos elementos (filas) como celdas tienen los MDT_O multiplicadas por 192 (cantidad de MDT_{M-D-R}), denominada *tabla de resultados* (Figura 2.5). De forma automática se le asigna a cada elemento las coordenadas X e Y del centro de cada celda y el método de reducción y los valores densidad y resolución del MDT_{M-D-R} del que derivan. A partir de las coordenadas de las celdas y las capas de información, a cada elemento se le asignan los valores de la pendiente, coeficiente de variación y cobertura. De igual forma se extraen los valores de elevación del MDT_O y MDT_{M-D-R} , y se calcula la diferencia entre ambos ($|\Delta h|$).

Una vez obtenida la *tabla de resultados*, se comprueba si los factores incluidos en la Tabla 2.3 influyen en la precisión de los MDT. Para ello, se calcula la precisión de cada MDT_{M-D-R} empleando los estadísticos robustos percentil del 68.3% y del 95% ($Q_{68.3|\Delta h|}$ y $Q_{95|\Delta h|}$, respectivamente) propuestos por Hühle y Hühle (2009) para cada nivel de los diferentes factores y combinaciones de factores. Así, el 68.3% y el 95% de los errores tienen una magnitud en un rango de $[0, Q_{68.3|\Delta h|}]$ y $[0, Q_{95|\Delta h|}]$, respectivamente. Estos estimadores no paramétricos se calcularon a partir de las diferencias absolutas en elevación entre cada MDT_O y los MDT_{M-D-R} para cada una de las 9 muestras de referencia ($|\Delta h|$).

Finalmente, se llevaron a cabo dos tipos de análisis: un análisis de sensibilidad y un análisis predictivo. El análisis de sensibilidad se realiza de forma cualitativa a partir de la función *plot.design* (paquete *graphics-v.3.2.1* de R). Mediante esta función se representa gráficamente la magnitud del efecto de cada factor sobre la variable dependiente ($|\Delta h|$). Dicho estadístico se calcula considerando los niveles de los diferentes factores de manera independiente. Así, en el eje X se disponen los factores mientras que los niveles de cada uno de ellos se sitúan a lo largo de una línea vertical. De esta forma, cuanto mayor es la longitud de la línea vertical sobre la que se sitúan los niveles de un determinado factor mayor es la influencia de dicho factor en la precisión de los MDT. Adicionalmente, el valor general del $Q_{68.3|\Delta h|}$ se representa mediante una línea horizontal.

Una de las herramientas de análisis predictivo más comunes, el árbol de decisión, se empleó para completar los análisis anteriores con dos propósitos: 1) predecir el error de los MDT en base a los factores identificados (predictores) (Tabla 2.3); y 2) comprobar si es posible extraer conclusiones acerca de si la combinación de varios de esos factores influye en la calidad de los modelos. Si bien existen múltiples algoritmos para llevar a cabo este análisis, en este caso se emplea el algoritmo CART (*Classification and Regression Tree Analysis*) usado en estudios previos como el de [Bater y Coops \(2009\)](#) o [Montealegre et al. \(2015a\)](#). Se ha seleccionado este análisis debido a que se trata de un método robusto que no requiere que los datos sigan una distribución estadística concreta y es capaz de manejar datos que contienen *outliers* y predictores no significativos ([Bater y Coops, 2009](#)).

Por medio de este análisis es posible identificar una serie de variables independientes (predictores), continuas y/o categóricas, como predictoras de una variable dependiente. En este estudio se consideran variables independientes los 7 factores analizados (densidad, pendiente, coeficiente de variación, tipo de entorno, cobertura, resolución y método de reducción) mientras que la variable dependiente es el error absoluto en elevación ($|\Delta h|$). El resultado de este análisis es un diagrama que representa la división de los datos en grupos homogéneos en base a las variables independientes. Así, el algoritmo busca la variable independiente y el valor que mejor divide los datos (aquel que maximiza la probabilidad de acierto) en dos grupos significativos (este proceso se denomina *split*). Tras dividir los datos, el mismo proceso se vuelve a aplicar a cada subgrupo por separado y así sucesivamente, bien hasta alcanzar un número máximo de iteraciones, bien hasta que no sea posible realizar más subdivisiones. Para evitar divisiones con baja significación es posible establecer un umbral por debajo del cual no se llevan a cabo más divisiones, este proceso se denomina *tree pruning* ([Godone y Garnero, 2013](#)). En este estudio no se ha limitado el proceso de subdivisión.

Para construir el árbol de decisión que relaciona las variables independientes con los errores absolutos de elevación de los modelos se empleó la función *rpart* (paquete *rpart-v.4.1-11* de R) ([Therneau et al., 2017](#)). Dicho árbol fue construido tomando como datos de entrada el

10% de los datos de la *tabla de resultados* (selección aleatoria), la cual contiene $\simeq 30$ millones de datos.

2.3 Resultados y discusión

2.3.1 Evaluación a nivel método ...

Para realizar la evaluación a nivel método se definieron 4 indicadores: *I1-distribución de los puntos*, *I2-proporción entre retornos*, *I3-proporción entre P_g y P_{ng}* y *I4-acuerdo entre la densidad fijada y la calculada* (en la Tabla 2.2 se pueden consultar los detalles de estos indicadores). En la Figura 2.6 se incluye un resumen de los resultados de los indicadores para los cuatro métodos de reducción en relación a los diferentes niveles del factor densidad. En esta figura, las columnas representan los diferentes niveles del factor densidad para cada método de reducción, mientras que las filas representan los 4 indicadores empleados para evaluar el funcionamiento de dichos métodos. A cada combinación de indicador, método de reducción y densidad de puntos, le corresponde un bloque de 9 celdas que se identifican con las diferentes muestras de referencia. Finalmente, cada celda fue codificada con un color en función del grado de cumplimiento de cada indicador (ver grados de cumplimiento en la Tabla 2.2).

Atendiendo a la Figura 2.6 se observa como, salvo excepciones puntuales, el grado de cumplimiento se reduce a medida que la densidad de puntos decrece. Los mejores resultados se obtienen a partir del método *PpC* al predominar las celdas verdes (grado de acuerdo *bueno*) sobre las que indican un grado de cumplimiento *regular* o *malo*. En el extremo opuesto se encuentran los métodos *SRpC* y *ThinData*.

Si se realiza un análisis individualizado, se tiene que el indicador ***distribución de puntos*** (*I1*), el cual refleja la correspondencia entre la distribución original de puntos y la que presentan las nubes de puntos reducidas, resultó ser el criterio más conflictivo. En las Figuras 2.7 y 2.8 se incluyen los resultados cualitativos y cuantitativos




Figura 2.6: Resultados de los indicadores a nivel método (B-Bueno; R-Regular; M-Malo). (La densidad original de la muestra 41 es 1.27 ptos/m², de ahí las celdas en color negro para una densidad de 1.5 ptos/m²).

relacionados con dicho indicador para las muestras de referencia 31 y 42, respectivamente (los resultados para el resto de muestras se incluyeron en el Anexo B.3). Se seleccionaron estas muestras por poseer una zona de solape entre pasadas, donde la variación de la densidad de puntos es más evidente. Como resultados cualitativos, se incluye la densidad de puntos normalizada (escala de 0 a 1) de los datos originales y de las nubes de puntos reducidas en formato ráster. Por otro lado, los resultados cuantitativos del grado de cumplimiento del *I1* vienen representados por el ajuste lineal tras comparar la distribución de la nube de puntos original y las nubes reducidas (comparación a nivel píxel).

En los ejemplos de las Figuras 2.7 y 2.8 se observa como las nubes de puntos reducidas a partir de los métodos *SRpC* y *ThinData* no conservan en ningún caso la distribución original de los puntos, pues el resultado de la reducción son nubes con puntos homogéneamente distribuidos. En el caso de estos métodos, los malos resultados de dicho indicador eran predecibles. Esta circunstancia se debe a uno de los objetivos que persiguen, la obtención de una nube de puntos con densidad uniforme, de forma que se elimina totalmente la heterogeneidad de la distribución original de los puntos. La idea de que una distribución homogénea

de los puntos repercute positivamente en la eficiencia del procesado de los datos LiDAR, es el principal motivo por el que estos métodos han sido desarrollados (Watt et al., 2014, Ruiz et al., 2014). Sin embargo, también ha sido considerada una limitación en otros estudios, pues se cree que una nube de puntos con densidad homogénea es puramente artificial y se encuentra muy alejada de la estructura típica de las nubes de puntos originales (Magnussen et al., 2010, Wilkes, 2016). Si bien dicha simplificación presenta ventajas como la disminución del tiempo de procesado o incluso la reducción de algunos errores durante el proceso de filtrado, posiblemente no justifiquen la pérdida de detalle tanto en la representación del terreno como en la caracterización de la estructura de la vegetación en zonas donde la densidad de puntos es mayor.

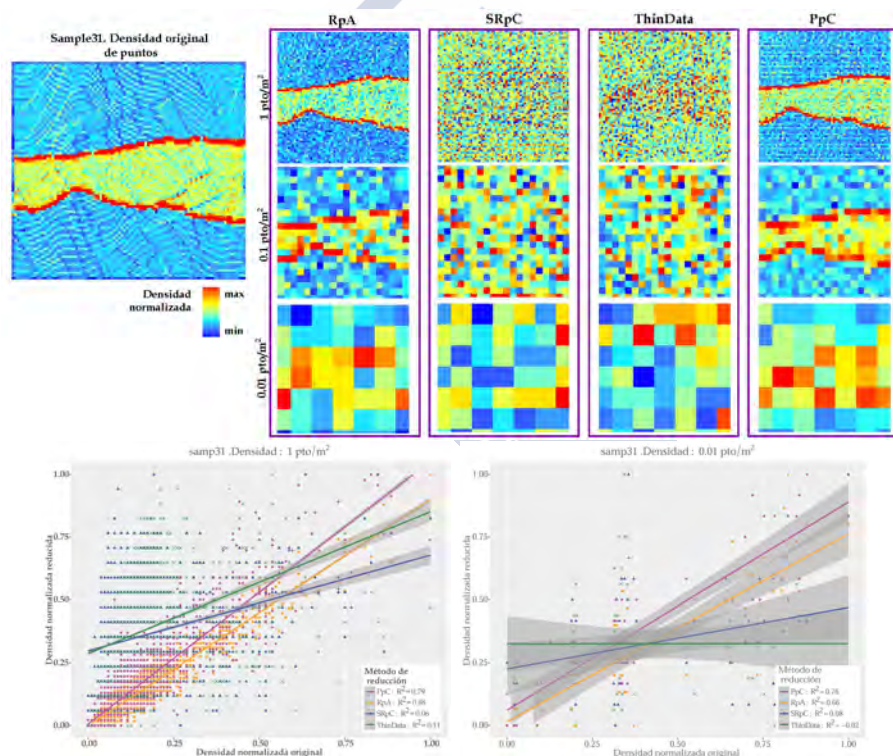


Figura 2.7: Muestra 31 - Indicador 1: Resultados cualitativos y cuantitativos.

A diferencia de los casos anteriores, los métodos *RpA* y *PpC* conservan la distribución original de los puntos siempre y cuando la

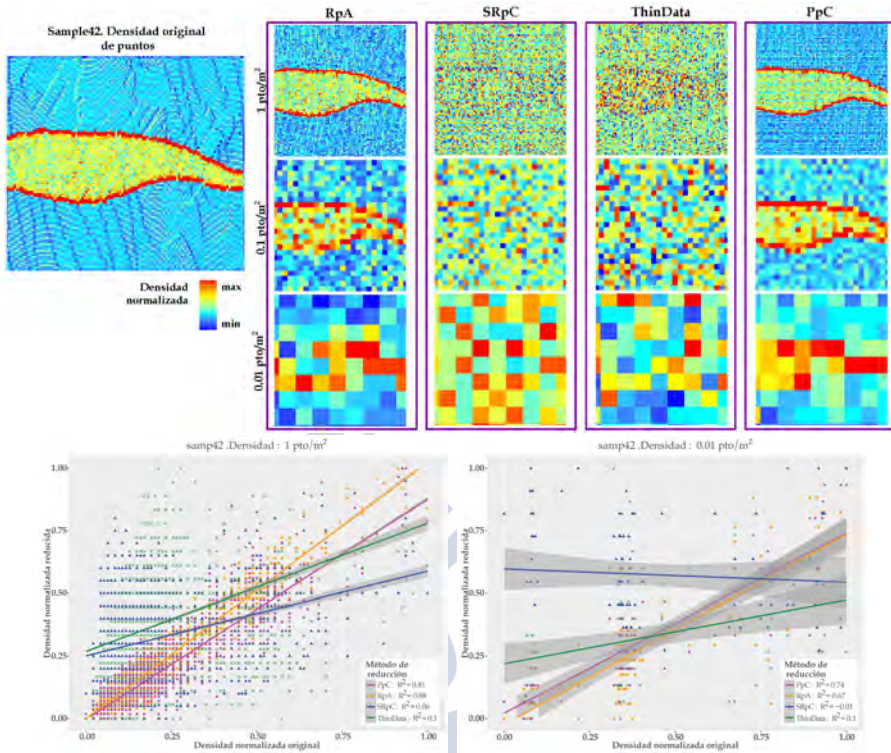


Figura 2.8: Muestra 42 - Indicador 1: Resultados cualitativos y cuantitativos.

densidad reducida no sea muy baja. Esta circunstancia también se observa en la Figura 2.6, donde al emplear el método *RpA* existe una relación directa entre el grado de cumplimiento del *I1* y la variación de la densidad de puntos, de forma que cumplir con este criterio es más difícil cuanto más se reduce la densidad de puntos. En el caso de los resultados del método *PpC* no se aprecia dicha relación, ya que los peores resultados del *I1* se observan cuando la densidad es máxima (1.5 ptos/m²) y mínima (0.01 ptos/m²), sin embargo en ningún caso el *R*² es inferior a 0.72 (en la Tabla B.1 del Anexo B.3 se incluyen los resultados del ajuste).

Por otro lado, el *I2*, *proporción entre retornos*, es la característica mejor conservada por los diferentes métodos de reducción. En general, para densidades iguales o superiores a 0.1 ptos/m² el grado de

cumplimiento de este indicador es *bueno* con la excepción de las muestras 21 y 41 reducidas con los métodos *ThinData* y *RpA*, respectivamente. En este caso, *SRpC* es el método que mejor se comporta en relación a la conservación de la proporción entre retornos pues muestra un acuerdo *bueno* en todos los casos. Se esperaban estos resultados pues dicho método tiene en cuenta el tipo de retorno a la hora de reducir la densidad de puntos. En el extremo opuesto se encuentra el método *RpA*, el cual vuelve a mostrar una relación directa entre el grado de cumplimiento de dicho indicador y la variación de la densidad de puntos, de manera que la conservación de la proporción entre retornos empeora a medida que la densidad disminuye. En cuanto a los métodos *ThinData* y *PpC* sus resultados fueron muy buenos, pues en el 90% y 95% de los casos respectivamente el grado de acuerdo fue *bueno*. Para estos métodos los peores resultados se concentran en las nubes de puntos con una densidad de 0.01 pts/m² y no se observa un patrón claro en su ocurrencia.

Tal y como ya se mencionó, este indicador refleja el acuerdo entre el ratio *FR:LR* de los datos originales y de las nubes de puntos reducidas. El no cumplimiento de este indicador por parte de los diferentes métodos puede introducir errores en la caracterización de las zonas con vegetación. Analizando los resultados cuantitativos del grado de cumplimiento de este indicador se tiene que la mitad de los errores cometidos por el método *RpA* y por el método *ThinData* tienen signo positivo, bien por la reducción el número de primeros retornos bien por el aumento de últimos retornos en las nubes de puntos reducidas. Sin embargo, el 80% de los errores cometidos por método *PpC* proceden de una diferencia negativa entre ratios, de tal forma que su empleo podría influir de forma negativa en la creación de MDT. Sin embargo, si bien ha de tenerse en cuenta esta observación, la magnitud de los errores cometidos en relación al *I2* es de los más bajos en comparación con el resto de métodos (datos obtenidos a partir de los resultados incluidos en la Tabla B.2 del Anexo B.3).

En el caso del *I3*, **proporción de P_g en relación a los P_{ng}** , los métodos *SRpC* y *ThinData* son los que muestran las mayores dificultades para conservar esta característica mientras que los métodos *RpA* y *PpC* conservan bien la proporción original de puntos terreno y objeto, aunque su efectividad se reduce ligeramente a medida que la densidad disminuye

(Figura 2.6). En referencia a los resultados de los dos primeros métodos, el grado de cumplimiento del $I3$ disminuye a medida que la densidad de puntos se reduce, de forma mucho más evidente en el caso del método *ThinData*. En este punto, sorprenden las diferencias de cumplimiento en relación a $I2$ e $I3$ del método *SRpC*, pues en general en zonas permeables los primeros retornos se corresponden con P_{ng} y los últimos retornos con P_g . Esta circunstancia nos puede llevar a pensar que la conservación de la proporción entre retornos implica la conservación de la proporción entre P_g y P_{ng} , cuando realmente no está siendo así. Por otro lado, analizando los resultados cuantitativos del grado de cumplimiento del $I3$, se tiene que las diferencias $D_{RP_g:P_{ng}}^O$ tienen signo negativo en el 75% de las muestras reducidas con el método *SRpC*, y en el 65% empleando el método *ThinData*, lo que indica un aumento de la proporción de P_g en relación a los P_{ng} en las nubes de puntos reducidas (datos obtenidos a partir de los resultados incluidos en la Tabla B.3 del Anexo B.3). Esta circunstancia ocurre en las muestras 22, 23, 31 y 42, donde la gran mayoría de las nubes de puntos reducidas con estos dos métodos fallan en el cumplimiento de este indicador. Complementariamente, la mayoría de las diferencias $D_{RP_g:P_{ng}}^O$ con signo positivo (disminución de la proporción de P_g en relación a los P_{ng} en las nubes de puntos reducidas) se dan en la muestra 24. Una posible explicación de por qué se están dando estos fenómenos tenga relación con la existencia de zonas de solape entre pasadas, las características de los datos en estas zonas y el comportamiento de los diferentes métodos de reducción ante estas casuísticas.

Para comprobar esta hipótesis se calculan los $I2$ e $I3$ a partir de las nubes de puntos originales considerando por separado las zonas con y sin solape para cada muestra de referencia (en la Tabla 2.4 *zona solape* y *zona no solape*, respectivamente). Los resultados de este cálculo se incluyen en la Tabla 2.4 junto con los valores reales que se usaron para establecer el grado de cumplimiento de dichos indicadores (*zona completa*). Así, se observa como las muestras 22, 23, 31 y 42, donde la mayoría de las nubes de puntos reducidas producen valores negativos de $D_{RP_g:P_{ng}}^O$ con un grado de cumplimiento *regular* o *malo*, presentan reducciones del 24%, 17%, 32% y 26%, respectivamente, del valor del ratio $P_g:P_{ng}$ en las zonas con solape con respecto al mismo ratio calculado para toda la zona. Estos resultados indican que en las

zonas de solape de estas muestras hay una reducción del número de P_g en relación a los datos de toda la zona. En la situación contraria se encuentra la muestra 24, la cual presenta un aumento del 30% del ratio $P_g:P_{ng}$ en zonas con solape en comparación con el ratio obtenido para toda la zona. Pero ¿cómo estas diferencias llegan a afectar al grado de cumplimiento del $I3$? ¿Cómo un menor (muestras 22, 23, 31 y 42) o mayor (muestra 24) número de P_g en zonas de solape entre pasadas produce, respectivamente, un aumento o disminución de los ratios $P_{gR}:P_{ngR}$ con respecto a los ratios de las nubes de puntos originales cuando se emplean los métodos *SRpC* y *ThinData*?

Tabla 2.4: Valores de los $I2$ e $I3$ a partir de los datos originales y diferenciando entre las zonas con y sin solape.

Muestra	Zona completa		Zona solape		Zona no solape		
	$\frac{FR_O}{LR_O}$	$\frac{P_g O}{P_{ng O}}$	$\frac{FR_O}{LR_O}$	$\frac{P_g O}{P_{ng O}}$	$\frac{FR_O}{LR_O}$	$\frac{P_g O}{P_{ng O}}$	
	Muestra 11	1	1	0.99	1.07 ↑ P_g 6%	1	0.96
Muestra 12	1	0.83	1.01	0.72 ↓ P_g 13%	1	0.85	
Muestra 21	1	1.85	0.97	2.08 ↑ P_g 11%	1	1.70	
Muestra 22	1	1.82	1	1.39 ↓ P_g 24%	1	2.45	
Muestra 23	1	0.99	0.99	0.82 ↓ P_g 17%	1	1.13	
Muestra 24	1	1.72	0.99	2.46 ↑ P_g 30%	1	1.44	
Muestra 31	1	0.91	1	0.62 ↓ P_g 32%	1	1.27	
Muestra 41	1	0.95	<i>No tiene zona de solape</i>				
Muestra 42	1	0.39	1	0.29 ↓ P_g 26%	1	0.5	

Nota: Para las zonas con solape y el $I3$, se muestran en color magenta el aumento de los P_g y en azul la disminución de dichos puntos en comparación con la nube de puntos original.

Por un lado, el ratio $P_{gO}:P_{ngO}$ que se toma como referencia para obtener el grado de cumplimiento del $I3$ se calcula teniendo en cuenta todos los puntos presentes en cada muestra. Este valor será tanto más *fiabile* cuanto más homogénea sea la distribución de los puntos en la nube original. Sin embargo, cuando la nube de puntos presenta zonas de solape entre pasadas, el valor del ratio $P_{gO}:P_{ngO}$ en estas zonas difiere del calculado para todo el área, influenciado principalmente por las características del terreno y los objetos presentes sobre él. Este hecho no tiene mayor importancia si el método de reducción que se emplea mantiene la distribución original de los datos (cumplimiento del $I1$ tal y como se observa en los resultados de los métodos *RpA* y *PpC* incluidos

en la Figura 2.6). Sin embargo se vuelve crítico si el método empleado produce nubes de puntos reducidas con una densidad homogénea, de forma que el número de puntos que se descartan en las zonas de solape es mayor que en el resto de zonas. En este caso se encuentran los métodos *SRpC* y *ThinData*. Así, si la proporción de P_g es mayor que la de P_{ng} en las zonas de solape, entonces la probabilidad de descartar más P_g que P_{ng} durante la reducción también es mayor y viceversa, provocando diferencias $D_{RP_g:P_{ng}}^O$ positivas y negativas, respectivamente. De esta forma, los fallos en relación al cumplimiento del $I3$ serán tanto más groseros cuanto mayor es la diferencia entre los ratios $P_{gO}:P_{ngO}$ calculados para toda la zona y los de las zonas de solape. Finalmente, en relación a las diferencias en el cumplimiento de los $I2$ e $I3$ por parte del método *SRpC*, en la Tabla 2.4 se comprueba que no existen diferencias entre los ratios $FP_O:LP_O$ calculados para toda la zona y los de las zonas de solape, de ahí que dicho método pueda tener buenos resultados para el $I2$ y malos en relación al $I3$.

En el marco de la generación de MDT y en base a las limitaciones encontradas en relación al cumplimiento del $I3$ por parte de los métodos *SRpC* y *ThinData*, la disminución del número de P_g en las zonas de solape se puede traducir en una pérdida del detalle con el que se representa el terreno en dichas zonas. Esta pérdida será tanto más significativa cuanto mayor sea la complejidad del relieve. Si bien el $I3$ es el que ha puesto de manifiesto esta limitación, su origen se encuentra en el no cumplimiento del $I1$, es decir, la no conservación por parte de las nubes de puntos reducidas de la distribución original de puntos. De ahí que un método de reducción que no conserva dicha característica de la nube de puntos original puede estar influyendo en la precisión no solo de los MDT generados con nubes de puntos con densidades reducidas *artificialmente* sino en otros productos como el cálculo de variables forestales como la altura o volumen de biomasa.

Finalmente, algunos métodos de reducción requieren fijar una serie de parámetros para alcanzar la densidad reducida deseada. La falta de acierto en la selección de los valores más apropiados para estos parámetros puede producir nubes de puntos cuya densidad difiere de la deseada, influyendo en el análisis de cómo la variación de la densidad afecta a la precisión de los modelos. En este contexto se define el $I4$,

acuerdo entre la densidad deseada y la calculada. Tal y como se esperaba, el método *RpA*, donde no se requiere establecer ningún parámetro para llevar a cabo la reducción de la densidad, es el que logra los mejores resultados (Figura 2.6). Por otro lado, los métodos *SRpC* y *ThinData* son los que presentan las mayores dificultades para cumplir con la densidad deseada. Los principales errores de estos métodos se dan cuando la densidad deseada es baja, fundamentalmente menor de 0.25 ptos/m². En el caso de la muestra 41, se aprecian errores en todas las nubes de puntos reducidas, donde a diferencia del comportamiento general, los errores son más groseros cuanto menor es el porcentaje de reducción (datos obtenidos a partir de los resultados incluidos en la Tabla B.4 del Anexo B.3). Los resultados que producen los métodos *SRpC* y *ThinData* en esta muestra probablemente se encuentren relacionados con que se han empleado los mismos parámetros para esta muestra, sin zona de solape, que para el resto de muestras donde la distribución de puntos era más heterogénea.

En esta línea, la selección del tamaño de celda en los dos métodos anteriores podría considerarse como un punto crítico. Según las especificaciones del método *ThinData* incluidas en McGaughey (2010), cuanto menor es el valor del parámetro *Cellsize* (superficie de la celda) menor es la probabilidad de descartar puntos de la nube original, pues aquellas celdas con un único punto no son modificadas, pudiendo dar lugar a nubes de puntos con densidades mayores a las deseadas. Es por ello que se aconseja asignarle un valor elevado a este parámetro, por ejemplo 25 m², a fin de alcanzar una determinada densidad de puntos. A pesar de esta recomendación, algunos investigadores optaron por aumentar gradualmente el valor del parámetro *Cellsize* a medida que la densidad de puntos objetivo (D_D) es reducida. Por ejemplo, Hansen et al. (2015) obtuvieron nubes de puntos con densidades de 8, 4, 2, 1, 0.5, 0.25 y 0.1 a partir de una nube de puntos con densidad de 13 pulsos/m² empleando como tamaño de celda los valores de 0.1, 0.2, 0.5, 1, 2, 10 y 20 m, respectivamente. En el estudio que aquí se presenta, donde la densidad de puntos original no supera los 2.5 ptos/m², el parámetro *Cellsize* se establece de forma que por lo menos dos puntos sean seleccionados en cada celda con el objetivo de alcanzar las densidades reducidas $D_D \in \{1.5, 1, 0.5, 0.25, 0.1, 0.05, 0.025, 0.01\}$. Así, $Cellsize = 2/D_D$ m². Sin embargo, aplicando estos valores se observó

que la densidad de las nubes de puntos reducidas superaban entre un 30% y un 60% la densidad objetivo. Estos valores se encuentran muy por encima de los identificados por [McGaughey \(2010\)](#), donde se afirmaba que los valores finales de densidad difieren de la densidad deseada entre el 1% y el 3%. Esta diferencia entre las densidades deseada y final puede influir en el momento de realizar la evaluación comparativa entre los resultados de los diferentes métodos, ya que no se estarían comparando modelos generados a partir del mismo valor de densidad.

Para mitigar estos desfases se optó por modificar el parámetro *Density* de la función *ThinData*, el cual se había fijado tomando como referencia los valores de D_D . De esta forma, $Density \in \{1.5, 0.75, 0.32, 0.16, 0.064, 0.032, 0.016, 0.006\}$ y $Cellsize \in \{2, 2, 4, 8, 20, 40, 80, 200\}$ m² para obtener nubes con densidades de 1.5, 1, 0.5, 0.25, 0.1, 0.05, 0.025, 0.01, respectivamente. En este caso, la densidad final varía de media un 6% con respecto a la densidad objetivo, valor bastante más bajo al obtenido previamente pero que aún así duplica al indicado por [McGaughey \(2010\)](#). En el caso de la muestra 41, dicho desfase es del 25% de media y los valores finales de densidad se encuentran más próximos a los del parámetro *Density* que a los objetivo (D_D). En base a estos resultados se podría pensar que el método *ThinData* no tiende a generar nubes de puntos con densidades superiores a las del parámetro *Density* si la distribución de los puntos en la nube original es homogénea. A falta de más muestras con estas características, estos resultados podrían indicar que el método *ThinData* es más sensible a las características de la nube de puntos objeto de reducción, como por ejemplo la distribución de puntos, que al valor del parámetro *Cellsize*.

Algunos autores ([Jakubowski et al., 2013](#)) han manifestado que la simulación de nubes de puntos de baja densidad a partir de nubes reales de alta densidad permite realizar análisis meramente informativos y por lo general no simulan de manera realista datos de menor densidad. En base a los resultados y análisis realizados en este apartado se considera que queda demostrado que algunos métodos como el *RpA* y el *PpC* proporcionan nubes de puntos con densidad reducida que mantienen muchas de las particularidades de las nubes de puntos originales, y se las considera lo suficientemente realistas y útiles para analizar la relación que existe entre la densidad de puntos y la precisión de los modelos.

2.3.2 Evaluación a nivel modelo ...

2.3.2.1 Precisión de los MDT

Tal y como hipotetizaron Anderson et al. (2006), desde el punto de vista de la *demanda de productos*, la resolución de un MDT juega un papel crítico a la hora de establecer la densidad de puntos necesaria para la generación eficiente de modelos del terreno, logrando así la precisión deseada a la vez que se reduce el tiempo de procesado y los costes. Algunos estudios como el de Stereńczak et al. (2013) han demostrado que la precisión de los modelos generalmente mejora al aumentar su resolución. En dichos estudios, la densidad de puntos es lo suficientemente elevada (7-8 ptos/m²) como para que la relación resolución-precisión se mantenga próxima a una relación lineal. En otros estudios como el de Immelman y Scheepers (2011), donde la densidad de puntos es baja ($\simeq 1.3$ ptos/m²), también obtuvieron que los modelos con mayor resolución son los que presentan las mejores precisiones. En su caso, la mayor parte de la superficie analizada se corresponde con zonas de pendiente moderada en una zona minera, con ausencia de vegetación donde la mayoría de los puntos pertenecen al terreno y éstos se encuentran homogéneamente distribuidos, circunstancias que simplificarían la tarea de representación del relieve.

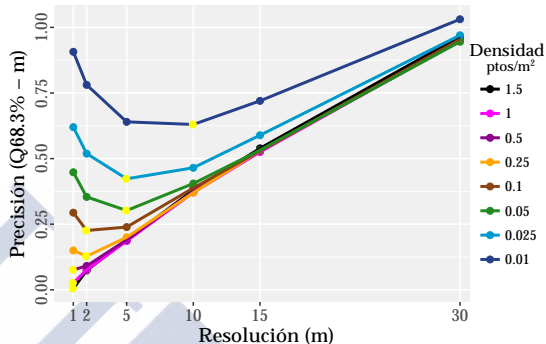


Figura 2.9: Relación entre la densidad y la resolución en referencia a la precisión de los MDT ($Q_{68.3}|\Delta h|$). El punto amarillo marca la resolución óptima para cada densidad.

En contraposición a estos resultados, en la Figura 2.9 se representa la relación **resolución-precisión** ($Q_{68.3}|\Delta h|$ - m) para cada densidad de puntos analizada. Se observa como dicha relación varía dependiendo de la densidad de puntos, donde para densidades superiores a 0.25 ptos/m²,

la relación entre la resolución y la precisión de los modelos es lineal positiva ($R^2 \simeq 1$) mientras que se transforma en polinómica de segundo grado para densidades inferiores a dicho valor ($R^2 \in [0.82, 0.98]$). De esta forma se muestra que no siempre una mayor resolución implica un menor error o mayor precisión de los modelos. Estos resultados también son compartidos por Wu et al. (2008). En base a ellos, se considera que la resolución óptima de los modelos para cada valor de densidad es aquella que da lugar a los modelos más precisos. Dichas combinaciones se han señalado con un círculo amarillo en la Figura 2.9. Estos resultados coinciden con los obtenidos por Smith et al. (2005), donde se establecía que la resolución es dependiente de la densidad de puntos, y su valor puede obtenerse en base al *point spacing* (PS) de los datos LiDAR (resolución = $PS = \sqrt{1/D}$).

Teniendo en cuenta la relación de equilibrio entre la resolución y la densidad establecida por Smith et al. (2005) ($R = PS = \sqrt{1/D}$), si $R > PS$, existe riesgo de pérdida de información debido a la generalización de los modelos, mientras que si $2R < PS$ los valores de los modelos también se verán alterados (celdas vacías) (Fisher y Tate, 2006). En esta línea, el análisis de la influencia que ejerce el par densidad-resolución sobre la precisión de los modelos llevado a cabo por Anderson et al. (2006) muestra que al variar la densidad de puntos, los errores varían más rápidamente en los modelos de mayor resolución en comparación con aquellos cuya resolución es menor. Este efecto puede apreciarse en la Figura 2.9. Si observamos verticalmente los valores de precisión de los modelos para cada una de las densidades desde cada resolución, se tiene que la diferencia de precisión entre los modelos $MDT_{M-D=1.5-R=1}$ y $MDT_{M-D=0.01-R=1}$ se encuentra próxima a 1 m mientras que entre los modelos $MDT_{M-D=1.5-R=30}$ y $MDT_{M-D=0.01-R=30}$ la diferencia es inferior a 20 cm. Estos resultados respaldan la hipótesis planteada por Hodgson y Bresnahan (2004) y los resultados obtenidos posteriormente por Aguilar et al. (2005) en relación al efecto conjunto que varios factores pueden producir en la precisión de los MDT.

Aclarar en este punto que los valores de precisión que se calculan en este estudio están desprovistos del error procedente de la precisión de los datos, pues los modelos *verdad terreno* (MDT_O) han sido creados a partir de los mismos datos que los MDT_{M-D-R} . Este hecho incumple

la norma que establece que para calcular la precisión de un modelo, los datos *verdad terreno* deben ser tres veces más precisos que los puntos empleados para generar los modelos a validar (Höhle y Höhle, 2009). Sin embargo, el objetivo de este estudio no es proporcionar la precisión de los modelos sino comprobar si los factores considerados influyen en su calidad. Para dicho propósito es necesario contar con datos cuantitativos que reflejen las tendencias de la variación de la precisión de los modelos, y aunque los datos LiDAR no son los óptimos para ello, se consideran aptos para alcanzar dicho objetivo. Esta misma estrategia fue empleada por Bater y Coops (2009) para evaluar la capacidad de varios interpoladores a la hora de predecir alturas en lugares donde no existían puntos terreno.

En relación al **método de reducción**, se aprecian diferencias puntuales entre métodos, en algún caso próximas a los 30 cm. Por ejemplo, el $Q68.3_{|\Delta h|}$ para los métodos *SRpC* y *ThinData* con una densidad de 0.01 pto/m² y una pendiente *High* es 1.58 m y 1.84 m, respectivamente. Para analizar las diferencias entre métodos, en la Figura 2.10 se representan mediante diagramas de cajas las diferencias entre las precisiones de los diferentes modelos para cada combinación de los niveles de densidad, pendiente y método de reducción. Para crear esta gráfica, en primer lugar se calculó el estadístico $Q68.3_{|\Delta h|}$ a partir de los errores incluidos en la *tabla de resultados* para cada método de reducción considerando las diferentes combinaciones de los niveles de la pendiente, densidad y resolución. A continuación se restaron entre sí los valores del estadístico $Q68.3_{|\Delta h|}$ para cada combinación resolución-pendiente-densidad. Así, la primera columna de gráficas de la Figura 2.10 representa para cada densidad de puntos, las diferencia entre los estadísticos $Q68.3_{|\Delta h|}$, obtenidos a partir de los errores de las celdas de los $MDT_{M=ThinData}$ y el mismo estadístico derivado de los $MDT_{M \in \{RpA, SRpC, PpC\}}$ para cada nivel de resolución y pendiente. Este mismo proceso se repitió para cada uno de los métodos restantes (en la Figura B.38 del Anexo B.4 se incluyen los resultados considerando el estadístico $Q95_{|\Delta h|}$). De esta forma, diferencias positivas indicarán que los modelos del método que se toma como referencia presentan errores de mayor magnitud que los creados a partir de las nubes reducidas con el resto de métodos.

Basándose en dichas gráficas, en general se observa como las

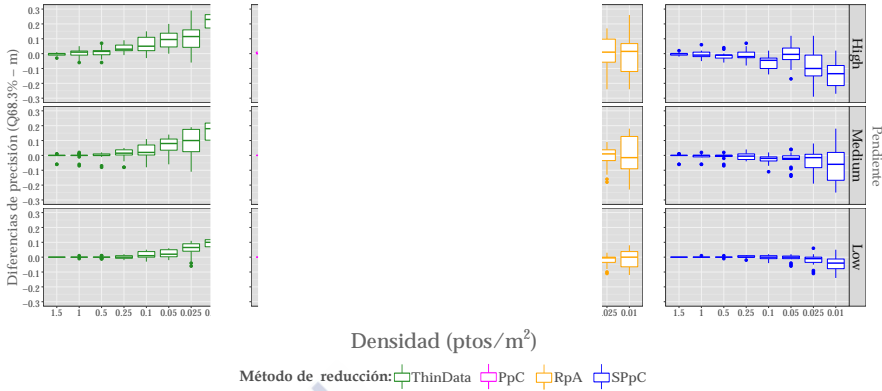


Figura 2.10: Diferencias de precisión entre modelos ($Q68.3_{|\Delta h|} - m$) generados con nubes reducidas por diferentes métodos.

diferencias entre métodos son mínimas para densidades superiores a 0.1 pto/m^2 , principalmente cuando la pendiente es inferior a 10° (*High*). En caso contrario, las diferencias entre métodos son más evidentes y con independencia de la pendiente, los modelos creados a partir de las nubes de puntos reducidas con el método *ThinData* tienden a presentar la mayores diferencias positivas. Este hecho se constata en la primera columna de gráficas de la Figura 2.10, donde para densidades inferiores a 0.25 pto/m^2 , las cajas se localizan en la parte positiva del *eje y*, mientras que para el resto de métodos esta tendencia no se presenta tan clara.

Por otro lado, se establece un valor de resolución óptimo para cada densidad a fin de calcular los valores de precisión de los modelos estratificando por el método de reducción y la densidad de puntos. Para ello se toman como referencia los resultados de la Figura 2.9, de forma que para las densidades de $1.5, 1$ y 0.5 pto/m^2 se consideran los modelos creados con una resolución de 1 m ; para 0.25 y 0.1 pto/m^2 se toman los modelos con resolución de 2 m ; para 0.05 y 0.025 pto/m^2 se toman los modelos con resolución de 5 m ; y para una densidad de 0.01 pto/m^2 la resolución es de 10 m . En este estudio, estos valores de resolución en función de la densidad de puntos se consideran los **valores óptimos de resolución**. En la Tabla 2.5 se incluyen los resultados de la precisión de los modelos para cada par densidad-método en relación a los factores coeficiente de variación, pendiente y cobertura. En este caso,

se consideraron conjuntamente las 9 muestras de referencia y se tomó como representación de la precisión el percentil del 68.3% ($Q_{68.3|\Delta h|}$). Dicho estadístico se obtuvo a partir de las diferencias entre las celdas de cada MDT_O y sus homólogas en los MDT_{M-D-R} de cada muestra.

Los datos de la Tabla 2.5 muestran una relación directa entre la precisión de los modelos ($Q_{68.3|\Delta h|}$) y la **densidad de puntos**, de manera que la precisión disminuye a medida que la densidad decrece, con independencia del método de reducción empleado. Este efecto se observa de forma gráfica en las Figuras 2.11a (considerando todas las resoluciones) y 2.11b (considerando sólo las resoluciones óptimas para cada nivel de densidad). Adicionalmente, estas figuras muestran que el desfase de elevación entre los MDT_O y MDT_{M-D} para $D \geq 0.1$ pto/m² es como máximo de 20 cm mientras que dichos desfases llegan hasta los 80 cm cuando $D < 0.1$ pto/m² (en la Figura B.39 del Anexo B.4 se incluyen los resultados considerando el estadístico $Q_{95|\Delta h|}$ -m). En base a estas figuras, la relación directa entre la precisión y la densidad podría matizarse, pues se observa que la tendencia es que los errores aumenten de manera lineal hasta una densidad reducida de 0.1 pto/m² y a partir de este punto el aumento de los errores es exponencial.

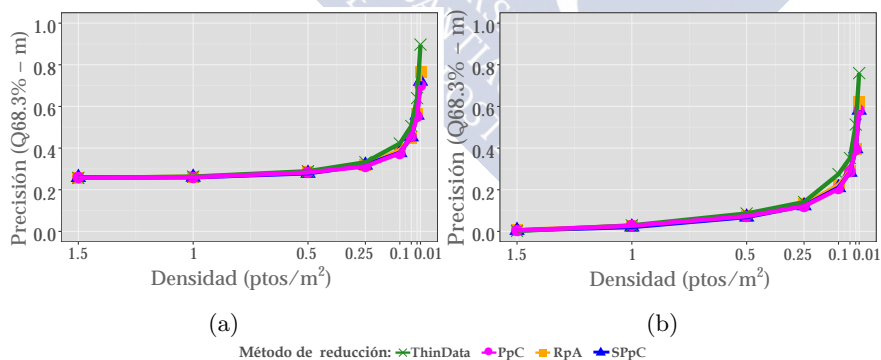


Figura 2.11: Precisión de los modelos ($Q_{68.3|\Delta h|}$ -metros) en función de la densidad y métodos de reducción: a) considerando todas las resoluciones y b) las resoluciones óptimas en función de la densidad.

Tabla 2.5: Precisión ($Q68.3|_{\Delta h_i} - m$) de los modelos en función de la cobertura, la pendiente y el coeficiente de variación en relación a las diferentes combinaciones de los niveles de densidad y método de reducción.

Método→	RpA			SRpC			ThinData			PpC					
	I	0.25	0.1	0.05	0.01	I	0.25	0.1	0.05	0.01	I	0.25	0.1	0.05	0.01
Densidad→	0.02	0.09	0.17	0.25	0.60	0.01	0.08	0.15	0.23	0.53	0.01	0.10	0.21	0.28	0.68
<i>Sd</i>	0.05	0.24	0.35	0.45	0.84	0.05	0.23	0.37	0.48	0.92	0.06	0.25	0.40	0.51	1.08
<i>V_{ad}</i>	0.04	0.18	0.28	0.38	0.77	0.02	0.17	0.27	0.38	0.75	0.03	0.19	0.35	0.44	0.87
<i>V_d</i>	0.03	0.15	0.25	0.34	0.72	0.02	0.15	0.23	0.33	0.67	0.02	0.16	0.30	0.41	0.82
<i>V_{md}</i>	0.02	0.13	0.21	0.28	0.62	0.03	0.13	0.22	0.30	0.66	0.03	0.15	0.27	0.33	0.76
<i>V_{pd}</i>	0.03	0.13	0.23	0.27	0.55	0.03	0.13	0.22	0.26	0.52	0.04	0.15	0.29	0.35	0.72
<i>Ed</i>	0.02	0.07	0.12	0.16	0.35	0.01	0.06	0.11	0.15	0.31	0.02	0.07	0.15	0.18	0.42
<i>Low</i>	0.04	0.16	0.26	0.33	0.74	0.03	0.16	0.26	0.35	0.68	0.04	0.17	0.33	0.44	0.86
<i>Medium</i>	0.09	0.45	0.67	0.91	1.66	0.05	0.42	0.62	0.86	1.58	0.08	0.48	0.72	0.97	1.84
<i>High</i>	0.02	0.08	0.13	0.18	0.40	0.02	0.07	0.13	0.17	0.36	0.02	0.08	0.17	0.22	0.48
<i>Low</i>	0.07	0.33	0.51	0.69	1.43	0.04	0.30	0.46	0.67	1.30	0.06	0.35	0.58	0.77	1.57
<i>Medium</i>	0.15	0.83	1.06	1.48	2.16	0.08	0.79	1.04	1.37	2.14	0.13	0.86	1.12	1.50	2.47
<i>High</i>															

En las Tablas B.5 y B.6 del Anexo B.4 se incluyen los resultados tanto del $Q68.3|_{\Delta h_i}$ como del $Q95|_{\Delta h_i}$ en función de los 6 factores analizados en este estudio.

Sithole y Vosselman (2004) emplearon los datos de la ISPRS para comparar la efectividad de diferentes algoritmos de filtrado. Una pequeña parte de su estudio incluía un análisis del efecto de la reducción de puntos, sin embargo sus resultados no fueron concluyentes. Este fue uno de los motivos que llevó a Puetz et al. (2009) a ampliarlo. Aunque en su estudio únicamente emplearon las muestras rurales (muestras de la 51 a la 71), sus resultados indican que la precisión de los modelos se reduce bruscamente a medida que la densidad disminuye y se aproxima a 0.15 ptos/m^2 ($PS=2.5$). A partir de este punto, la precisión sigue reduciéndose pero de forma más paulatina hasta una densidad de 0.01 pto/m^2 ($PS=10$) a partir de la cual vuelve a caer de forma abrupta. Esta tendencia es contraria a la observada en las Figura 2.11a y 2.11b y a la obtenida en otros estudios donde el efecto de la reducción de densidad sobre la precisión de los modelos es exponencial cuando $D < 0.1 \text{ pto/m}^2$ mientras que en caso contrario la relación es aproximadamente lineal (Sani, 2008, Immelman y Scheepers, 2011). Puetz et al. (2009) justificaron sus resultados por la estrategia de filtrado empleada, pudiendo ser la causante de las diferencias en los matices de la relación precisión-densidad.

Según Anderson et al. (2006), las nubes de puntos LiDAR pueden soportar reducciones sustanciales hasta cierto nivel sin que por ello la precisión de los MDT se vea reducida. Algunos autores como Immelman y Scheepers (2011) o Asal (2016) buscaron identificar el nivel de reducción que permitiera obtener el balance óptimo entre la densidad y el volumen de datos, minimizando la pérdida de precisión de los modelos. Dicho nivel lo establecieron en el 50%. Sin embargo, este valor no es estándar ya que depende de las características de los datos originales, la variabilidad de la topografía y los métodos empleados para generar los modelos. Si este nivel de reducción se transforma a unidades de ptos/m^2 , se tiene que tanto en el estudio de Immelman y Scheepers (2011) como en el de Liu y Zhang (2008) o Asal (2016) dicho nivel de reducción se fija en aproximadamente 0.1 ptos/m^2 (reducción al 10% de una densidad original de 1.26 ptos/m^2 , al 50% a partir de una densidad de 0.2 ptos/m^2 y al 37.3% a partir de una densidad de 0.27 ptos/m^2 , respectivamente). Concretamente, Asal (2016) comparó varios perfiles longitudinales extraídos a partir de MDT elaborados con diferentes densidades de puntos. En su

estudio observó que las desviaciones en elevación entre perfiles aumentan significativamente cuando dichos perfiles proceden de MDT creados con densidades inferiores a 0.10 ptos/m^2 . Estas comparaciones se realizaron empleando como datos de control los mismos datos que se usaron para generar los diferentes modelos. De tal forma que se podría pensar que este umbral puede no mantenerse si el cálculo de las desviaciones se hiciera en base a puntos de control externos. En este sentido, [Asal \(2016\)](#) también analizó dichas diferencias mediante el empleo de un conjunto de puntos de control capturados en campo. Así, los resultados anteriores se vieron reforzados al comprobar que el umbral en este caso es de 0.13 ptos/m^2 , a partir del cual los residuales aumentan de forma exponencial a medida que la densidad se reduce (se corresponde con un nivel de reducción de los datos al 47.5%).

En resumen, si se considera la densidad como un factor de influencia aislado, tanto los resultados del estudio que se presenta aquí como los obtenidos en investigaciones previas ([Liu y Zhang, 2008](#), [Immelman y Scheepers, 2011](#), [Asal, 2016](#)), muestran como hasta una densidad de 0.1 ptos/m^2 la precisión de los MDT no se ve comprometida de manera evidente. Sin embargo esta afirmación es cierta con matices. En primer lugar, su cumplimiento puede asegurarse para una densidad de puntos original baja (no mayor de 2 ptos/m^2) y en segundo lugar, la variación de la resolución de los modelos parece no afectar a la tendencia aunque sí a la magnitud de los errores, de forma que existe una diferencia positiva de 30 cm si se consideran todos los niveles de resolución que si únicamente se tienen en cuenta los valores óptimos (datos obtenidos comparando la [Figura 2.11a](#) con la [Figura 2.11b](#)). En base a estos resultados se podría decir que la selección inadecuada de la resolución de los modelos derivados de una nube de puntos, puede suponer un incremento de 30 cm en el error de los modelos.

Los resultados obtenidos por [Anderson et al. \(2006\)](#) difieren en este último punto, pues en su caso el nivel de reducción de la densidad a partir del cual se ve afectada la precisión de los modelos depende de la resolución. Esta diferencia de resultados puede ser debida bien a que la densidad de los datos empleados por [Anderson et al. \(2006\)](#) es casi 5 veces superior a la de los datos empleados en este estudio bien a las diferencias en la estrategia para obtener los errores de los modelos. En su

caso, si bien los MDT_O de referencia también se obtuvieron a partir de la nube de puntos original, éstos fueron interpolados empleando diferentes valores de resolución con el propósito de equipararlos a los MDT derivados de las nubes de puntos reducidas. Este proceso provocó una generalización de los modelos (al existir más de un punto por celda, el valor que se le asigna es el valor medio de elevación de los puntos que caen en su interior), de manera que cuanto menor es el nivel de generalización mayores son las diferencias con los MDT_O de referencia. [Stereńczak et al. \(2013\)](#) señalaron en su estudio que una posible razón para la ocurrencia de este fenómeno sea que en zonas donde la vegetación es muy densa no existe la suficiente cantidad de puntos terreno para satisfacer las necesidades que demanda el empleo de elevadas resoluciones espaciales, ocasionando grandes errores. Esta circunstancia produce que el nivel de reducción de la densidad sin incidencia en la precisión de los modelos varíe dependiendo de la resolución espacial empleada. Adicionalmente, en base a que la densidad está relacionada tanto con la morfología del relieve como con el uso del suelo, [Anderson et al. \(2006\)](#) advierten en su estudio que sus resultados deberían ser comparables únicamente con aquellos obtenidos en zonas forestales cuyo relieve no es muy accidentado. Por tanto, el tipo de entorno también pudo ser uno de los factores que propiciaron las diferencias entre sus resultados y los obtenidos en este estudio.

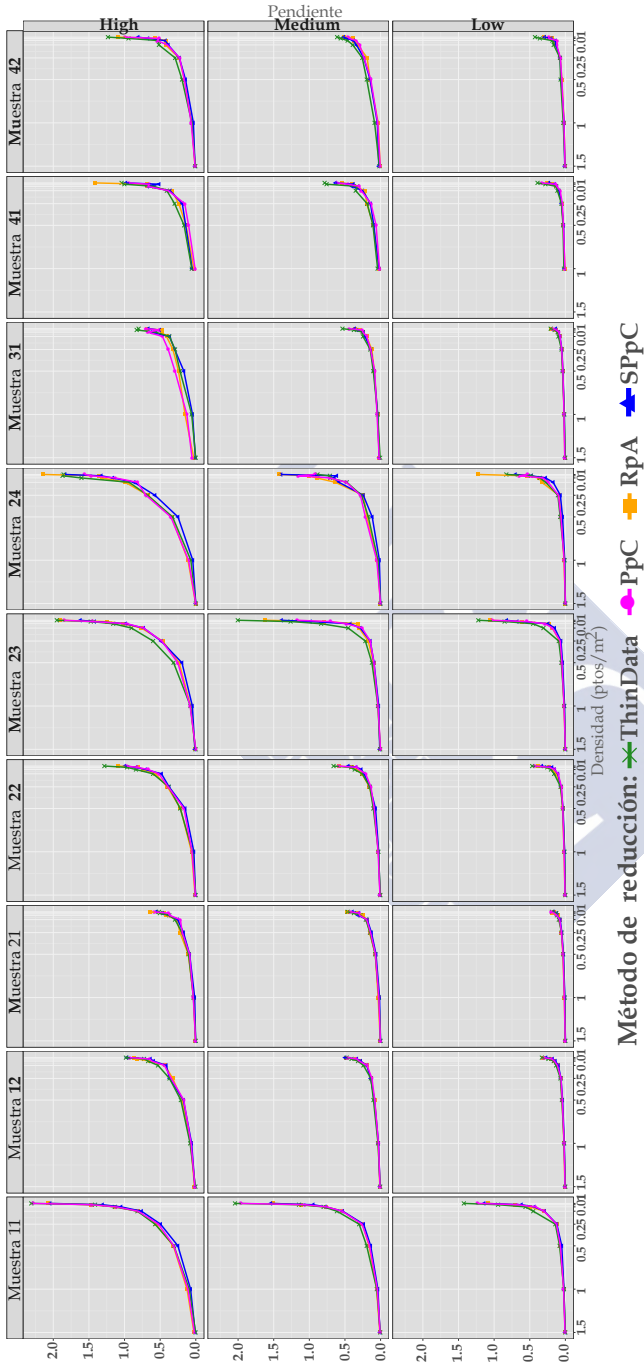


Figura 2.12: Precisión general de los MDT ($Q_{68.3} \Delta_k | - m$) para cada muestra en función de la densidad de puntos, el método de reducción y la pendiente de los modelos (para cada combinación de método de reducción y densidad se emplearon los modelos con la resolución óptima en relación a la densidad).

En relación a la Figura 2.12, para todas las muestras se sigue observando una relación inversa entre la precisión de los modelos y la densidad de puntos con independencia de la pendiente (en la Figura B.40 del Anexo B.4 se incluye el gráfico con los resultados empleando el $Q95_{|\Delta h|}$). Sin embargo, esta relación también presenta matices pues en algunos casos, como en las muestras 12, 21, 22, 31, 41 y 42, la diferencia de precisión entre los $MDT_{M-D=1-R=1}$ y $MDT_{M-D=0.01-R=10}$ varía entre los 18 cm (muestra 31) y los 50 cm (muestra 22) mientras que para el resto de las muestras (11, 23 y 24) esta diferencia varía entre 1 m (muestra 24) y los 2.05 m (muestra 11).

Lógicamente, la reducción de la densidad de puntos provoca que el número de P_g también se reduzca. En este sentido, Sithole y Vosselman (2004) identificaron la densidad y distribución de P_g como factores a tener en cuenta a la hora de producir MDT. Si bien los resultados obtenidos en estudios previos respaldan esta afirmación (Barreiro-Fernández et al., 2016), en el estudio que aquí se presenta, tras considerar los porcentaje de superficie sin puntos terreno y la proporción de P_g frente a los P_{ng} incluidos en la Tabla 2.1, no se encuentra una relación evidente entre dichos factores y las diferencias en la relación precisión-densidad entre las muestras de referencia. Sithole y Vosselman (2004) identificaron 3 posibles razones para dichas diferencias: las características y parámetros del algoritmo de filtrado empleado para identificar los P_g , el efecto borde y las características del entorno. En este caso, las dos primeras causas no han tenido ningún efecto sobre los resultados ya que los datos han sido clasificados empleando un único método (combinando procesos automáticos y manuales). Sin embargo, las características del entorno es un factor a tener en cuenta a la hora de encontrar explicaciones al diferente comportamiento de los modelos al variar la densidad de puntos. En este sentido, las muestras 11, 23 y 24 representan entornos mucho más complejos que el resto de muestras. Para respaldar esta afirmación, se ha caracterizado cada una de las muestras extrayendo los porcentajes de superficie correspondientes a cada nivel de las capas de información CV, pendiente y cobertura. Los resultados se incluyen en la Tabla 2.6, donde se observa como las muestras 11, 23 y 24 presentan los mayores porcentajes de superficie con **pendiente** y **CV** elevada. Adicionalmente, las muestras 11 y 24 presentan una gran proporción de superficie con vegetación, donde

se produce una reducción del número de P_g y por tanto una peor caracterización del terreno.

Tabla 2.6: Características de las muestras en relación a los factores cobertura, pendiente y coeficiente de variación (% de superficie para cada muestra de referencia).

Muestra→	M11	M12	M21	M22	M23	M24	M31	M41	M42	
Cobertura	<i>Sd</i>	27.3	37.86	12.08	18.23	40.58	19.66	42.12	52.05	63.51
	<i>V_{ad}</i>	11.01	5.98	7.73	3.46	3.59	13.36	7.00	1.62	4.97
	<i>V_d</i>	19.53	13.05	22.19	10.97	10.6	24.51	11.71	6.75	8.05
	<i>V_{md}</i>	10.3	8.89	11.65	7.35	8.14	11.57	7.31	3.66	4.95
	<i>V_{pd}</i>	3.14	3.50	4.48	2.53	2.51	2.00	3.28	1.29	2.08
	<i>Ed</i>	28.73	30.72	41.88	57.47	34.57	28.92	28.58	34.63	16.44
Pendiente	<i>Low</i>	13.23	68.49	70.54	63.87	47.44	38.00	89.38	67.92	84.84
	<i>Medium</i>	10.54	19.85	19.90	17.29	21.64	17.25	8.09	13.29	5.22
	<i>High</i>	76.23	11.66	9.56	18.84	30.92	44.75	2.53	18.79	9.94
CV	<i>Low</i>	22.98	87.14	85.78	77.18	65.84	50.02	96.78	78.56	88.38
	<i>Medium</i>	44.34	10.77	14.21	16.45	22.32	29.12	2.69	20.47	11.60
	<i>High</i>	32.68	2.08	0.02	6.37	11.84	20.86	0.54	0.97	0.02

En la Tabla 2.5 además de la relación densidad-precisión, también se puede ver como la precisión de los modelos decrece a medida que aumenta la pendiente. Algunos autores como Guo et al. (2010) encontraron una relación lineal entre la pendiente y el CV ($R^2=0.76$), lo que los condujo a elegir uno de ellos, en su caso fue el CV. En este estudio se encontró que la relación entre ambos factores es polinómica de segundo orden ($R^2=0.91$). A diferencia del estudio citado, en este caso la evaluación del efecto que produce la pendiente y el CV sobre la representación del relieve, salvo en casos puntuales, se realizará de forma conjunta sin descartar ninguno de los factores. Así, según los datos incluidos en la Tabla 2.5, el valor de los errores obtenidos en zonas cuya pendiente es superior a 10° o donde el CV se encuentra por encima de 0.15 casi triplica a los obtenidos en zonas de menor pendiente y variabilidad topográfica, independientemente de los factores densidad de puntos y método de reducción.

Los resultados anteriores coinciden con los obtenidos en otros estudios, donde los errores observados en zonas llanas (pendiente inferior a 10%) son duplicados (Hodgson y Bresnahan, 2004, Spaete et al., 2011)

o triplicados (Hollaus et al., 2006, Barreiro-Fernández et al., 2016) por aquellos que se dan en zonas con pendiente más elevada. En relación al CV y al igual que en nuestro caso, los análisis realizados por Guo et al. (2010) mostraron la relación directa y lineal entre el aumento del CV y de los errores, viéndose esta relación acentuada por la influencia de la densidad de puntos. Algunos autores consideran que estos errores son debidos a la precisión horizontal de los datos LiDAR, pues puede producir un desplazamiento planimétrico en los MDT (Hodgson y Bresnahan, 2004, Estornell et al., 2011). Si consideramos que el error planimétrico de los datos LiDAR es de 50 cm, para pendientes de 5°, 10° y 20° se tendrían unos errores verticales teóricos de 5, 10 y 20 cm, respectivamente (Estornell et al., 2011). Así, los errores teóricos debidos a la pendiente en zonas abruptas (20°) son el doble que en zonas de pendiente media (10°) y 4 veces superiores a los que se dan en zonas relativamente llanas (5°). De manera que estos valores podrían considerarse la aportación del factor pendiente a los errores de los modelos. Sin embargo, dichas proporciones son válidas únicamente cuando el resto de factores se mantienen constantes. Los resultados cuantitativos incluidos en la Tabla 2.5 muestran como la proporción entre los errores en zonas con diferente pendiente es tanto más semejante a la teórica cuanto menos se reduce la densidad. Sin embargo, a medida que la densidad disminuye dichas proporciones se ven ligeramente ampliadas. Podría tomarse esta evidencia como un indicador del efecto multiplicador de la combinación de varios factores sobre la precisión de los modelos.

En cuanto al factor **cobertura del suelo**, generalmente aquellas coberturas que se encuentran vinculadas a la vegetación son las que influyen más negativamente en la precisión de los modelos. La complejidad de estas coberturas puede expresarse de diferentes formas: nivel de penetrabilidad (vegetación densa vs. no densa); la estructura (varios estratos vs. un único estrato); la altura de la vegetación (baja vs. alta) o combinaciones de ellas, dando lugar a masas más o menos complejas. Para analizar este factor, en la Figura 2.13a se representa la precisión de los MDT ($Q68.3_{|\Delta h|}$ - m) en función de los niveles de cobertura del suelo, prestando especial atención a las coberturas relacionadas con la vegetación, para cada densidad de puntos considerado únicamente los errores de los modelos con resolución óptima

(en la Figura B.41 del Anexo B.4 se incluyen los resultados considerando el estadístico $Q95_{|\Delta h|}$). Se observa como a medida que la densidad se reduce la precisión de los modelos en función de la cobertura siguen las pautas esperadas: mayor precisión en la representación del relieve cuanto menos densa es la vegetación, llegando a una diferencia de más de 20 cm entre los niveles de cobertura vegetación de alta densidad y poco densa cuando la densidad de puntos es de 0.01 pto/m² (Tabla 2.5). Esta hipótesis se basa en que la vegetación muy densa impide el paso del láser y por tanto el número de puntos terreno es menor que en aquellos lugares donde la vegetación es menos densa (Clark et al., 2004). Los resultados obtenidos por Hodgson et al. (2005), Estornell et al. (2011) y Salleh et al. (2015) respaldan esta idea. Reutebuch et al. (2003) también identificó un ligero aumento de la magnitud de los errores en los modelos a medida que la densidad de la vegetación aumentaba, y al igual que en este estudio, dichas diferencias eran pequeñas.

Debido a la metodología de evaluación empleada en este trabajo, resulta complicado comparar cuantitativamente los resultados que aquí se presentan con los obtenidos en otros estudios. Sin embargo, sí es posible comparar diferencias entre valores de precisión. En este sentido, si consideramos los resultados para una densidad de 0.1 pto/m² en zonas de pendiente *Low*, la diferencia entre los niveles de cobertura *suelo desnudo* y *vegetación alta densidad* para los métodos *RpA*, *SRpC*, *ThinData* y *PpC* es de 4.4 cm, 8 cm, 8.1 cm y 6 cm, respectivamente (se emplearon los valores de resolución óptimos para cada densidad). Estos valores son muy similares a los obtenidos por Hodgson y Bresnahan (2004), donde a partir de datos con una densidad de 0.17 pto/m² en una zona llana (pendiente < 5°), obtuvieron un RMSE de casi 20 cm en zonas de vegetación baja (equivalente a la cobertura *suelo desnudo*) mientras que en zonas forestales de caducifolias (equivalente a la cobertura *vegetación alta densidad*) dicho error aumentó hasta los 26 cm, lo que supone una diferencia de 6 cm entre ambos tipos de áreas.

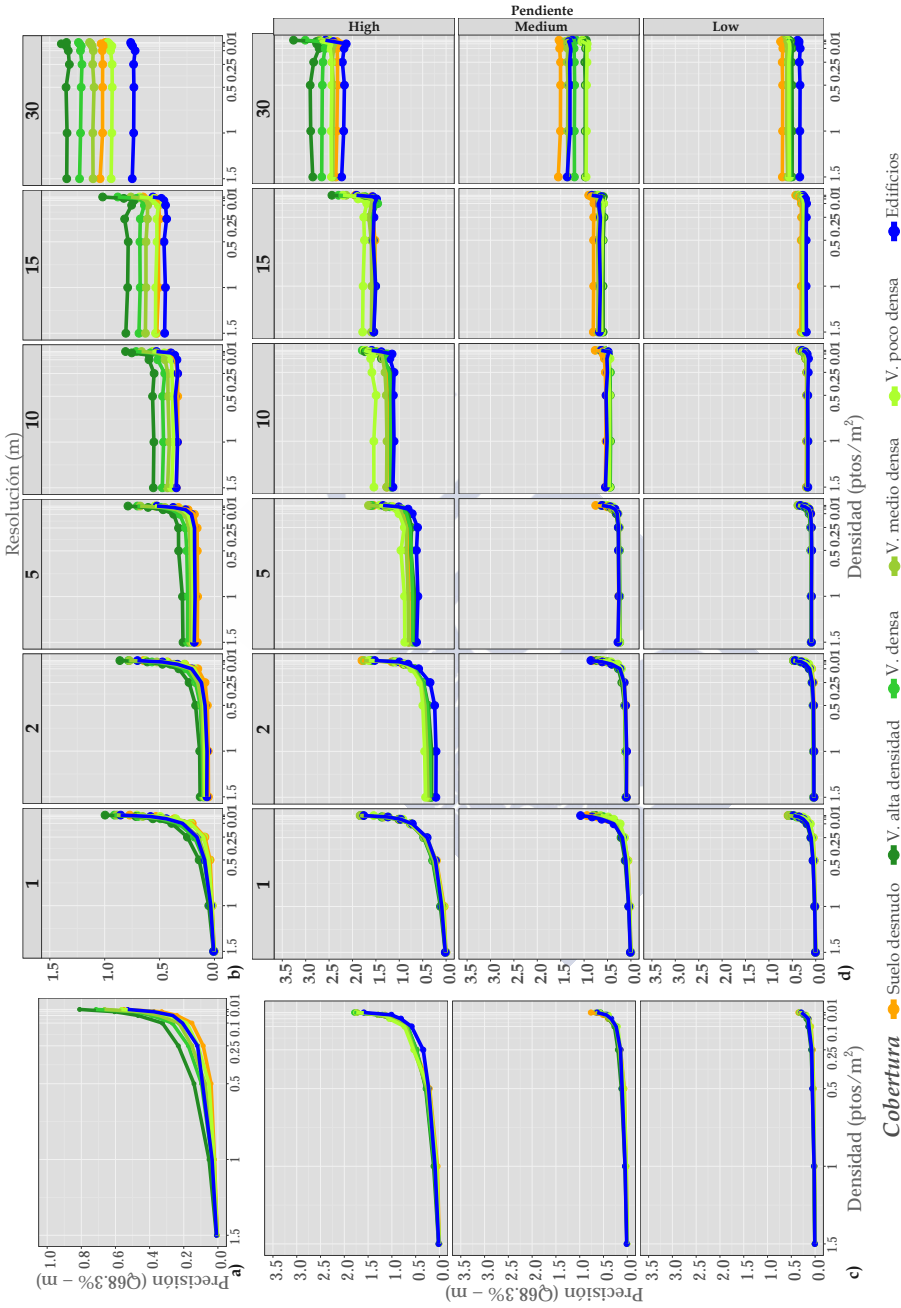


Figura 2.13: Precisión de los MDT ($Q68.3_{|\Delta h|} - m$) teniendo en cuenta la densidad y la cobertura (fig.sup.izq.) (resoluciones óptimas), la resolución, cobertura y la densidad (fig. sup. drch.), la pendiente, densidad y cobertura (fig.inf.izq.) (resoluciones óptimas) y adicionalmente la resolución (fig. inf. drch.).

En oposición a la tendencia anterior, [Barreiro-Fernández et al. \(2016\)](#) mostraron en su estudio que las regiones del MDT donde la vegetación presenta un dosel de copas compacto (frondosas) presentaban mejor precisión que las zonas donde la vegetación arbolada es menos compacta (coníferas). Argumentaron que si bien las primeras impiden el paso de la luz solar, al igual que impiden el paso del rayo láser del sistema LiDAR reduciendo la densidad de puntos terreno, también evitan la existencia de vegetación bajo arbolado, lo que facilita la caracterización del relieve en estas zonas. Adicionalmente, factores como la estación del año en la que tiene lugar la toma de datos (presencia de vegetación bajo arbolado o alta densidad de follaje en verano o capa de hojas sobre el terreno en otoño) ([Triglav-Čekada et al., 2009](#), [Stereńczak et al., 2013](#)), la especie ([Estornell et al., 2011](#)) y la altura de vuelo (a mayor altura de vuelo menor capacidad de penetrar en la vegetación) ([Hyypä et al., 2005](#)) pueden influir en la precisión con la que se representa el terreno en estas zonas. Sin embargo, estos factores pierden importancia si la densidad de puntos es elevada (8 - 10 ptos/m²), pues es posible obtener precisiones similares a las que se logran en zonas sin vegetación ([Reutebuch et al., 2003](#), [Triglav-Čekada et al., 2009](#)), como en el estudio de [Barreiro-Fernández et al. \(2016\)](#). Por tanto, vuelve a ponerse en evidencia que sacar conclusiones universales sobre la influencia de factores externos en la calidad de los modelos es una tarea muy compleja.

Estudios previos también han puesto de manifiesto la existencia de diferencias de precisión de los MDT ante diferentes tipos de cobertura no relacionados con la vegetación ([Spaete et al., 2011](#), [Barreiro-Fernández et al., 2016](#)). A partir de estos estudios se extrae que las zonas con edificaciones tienden a presentar errores groseros debido a fallos en el proceso de filtrado, la complejidad del terreno o por el método de interpolación empleado ([Sithole y Vosselman, 2004](#)). A diferencia de las conclusiones alcanzadas en estudios previos, en este estudio las zonas con edificaciones presentan una precisión similar y en algunos casos mejor que la de las zonas sin vegetación arbolada (*suelo desnudo*) (Tabla 2.5). Esta excepción puede deberse a que la validación se realiza comparando las celdas de los MDT_O con las celdas de los MDT_{M-D-R} y no éstos con puntos de control externos. Al comparar todas las celdas, grandes superficies sin puntos terreno, como las huellas de los edificios, arrojarán errores próximos a 0. Este hecho se da en un elevado porcentaje de

celdas debido a que las muestras de referencia empleadas representan entornos urbanos con grandes edificios. Por tanto, es posible que en estas zonas se esté sobrestimando la precisión de los modelos, situación que probablemente no se daría si la penetrabilidad nula se debiera a la presencia mayoritaria de vegetación arbolada densa.

Hasta este momento la influencia de los diferentes factores sobre la precisión de los modelos se analizó principalmente de manera individual. Sin embargo, estudios previos han mostrado que la interacción entre varios factores puede alterar el patrón de influencia que cada uno de modo individual tiene sobre el error en elevación de los modelos (Hodgson et al., 2005, Guo et al., 2010). En base a este supuesto y con el propósito de analizar el efecto combinado de diferentes factores sobre la precisión de los MDT, en la Figura 2.13 se representan los valores de precisión ($Q_{68.3}|\Delta h$) combinando los factores resolución y pendiente para cada nivel de densidad y cobertura del suelo. En este caso se ha optado por emplear la pendiente y no el coeficiente de variación de la elevación para representar la relación entre los factores citados debido a que la variable pendiente ha sido empleada en más estudios que el coeficiente de variación, circunstancia que facilita la tarea de comparar resultados con estudios previos.

La Figura 2.13b permite analizar la interacción del factor cobertura con la resolución de los modelos. Así, se observa como a medida que disminuye la resolución, la precisión de los modelos para cada una de las coberturas disminuye, al mismo tiempo que las diferencias entre coberturas se hacen más evidentes. Bater y Coops (2009) y Montealegre et al. (2015b) también encontraron que los errores aumentan a medida que la resolución disminuye para diferentes coberturas forestales. Sin embargo, en ambos casos este efecto se aprecia de forma muy sutil debido a que emplearon un número reducido de niveles de resolución cuyos valores son muy próximos entre sí (0.5, 1, 1.5 m y 1, 2 m, respectivamente), lo que impide apreciar si las diferencias entre coberturas varían o permanecen constantes con la disminución de la resolución. Por otro lado, si en la Figura 2.13b se atiende al comportamiento de los modelos en zonas edificadas, se tiene que para resoluciones superiores a 15 m la precisión de los modelos en zonas con *edificaciones* y *suelo desnudo* presentan valores similares, siendo

en esta última cobertura donde la precisión es ligeramente mejor. Sin embargo, cuando la resolución es menor ($R \in [15, 30]$) los modelos en las zonas edificadas son claramente más precisos que en el resto de coberturas, mientras que la cobertura *suelo desnudo* pierde precisión y se convierte en una de las clases a la que más le afecta la disminución de la resolución. Estas zonas son las que presentan la mayor densidad de puntos terreno y por tanto, donde el relieve se encuentra mejor definido, fundamentalmente si la resolución es alta ($R \in [1, 5]$). Sin embargo, si la resolución disminuye, el resultado de la generalización en estas zonas será más evidente que en zonas donde la densidad de puntos terreno es menor, por ejemplo las zonas con *vegetación de alta densidad*, donde originalmente el terreno se encuentra pobremente definido.

Adicionalmente, el efecto que la densidad tienen sobre la precisión de los modelos en cada cobertura se ve alterada por la variación de la resolución. En la Figura 2.13b considerando la mayor de las resoluciones ($R=1$) se observa el mismo patrón de comportamiento que en la Figura 2.11. A medida que la resolución disminuye, dicho patrón se va modificando hasta que la relación entre la densidad y la precisión de los modelos para cada una de las coberturas se vuelve lineal donde la línea de ajuste tiene una pendiente próxima a 0. Esta transformación indica que cuanto menor es la resolución de los modelos menor es la influencia que ejerce la densidad de puntos sobre su precisión, llegando a ser inexistente cuando la resolución es muy baja ($R=30$). Este aspecto ya se puso de manifiesto mediante el análisis de los resultados incluidos en la Figura 2.9 y también fue observada por Guo et al. (2010), en cuyo caso para $R \geq 5$ m, la precisión de los modelos era constante al reducir la densidad de puntos. Estos autores también concluyeron que el empleo de valores altos de resolución (0.5 ó 1 m) contribuye a disminuir la magnitud de los errores en los MDT cuanto más alta es la densidad de puntos. Sin embargo esta mejora es muy pequeña si la reducción de la densidad es inferior al 70%. En su caso, a partir de una densidad original de 1.32 ptos/m², no se observan mejoras en la precisión de los modelos al emplear resoluciones altas para densidades superiores a 0.9 ptos/m². Dichas mejoras tienen una magnitud de 5 cm referidas al RMSE. En el estudio que aquí se presenta, si se consideran los resultados donde $R < 2$ m se observa que dicho efecto se da para densidades superiores a 1 pto/m², lo que representa una reducción del 60% considerando una

densidad original media de 1.75 ptos/m² y diferencias entre modelos inferiores a 5 cm referidas al $Q68.3_{|\Delta h|}$ (Tabla B.5 del Anexo B.4).

En la Figura 2.13d se observa como se produce un efecto similar si se tiene en cuenta la pendiente, de forma que existe una relación directa entre este factor y las diferentes clases de cobertura en relación al error de los modelos. Las precisiones para todas las coberturas en zonas de baja pendiente son 3 y 5 veces mayores que aquellas que se obtienen en zonas de pendiente media y alta, respectivamente. Si mantenemos constante la resolución, un aumento de la pendiente no produce un aumento en las diferencias de precisión de los modelos entre coberturas salvo en el caso más desfavorable, cuando la pendiente toma valores máximos ($P=High$) y la resolución es baja ($R=30$). En cuanto a las diferencias debidas a la pendiente, resultados similares fueron obtenidos por Spaete et al. (2011), donde la precisión de los modelos con un tipo de vegetación determinada y con una pendiente del terreno superior a 10° es el doble que la que presentan las zonas con pendiente menor. Sin embargo, en algunos casos se observa que la diferencia de precisión entre clases aumenta a medida que aumenta la pendiente. Por ejemplo, entre las clases *Low sagebrush* y *Herbaceous* la diferencia de precisión en términos de RMSE es de casi 3 cm cuando la pendiente es inferior a 10° y pasa a multiplicarse por 4 cuando la pendiente es superior. Finalmente, una diferencia con respecto a los resultados analizados previamente es la precisión de los modelos en zonas de suelo desnudo. Cuando la resolución es baja ($R \in [15, 30]$) y la pendiente inferior a 10°, inesperadamente los modelos en dichas zonas tienen los valores de precisión más bajos. Si vinculamos estos resultados con los análisis realizados a partir de la Figura 2.13b se tiene que el efecto de la generalización en zonas de *suelo desnudo* influye más negativamente en zonas donde la pendiente es inferior a 10° que en zonas donde la pendiente se encuentra por encima de este umbral. Probablemente se deba a que la combinación de orografía compleja y presencia de vegetación afecten más negativamente a la representación del relieve que el proceso de generalización.

En la Figura 2.13c se representa la precisión de los modelos (considerando aquellos con resolución óptima) para cada tipo de cobertura en función de la pendiente y la densidad de puntos. En primer lugar, se observa como en general no existen diferencias evidentes

de precisión entre coberturas al variar la pendiente y la densidad de puntos. En segundo lugar, aunque la densidad sea baja, la magnitud de los errores es pequeña en zonas donde la pendiente no excede los 10° ($Q_{68.3}|\Delta h| < 1$ m y si $D > 0.1$ ptos/m², $Q_{95}|\Delta h| < 1$ m - Figura B.41 del Anexo B.4). Sin embargo, en zonas de mayor pendiente, emplear nubes de puntos de baja densidad implica duplicar la magnitud de los errores que se dan en las zonas de menor pendiente empleando las mismas densidades de puntos (si $D < 0.1$ ptos/m², $Q_{68.3}|\Delta h|$ llega a tomar un valor máximo de 1.84 m). Adicionalmente, en las zonas donde la orografía es más compleja se aprecian ligeras diferencias entre coberturas a medida que la densidad de puntos disminuye. En el estudio realizado por Barreiro-Fernández et al. (2016), donde el área de estudio era forestal y se diferenciaron 4 tipos de coberturas (*suelo desnudo*, *matorral*, *caducifolias* y *coníferas*) y 3 niveles de pendiente ($P \leq 4^\circ$; $4^\circ < P \leq 11^\circ$ y $P > 11^\circ$) tampoco encontraron grandes diferencias entre coberturas bajo las mismas condiciones de pendiente. En su caso, considerando que la densidad de puntos terreno en ningún caso fue inferior a 0.3 ptos/m², la precisión de los modelos en zonas donde la pendiente era inferior a 11° superaba ligeramente el valor de 1 m al emplear el $Q_{95}|\Delta h|$. Sin embargo estos resultados no son comparables con los que se presentan en este estudio por varios motivos: considera densidad de puntos terreno y no densidad de puntos total; emplea un proceso automático para identificar los puntos terreno que introduce errores adicionales en los modelos, los cuales no se encuentran presentes en este estudio (presumiblemente); emplea puntos externos obtenidos mediante técnicas topográficas clásicas para validar los modelos y no los propios datos LiDAR. Todas estas casuísticas vuelven a poner de manifiesto la complejidad de llevar a cabo comparativas con estudios previos.

Previamente se ha mencionado la existencia de una relación estrecha entre la resolución de los modelos y las características del relieve. De forma que el error debido a la resolución puede aumentar dramáticamente si en zonas con orografía compleja se emplearan valores de resolución demasiado altos en relación a la densidad de puntos, ya que la pérdida de información en dichas zonas tiene mayor repercusión (negativa) sobre la precisión de los modelos que si la misma situación tuviese lugar en una zona llana (Fisher y Tate, 2006). En este sentido,

en la Figura 2.9 se observaba como para densidades de 0.01 ptos/m² la resolución más adecuada se fijaba en 10 m, sin embargo analizando los resultados presentados en la Figura 2.13d esto es cierto siempre y cuando la pendiente sea inferior a 10°, mientras que en caso contrario una resolución de 5 m parece la más adecuada. Estos resultados respaldan la idea de Fisher y Tate (2006) sobre que un aumento de la complejidad del relieve puede aumentar la magnitud de los errores debidos a otros factores, como por ejemplo la resolución.

En la Figura 2.13b se apreciaba que a medida que la resolución disminuía, el factor densidad de puntos veía reducida su influencia sobre la precisión general de los modelos. Dicha tendencia también se observa en la Figura 2.13d con independencia de la pendiente del terreno. Aunque este factor no modifica la forma en que la densidad afecta a la precisión de los modelos, sí produce un aumento evidente de la magnitud de los errores a medida que el relieve gana en complejidad. Este efecto se observa en el estudio de Guo et al. (2010), donde para resoluciones altas ($R \leq 1$ m) el RMSE es inferior a 30 cm para cualquier valor de la variabilidad del relieve (medida a partir del CV). Sin embargo, cuando $R \geq 5$ m, el RMSE toma un valor máximo de 3 m en las zonas de mayor variabilidad topográfica. Los resultados del estudio que aquí se presenta coinciden con dichos valores para densidades superiores a 0.25 ptos/m². Por otro lado, los errores de los modelos no son muy elevados aunque la resolución y la densidad de puntos disminuya, siempre y cuando la pendiente del terreno sea baja. En este sentido, Sailer et al. (2014) concluían a partir de su estudio que únicamente se aconsejaba el empleo de bajas densidades de puntos y bajas resoluciones en terrenos cuya pendiente fuera baja-moderada puesto que los errores que se producen en los MDT son relativamente bajos.

Finalmente, en cuanto a la diferencia entre coberturas, éstas se ven acentuadas a medida que la pendiente aumenta y la resolución disminuye, llegando a ser máximas para $R=30$ y $P=High$. Así, cuando la resolución es de 1 m, las diferencias de precisión entre coberturas son inexistentes con independencia de la densidad de puntos y la pendiente. Sin embargo, si la resolución es menor, por ejemplo de 30 m, las diferencias de precisión entre coberturas son mucho más evidentes, de forma que en zonas de alta pendiente la precisión de las


zonas con *edificaciones y vegetación de alta densidad* difieren en casi 80 cm, mientras que la densidad de puntos no parece ejercer influencia en la precisión de las diferentes coberturas. En este sentido, si se comparan estos resultados con los de la Figura 2.13c donde solo se han considerado los modelos con resolución óptima, se observa como el empleo de una resolución espacial adecuada permite reducir el efecto del factor cobertura sobre la precisión de los modelos.

2.3.2.2 Análisis de sensibilidad y predictivo


A continuación, a partir de los datos de la *tabla de resultados* se realiza un análisis de sensibilidad para comprobar y comparar de forma gráfica el efecto de cada uno de los factores en la precisión del MDT. Para ello se empleó la función *plot.design* (paquete *graphics* de R) (R Core Team, 2015). El resultado de este análisis se incluye en la Figura 2.14a y en la Figura 2.14b, en esta última únicamente se consideraron los modelos con resolución óptima. De forma complementaria se realizó el mismo análisis a partir de los resultados obtenidos en el estudio de Barreiro-Fernández et al. (2016) (*enfoque 2* de reducción de densidad de puntos) (Figura 2.14c).

Según el resultado del análisis de sensibilidad teniendo en cuenta todos los factores y empleando el percentil del 95% como medida de la precisión de los modelos (Figura 2.14a), los factores que más influyen en la precisión de los MDT son por este orden: tipo de muestra > coeficiente de variación > resolución \simeq pendiente > densidad de puntos > cobertura > método de reducción. Se tiene por tanto que el **tipo de entorno** es el factor más influyente. Observando la distribución de sus niveles a lo largo de la línea vertical que corresponde a este factor, se diferencian dos grupos. Por un lado, se encuentran las muestras que representan los entornos más complejos, las muestras 11, 23 y 24, las cuales coinciden con las identificadas en el apartado anterior tras el análisis de sus características (Tabla 2.4) y la precisión de los modelos (Figura 2.12). Otra evidencia de la complejidad de estas áreas es el hecho de que muchos de los algoritmos de filtrado desarrollados hasta el momento y que emplearon estos datos para comprobar su efectividad,

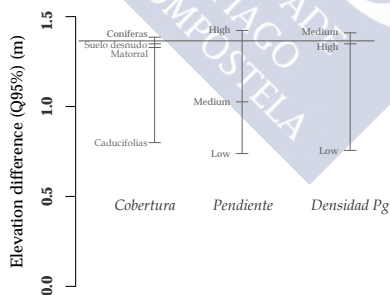
Capítulo 2. Factores que afectan a la precisión de los MDT



(a)



(b)



(c)

Figura 2.14: Análisis de sensibilidad. Efecto de los diferentes factores sobre la precisión de los MDT: Resultados de a) este estudio teniendo en cuenta todos los factores y muestras; b) teniendo en cuenta los modelos con resolución óptima y c) Barreiro-Fernández et al. (2016).

suelen fallar en dichas muestras, dando como resultado las precisiones de filtrado más bajas (Brovelli et al., 2002, Lu et al., 2008, Yan et al., 2012, Mongus y Žalik, 2014). Por otro lado están los entornos más simples (muestras 12, 21, 22, 31, 41, 42), donde la precisión de los modelos es mayor que la obtenida a partir de las muestras anteriores. El tipo de entorno, visto como la combinación de diferentes características (existencia de grandes edificaciones y diferentes tipos de construcciones, vegetación, orografía compleja,...) no se ha considerado previamente en ningún estudio al evaluar los factores que influyen en la precisión de los modelos, lo que impide llevar a cabo un análisis comparativo externo en relación a este punto.

En el caso de considerar únicamente aquellos modelos con resolución óptima, el resultado del análisis de sensibilidad (Figura 2.14b) muestra ciertas diferencias con respecto a la gráfica anterior. Así, la **densidad de puntos** gana protagonismo con respecto a los resultados de la Figura 2.14a y se convierte en el factor que más influye en la precisión de los modelos. De acuerdo a la lógica, los niveles de la densidad se disponen en orden decreciente a medida que el error en los modelos aumenta. La distribución de los niveles de densidad sobre la vertical (Figura 2.14b) muestra como la magnitud del rango de precisiones entre 1.5 ptos/m² y 0.25 ptos/m² es menor ($\simeq 75$ cm) que en el caso de densidades entre 0.1 ptos/m² y 0.01 ptos/m² ($\simeq 2.5$ m). Esta tendencia, al igual que la relación inversa entre la densidad y el error, ya se detectó a partir de la Figura 2.11. Sin considerar la magnitud de los errores, ninguno de los fenómenos identificados coinciden con los resultados obtenidos por Barreiro-Fernández et al. (2016) (Figura 2.14c). En su estudio, la pendiente es el principal factor que afecta a la calidad de los modelos aunque su influencia es muy similar a la de la densidad de puntos terreno. Por otro lado, los niveles de este factor no se disponen en orden creciente a medida que el error de los modelos disminuye, ya que zonas con densidades medias (entre 0.25 y 0.5 ptos/m²) obtienen peores precisiones que aquellas zonas donde la densidad de puntos es superior (>0.5 ptos/m²). En el estudio realizado por Guo et al. (2010), la morfología del terreno también resultó ser el factor con más influencia en la precisión de los modelos.

Los casos anteriores presentan varias diferencias con el estudio que

aquí se presenta. Dichas diferencias pudieron ser las causantes de la no correspondencia entre resultados. Por un lado, las zonas de estudio empleadas en dichas investigaciones son forestales. Aunque no se ha encontrado ningún estudio que analice si el orden de importancia de los diferentes factores que actúan sobre la calidad de los modelos varía dependiendo de la naturaleza de las zonas de estudio, los resultados obtenidos considerando o no la resolución indican que dicho orden sí puede variar dependiendo de los factores que se tengan en cuenta y por ende, podría darse un efecto similar con el tipo de muestra. Otra diferencia sería la estrategia seguida para la obtención de los puntos terreno. Mientras en este estudio el proceso para identificar P_g combinó técnicas automáticas con manuales, en el caso de [Guo et al. \(2010\)](#) ó [Barreiro-Fernández et al. \(2016\)](#) dicho proceso fue totalmente automático. La limitación de los métodos automáticos de filtrado, principalmente para identificar puntos terreno en zonas de pendiente elevada y con vegetación, ha sido reconocida en múltiples estudios ([Sithole y Vosselman, 2004](#), [Hu et al., 2014](#)). Recientemente, [Aryal et al. \(2017\)](#) comparó el resultado del filtrado de dos conjuntos de datos con diferentes densidades en zonas con distinta pendiente. Sus resultados mostraron como el empleo de uno u otro método de filtrado produce errores de diferente magnitud cuando la pendiente es elevada. Si en los estudios mencionados se produjeron errores durante el proceso de filtrado en este tipo de zonas, pudiera ser que estos errores se estén asociando erróneamente al efecto directo de la pendiente y no al empleo de una determinada estrategia de filtrado, llevando a magnificar la influencia que factores como la pendiente tienen sobre la precisión de los modelos.

A pesar de que los factores relacionados con la morfología del terreno, en este caso el **coeficiente de variación** y la **pendiente**, no son los principales elementos que afectan a la precisión de los modelos, tienen un papel destacado en la precisión de los modelos, tanto si se considera la resolución (Figura 2.14a) como si no (Figura 2.14b). De esta forma, los resultados presentados en el apartado anterior (Tabla 2.5, Figura 2.12 o Figura 2.13) son reforzados por el análisis de sensibilidad. No solo se consolida el hecho de que un aumento de la pendiente y el coeficiente de variación de la elevación repercuten negativamente en la precisión de los modelos (efecto representado en la Figura 2.14a al disponerse en orden creciente los niveles de ambos factores a medida que la precisión

disminuye) sino que también se observa como dichos factores tienen un alto impacto en la precisión de los modelos. En consonancia con estos resultados, [Guo et al. \(2010\)](#) afirmó en su estudio que la variabilidad de la topografía, medida a través del coeficiente de variación de la elevación, es el factor que más influye en la precisión de los modelos encontrando una relación aproximadamente lineal entre ellos. Por su parte, [Gould et al. \(2013\)](#) mediante una comparación *post-hoc* también analizaron si la pendiente influye en la precisión de los modelos detectando diferencias significativas entre el nivel de pendiente 1 ($P \leq 14^\circ$) y el nivel 4 ($P \geq 25^\circ$). Si observamos la disposición de los niveles de pendiente en relación a la precisión de los modelos en las Figuras 2.14a y 2.14b se comprueba que existen grandes diferencias entre los niveles extremos de pendiente. La influencia de este factor en la precisión de los modelos también se hizo evidente en el estudio de [Barreiro-Fernández et al. \(2016\)](#) (Figura 2.14c) y en otros estudios como en el de [Spaete et al. \(2011\)](#), [Stereńczak et al. \(2013\)](#) o [Montealegre et al. \(2015b\)](#), donde la pendiente se muestra como la principal fuente de error en la producción de MDT.

Por otro lado, la **resolución de los modelos** se encuentra al mismo nivel de importancia que la pendiente del terreno (Figura 2.14a). Como se esperaba, sus niveles se disponen en orden creciente a medida que la precisión de los MDT disminuye. Como valores extremos se encuentra por un lado el nivel de 30 m y por otro, los niveles 1, 2 y 5 m, los cuales en general arrojan las mejores precisiones (Figura 2.9 y Figura 2.13). Tras comparar los resultados del análisis de sensibilidad teniendo en cuenta la resolución (Figura 2.14a) y sin considerarlo (Figura 2.14b donde se emplearon los valores óptimos de resolución) se considera que la influencia de la resolución va más allá si se analiza de forma conjunta con otros factores. Si la resolución no interactuara con otros factores, se esperaría que el orden de importancia de dichos factores sobre la precisión de los MDT fuese el mismo. Sin embargo, con independencia de si la resolución es o no considerada, no es así y el orden de importancia de los diferentes factores se ve alterado. Las principales diferencias con respecto a los resultados que se incluyen en la Figura 2.14a se dan en relación al tipo de muestra, que pierde importancia; y a la densidad de puntos, que la gana. Los resultados alcanzados por [Guo et al. \(2010\)](#) también muestran la pérdida de importancia del factor densidad sobre la precisión de los MDT cuando se tiene en cuenta la resolución

espacial. Mediante un análisis de regresión multivariante obtuvieron que la correlación lineal entre la precisión y el \log_e de la densidad es significativa para altas resoluciones (0.5 y 1 m) mientras que no lo es para resoluciones menores (5 y 10 m). Sin embargo, la relación lineal positiva entre el CV y el error de los modelos y la magnitud del efecto de este factor, se mantiene con independencia de la resolución.

Por el contrario, los resultados obtenidos por [Immelman y Scheepers \(2011\)](#) indican que la reducción de la densidad sigue el mismo patrón de influencia sobre la precisión de los modelos independientemente del valor de la resolución (relación lineal positiva entre la densidad y la precisión para densidades superiores de 0.1 pto/m², mientras que para densidades inferiores la relación es exponencial positiva). [Sanii \(2008\)](#) obtuvo los mismos resultados aunque en su caso fijó en 0.06 pto/m² la densidad de puntos a partir de la cual la tendencia cambia de lineal a exponencial. Concluyó que para los diferentes niveles de resolución, la precisión de los modelos es muy homogénea mientras que presenta grandes variaciones entre los niveles de densidad, circunstancias que indican que la resolución de los modelos no tiene gran influencia sobre la precisión de los modelos, marcando así la diferencia con los resultados que se obtienen en este estudio.

La resolución se encuentra estrechamente vinculada a las características de los datos de entrada y del relieve del terreno ([Fisher y Tate, 2006](#)). Es en estos vínculos donde posiblemente reside la explicación a las diferencias entre resultados. Como ya se mencionó, el área de estudio del primer caso es una zona minera con poca presencia de edificaciones y vegetación, dando lugar a que la mayoría de los puntos pertenezcan al terreno a la vez que se encuentran distribuidos de forma homogénea por la zona. En el segundo caso, las tres áreas de estudio se corresponden con entornos rurales con diferentes niveles de complejidad en relación al relieve del terreno y donde la densidad de puntos varía entre 0.25, 0.37 y 0.45 pto/m². Los datos LiDAR fueron capturados a mediados de otoño dando lugar a una mayor cantidad de puntos terreno en zonas con vegetación arbolada. En ambos casos, las características citadas son completamente diferentes a las que presentan las áreas de referencia empleadas aquí.

Finalmente, la **cobertura** y el **método de reducción** ejercen una influencia mucho menor sobre la precisión de los modelos que los factores analizados previamente (Figuras 2.14a y 2.14b). En cuanto a la cobertura y en contra de lo esperado, las zonas con edificaciones (*Ed*), presentan las mejores precisiones. Tal y como se indicó en el apartado anterior, esta excepción puede deberse a que los errores se calculan a partir de la diferencia entre las celdas de los MDT_O y las celdas de los MDT_{M-D-R} . Las huellas de los edificios, arrojarán errores próximos a 0, ocasionando una sobreestimación de la precisión de los modelos en dichas zonas. Se podría pensar que esta situación no se daría si la penetrabilidad nula se debiera a la presencia mayoritaria de vegetación arbolada densa. Sin embargo, los resultados obtenidos por Barreiro-Fernández et al. (2016) (Figura 2.14c) en relación al factor cobertura, indican que esta sentencia puede no ser cierta, pues en su estudio las zonas con vegetación más compacta son las que presentan las mejores precisiones. Adicionalmente, los niveles que hacen referencia a la vegetación, se disponen de forma decreciente en relación a su densidad a medida que el error aumenta, sin embargo las diferencias en términos de precisión entre estos niveles son muy pequeñas.

En cuanto al método de reducción, se trata del factor que menos afecta a la precisión de los modelos. Se observa como el método *ThinData* produce precisiones ligeramente inferiores a los métodos *PpC*, *SRpC* y *RpA*. Este resultado respalda los obtenidos mediante el análisis de la precisión de los modelos realizada en el apartado anterior (Figura 2.10). Yilmaz y Uysal (2016), bajo el enfoque de la generalización, obtuvo que si bien la influencia de los métodos de reducción de la densidad es el factor menos significativo de los analizados, la magnitud de las diferencias de precisión al emplear uno u otro método podían ser superiores a 1 m. En este caso y bajo un enfoque distinto (mejora de la relación coste-beneficio), dichas diferencias no superan los 30 cm. Este valor puede matizarse teniendo en cuenta el análisis de la precisión de los modelos realizada en el apartado anterior, donde se apreció cierto efecto combinado entre la densidad y el método de reducción, de forma que cuanto más se reducía la densidad de puntos mayores eran las discrepancias entre métodos en relación a la precisión de los modelos (Figura 2.10).

Complementariamente, para reforzar el análisis anterior se llevó a cabo un análisis CART. Los árboles predictivos resultado de este análisis se incluyen en la Figura 2.15. Dichos árboles se crearon considerando los factores coeficiente de variación, pendiente, cobertura del suelo, resolución, densidad y método de reducción (Figura 2.15a). Adicionalmente, se consideraron también las muestras de referencia como factor (Figura 2.15b). Asimismo también se obtuvieron los árboles predictivos teniendo en cuenta únicamente los modelos con resolución óptima (Figuras 2.15c y 2.15d, en este último caso considerando el tipo de muestra).

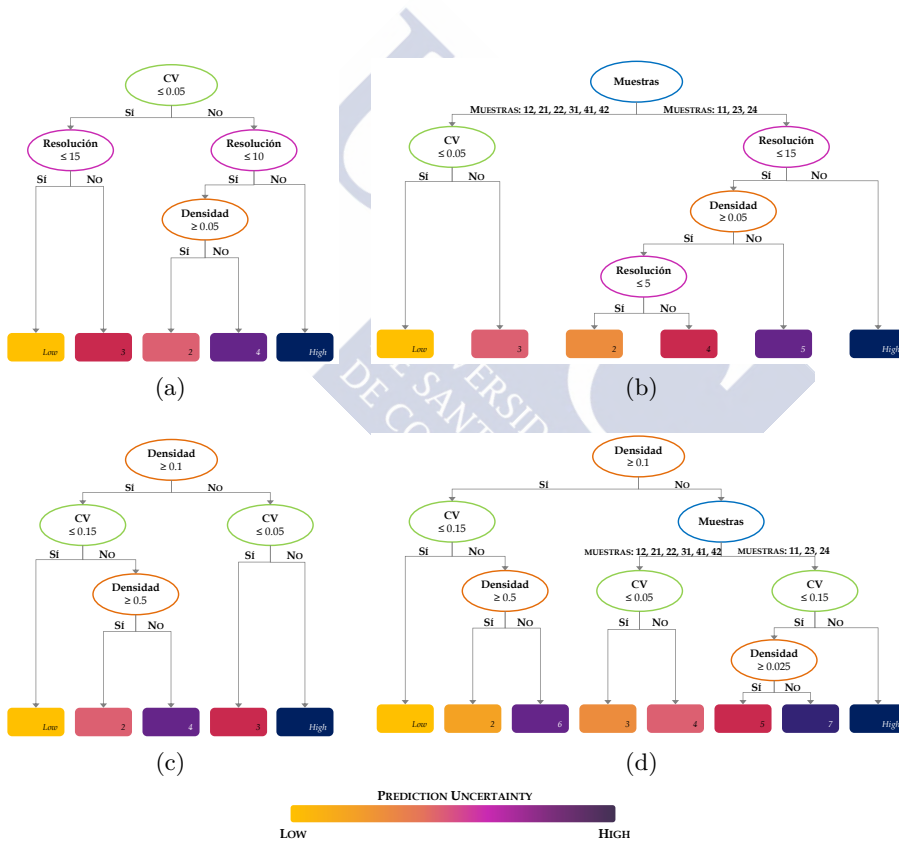


Figura 2.15: Árboles predictivos obtenidos a partir del análisis CART de los errores absolutos de elevación: a) sin considerar las muestras de referencia; b) teniéndolas en cuenta; a partir de los modelos con resolución óptima en función de la densidad de puntos c) sin considerar las muestras de referencia y d) teniéndolas en cuenta.

El resultado de un análisis CART es un conjunto de reglas que permiten clasificar las muestras en una serie de categorías de incertidumbre (*prediction uncertainty*). En este estudio, teniendo en cuenta el factor resolución, el análisis CART indica que las variables predictoras que mayor influencia tienen en la precisión de los modelos son el coeficiente de variación, la resolución y la densidad de puntos (Figura 2.15a), y adicionalmente el tipo de muestra si ésta se considera como factor (Figura 2.15b). El hecho de que el factor pendiente no aparezca en dichos árboles probablemente se deba a la correlación con el CV (relación polinómica de segundo orden donde $R^2=0.91$). Analizando el árbol de la Figura 2.15a, se observan dos tipos de combinaciones entre factores: 1) CV y resolución y 2) resolución y densidad de puntos. Por un lado se tiene que si la variabilidad del relieve es baja ($CV \leq 0.05$) y la resolución no supera los 15 m, la propensión a la ocurrencia de errores de elevación en los modelos es mínima, con independencia de la densidad de puntos y de cualquier otro factor analizado. Se obtiene una incertidumbre similar a la anterior empleando una resolución igual o mayor a 10 m ($R \leq 10$ m) y una densidad de puntos superior a 0.05 pts/m², con independencia de la morfología del terreno. Estos resultados son coherentes con la teoría, pues zonas donde el relieve es simple requieren menos cantidad de puntos y por tanto menor nivel de resolución para caracterizar el relieve que aquellas zonas más complejas, las cuales demandan un mayor nivel de detalle que se logra con un mayor número de puntos y una mayor resolución. En estas zonas, la resolución de los modelos es un factor crítico, pues con independencia del resto de factores, los modelos cuya resolución está por encima de los 10 m presentan los valores más elevados de incertidumbre.

Por el contrario, si se tienen en cuenta aquellos modelos con resolución óptima, se obtiene un árbol predictivo que presenta diferencias significativas con respecto al anterior (Figura 2.15c). En línea con los resultados previos, en general se observa que cuanto mayor es la densidad y menor la variabilidad del relieve menor la ocurrencia de errores. De igual forma, cuanto menor es la densidad ($D < 0.1$ pts/m², valor que ya se mostraba como punto de inflexión en la Figura 2.11) y mayor es el CV ($CV > 0.05$), la ocurrencia de errores de elevación en los modelos aumenta. Casi el mismo nivel de incertidumbre se obtiene cuando la variabilidad es alta ($CV > 0.15$) y la densidad de puntos ligeramente

superior a la del caso anterior ($0.5 \text{ ptos/m}^2 > D > 0.1 \text{ ptos/m}^2$). Estos resultados son similares a los obtenidos por [Bater y Coops \(2009\)](#) y [Montealegre et al. \(2015b\)](#). De igual modo, se observa que si la densidad es superior a 0.5 ptos/m^2 , la variabilidad del relieve pierde peso sobre la precisión de los modelos. Esta evidencia no se aprecia en los resultados obtenidos por [Montealegre et al. \(2015b\)](#), pues en su caso la pendiente se muestra como el factor más determinante, de tal forma que las zonas con pendiente inferior a 15° , con independencia del resto de factores, son las que presentan el menor nivel de incertidumbre. Analizando estos resultados conjuntamente con las capas de información disponibles en su estudio (pendiente, cobertura, densidad y penetrabilidad), se observa que dichas zonas coinciden mayoritariamente con áreas quemadas, que presentan un elevado porcentaje de penetrabilidad ($P_n > 75\%$) o con cursos de agua, lo que explicaría porqué el resto de factores no son significativos en zonas con pendiente inferior a 15° . Así, las particularidades de la zona de estudio y los datos empleados pueden ser la explicación a las diferencias entre sus resultados y los que aquí se muestran.

En la misma línea, [Godone y Garnero \(2013\)](#) también realizaron un análisis CART donde la densidad no resultó ser un factor relevante. Este resultado seguramente se deba a que por un lado la densidad de puntos, aunque no homogénea (varía entre los 19 ptos/m^2 y los 35 ptos/m^2), era muy elevada; y por otro lado que los modelos fueron transformados a formato ráster con resoluciones de 1, 2 y 5 m. En relación al primer punto, a partir del estudio de [Anderson et al. \(2006\)](#) se podía extraer la idea de que por encima de cierta densidad de puntos la precisión de los MDT no se ve comprometida, mientras que en referencia a la resolución, los valores fijados son muy superiores a los recomendados para la densidad de puntos disponible, pues según [Salleh et al. \(2015\)](#), la resolución debería fijarse como $\sqrt{1/D}$. Estas dos observaciones justificarían que la densidad de puntos no aparezca como determinante en la calidad de los modelos en el estudio realizado por [Godone y Garnero \(2013\)](#). A esta misma conclusión se llega comparando los árboles de la [Figura 2.15a](#) y [Figura 2.15c](#), donde al tener en cuenta la resolución como factor, la densidad de puntos queda relegada a un papel secundario.

Adicionalmente, en el estudio de [Montealegre et al. \(2015b\)](#), cuando

la pendiente es elevada ($P > 15^\circ$) y la densidad de puntos superior a 1.07 ptos/m^2 , la cobertura del suelo se muestra como un factor significativo. Esta diferencia con respecto a los resultados que se obtiene aquí puede ser debida a la diferente naturaleza de las zonas de estudio, en nuestro caso urbana mientras que [Montealegre et al. \(2015b\)](#) realizó su investigación en una zona forestal, donde la existencia de vegetación con diferente estructura puede afectar de forma más clara a la calidad de los modelos. En relación al tipo de entorno, pero más vinculado a la complejidad del relieve que a la cobertura, en la [Figura 2.15d](#) se observa como para densidades inferiores a 0.1 ptos/m^2 , el tipo de muestra influye en la calidad de los modelos, de forma que las 9 muestras de estudio se dividen en 2 grupos. Por un lado, las muestras 12, 21, 22, 31, 41 y 42 donde la pendiente, representada por el Q95, varía entre los 6.9° y los 26.8° ; y por otro lado, las muestras 11, 23 y 24, donde la pendiente es de 52.5° , 41.9° y 39.3° , respectivamente. Esta misma agrupación también se observó en las [Figuras 2.14a](#) y [2.14b](#). En el caso del primer grupo de muestras la incertidumbre es dos niveles inferior (3 sobre 8) cuando el CV es inferior a 0.05 al de las muestras del segundo grupo (incertidumbre de 5 sobre 8) para un valor de variabilidad menos restrictivo ($CV \leq 0.15$). Nuevamente se vuelve a poner de manifiesto como la densidad pierde importancia frente a la resolución de los modelos si comparamos estos resultados con los incluidos en la [Figura 2.14b](#), donde el tipo de muestra también gana importancia.

Si bien la resolución no aparece como el principal factor de influencia en el análisis de sensibilidad ([Figura 2.14a](#)), la comparación de resultados teniendo este factor en cuenta y no considerándolo tanto en el propio análisis de sensibilidad como en el predictivo, indica que su efecto no es únicamente sobre la precisión de los modelos sino que su combinación con otros factores hace variar el grado de influencia que dichos factores tienen sobre la precisión de los modelos, fundamentalmente con el CV y la densidad. Finalmente, destacar que en ninguno de los árboles de predicción, el método de reducción aparece como relevante a la hora de predecir el error de los modelos, reforzando nuevamente los resultados del análisis de sensibilidad ([Figuras 2.14a](#) y [2.14b](#)).

2.4 Conclusiones

La densidad de puntos se considera uno de los factores con mayor influencia en la generación de MDT tanto desde el punto de vista de los costes como de la calidad, ya que cuanto mayor es la densidad mayores son los costes económicos de la toma de datos, mayor el tiempo de procesado pero mayor también el nivel de detalle con el que se puede representar el relieve del terreno. Por ello, en el marco de la generación de MDT, el análisis de este factor resulta de gran importancia de cara a conciliar la efectividad con la eficiencia en dicho proceso. Sin embargo realizar estos análisis requiere disponer de nubes de puntos con diferentes densidades. Este reto ha sido abordado reduciendo artificialmente la densidad original de nubes de puntos LiDAR a partir de diferentes métodos. En este punto, ninguno de los estudios consultados se ha cuestionado si el empleo de estos métodos está introduciendo errores en los modelos. En este trabajo se abordó esta cuestión presentando un nuevo método de reducción, comparando su funcionamiento con el de otros métodos de reducción existentes (evaluación a nivel método) y analizando si existen diferencias de precisión entre los MDT derivados de las nubes de puntos reducidas (evaluación a nivel modelo). Las principales conclusiones que se derivan de este estudio son:

En cuanto a la evaluación a nivel método ...

Según los resultados de los 4 indicadores definidos para evaluar el funcionamiento interno de los métodos de reducción, se tiene que el método *PpC* es el que presenta el mayor grado de cumplimiento con dichos indicadores, seguido del método *RpA*. Por otro lado, los métodos *ThinData* y *SRpC* son los que mostraron más dificultades para cumplir con dichos indicadores, fundamentalmente los relacionados con la *distribución de los puntos (Indicador 1)* y la *conservación del ratio $P_g:P_{ng}$ (Indicador 3)*. Dichos errores tienen su origen en uno de los objetivos perseguido por estos métodos, obtener nubes de puntos distribuidos homogéneamente. Es evidente que dicho objetivo va contra el cumplimiento del *Indicador 1*. En relación al *Indicador 3*, la combinación de dicha estrategia con la presencia de zonas con solape entre pasadas que presentan un ratio $P_g:P_{ng}$ que difiere del $P_{gO}:P_{ngO}$

tomado como referencia, han provocado fallos en el cumplimiento de este indicador. De modo similar, aunque con mayor éxito, se encuentra el *Indicador 4 (acuerdo entre la densidad fijada y la calculada)*. Este tipo de métodos también presentan limitaciones para alcanzar la densidad de puntos deseada en el caso de nubes de puntos cuya distribución es heterogénea. En este caso, los errores también se relacionan con la distribución homogénea de los puntos de las nubes reducidas pero también con el grado de acierto en el establecimiento del tamaño de ventana (parámetro propio de algunos métodos de reducción) y la presencia de grandes áreas sin datos.

El empleo de métodos de reducción que busquen la obtención de nubes de puntos con distribución homogénea, como por ejemplo los métodos *SRpC* y *ThinData*, puede influir negativamente en la precisión de los MDT obtenidos a partir de nubes de puntos reducidas si los datos LiDAR presentan solape entre pasadas tanto más cuanto más compleja sea la orografía de la zona de estudio (pendiente y variabilidad del terreno elevada). Si bien el *Indicador 3* es el que ha puesto de manifiesto esta limitación, su origen se encuentra en el no cumplimiento del *Indicador 1*, es decir, la no conservación por parte de las nubes de puntos reducidas de la distribución de puntos original. De ahí que un método de reducción que no conserva dicha característica de la nube de puntos original puede estar influyendo en la precisión no solo de los MDT generados con nubes de puntos con densidades reducidas *artificialmente* sino que también puede producir errores en aquellos estudios donde se evalúa la influencia que ciertos factores tienen sobre la precisión de determinados productos, como por ejemplo el cálculo de variables forestales como la altura o volumen de biomasa. De esta forma, pudiera suceder que errores que se achacan a la reducción de la densidad no se encuentren tan vinculados con la densidad en sí como con el método de reducción empleado.

En cuanto a la evaluación a nivel modelo ...

¿Cuánto puede ser reducida la densidad de puntos sin sacrificar la **calidad de los modelos**? Depende ... Partiendo de una densidad original de $\simeq 1.8$ pts/m², reducir la densidad de puntos hasta valores próximos a 0.1 pto/m² (5% de los puntos originales) como máximo supondrá un aumento de $\simeq 20$ cm (tomando como referencia el estadístico

$Q_{68.3|\Delta h}$) en el error de los modelos con independencia del método de reducción empleado, siempre y cuando se empleen los valores de resolución adecuados. Dicho aumento del error también se mantiene para todos los niveles de cobertura y en zonas donde la pendiente es inferior a 10° y el coeficiente de variación no superior a 0.15. En regiones donde la pendiente o el CV supera estos umbrales se mantiene dicho aumento del error si la densidad de puntos no se reduce más allá de los 0.5 pto/m^2 (25% de los puntos originales). A partir del valor de densidad que representa el 5% de la densidad original, la relación directa entre la densidad y la precisión pasa de ser lineal positiva ($R^2 \simeq 1$) a polinómica de segundo grado ($R^2 \in [0.82, 0.98]$). Asimismo, el efecto del aumento de la pendiente es más significativo y el empleo de uno u otro método de reducción afecta a la precisión de los modelos. En general, el hecho de emplear uno u otro método de reducción es tanto más determinante cuanto más se reduzca la densidad de puntos. Las diferencias de precisión entre modelos generados a partir de nubes de puntos reducidas empleando diferentes métodos pueden llegar hasta los 30 cm.

Al variar la densidad de puntos en los modelos de mayor resolución, los errores varían más rápidamente y las diferencias de precisión entre modelos son mayores que si éstos tienen menor resolución. Esta tendencia se mantiene con independencia de la cobertura del suelo. Con la disminución de la resolución los modelos aumentan sus errores con independencia de la cobertura. Sin embargo, teniendo en cuenta la diferencia de precisión de los modelos al variar la resolución, una de las coberturas que se ve más afectada por la variación de la resolución es la clase *suelo desnudo*. Este efecto probablemente se deba a que dichas zonas presentan la mayor densidad de puntos terreno, y por tanto donde el terreno se encuentra mejor definido. Pero si empleamos bajos valores de resolución, la pérdida de información y por tanto de detalle es muy evidente, provocando que la reducción de la precisión en estas zonas sea de las mayores en comparación con la que se da en el resto de coberturas. Esta afirmación es cierta en aquellas zonas donde la pendiente es inferior a 10° , ya que en el caso de pendientes mayores, el par orografía compleja - vegetación ejercen mayor influencia sobre la precisión de los modelos que el proceso de generalización en zonas sin vegetación.

En teoría, las zonas edificadas tienden a presentar errores groseros. En este caso no es así y las zonas edificadas presentan precisiones similares, y en muchos casos mejores, que las zonas de suelo desnudo, en donde se esperaría las mejores precisiones. Generalmente, los errores en estas zonas se atribuyen a fallos durante el proceso de identificación de puntos terreno (errores de comisión debido a la selección errónea de P_{ng} de los muros de las construcciones como P_g) y durante el proceso de interpolación (errores debidos a que cada interpolador se comporta de manera diferente a la hora de estimar valores de elevación en las huellas de las edificaciones a partir de puntos distantes). Sin embargo, en este estudio se han empleado datos clasificados mediante la combinación de técnicas automáticas y manuales de filtrado, lo que ha permitido llevar a cabo el análisis de la influencia de diferentes factores sobre la calidad de los modelos prescindiendo de la influencia del método de filtrado. Descartada esta causa, se considera que la precisión de los modelos en estas zonas se sobrestima debido a la estrategia de validación adoptada.

Adicionalmente, se ha relacionado la resolución de los modelos y la densidad de puntos con la precisión de los MDT. A partir de esta relación se han obtenido valores de resolución óptimos en función de la densidad, mostrando que no siempre mayor resolución implica menor error. Sin embargo, se ha encontrado que estos valores pueden variar dependiendo de la morfología del terreno. De manera que una mayor complejidad del terreno demanda un nivel de resolución mayor que en zonas donde la morfología es más simple. Adicionalmente, se ha observado que la incorrecta selección de la resolución de los modelos puede suponer un incremento de los errores. Además, el empleo de una adecuada resolución espacial permite reducir el efecto del factor cobertura sobre la precisión de los modelos. Esta información se considera de gran importancia para los usuarios pues podría usarse como guía para la creación de MDT.

A pesar de la gran cantidad de estudios que han evaluado como diferentes factores influyen en la precisión de los MDT, ha sido complicado comparar los resultados obtenidos en este estudio con los de investigaciones previas. La comparación con resultados previos y la discusión en relación a la influencia de diferentes factores sobre la precisión de los modelos han sido tanto más ricas cuantos menos factores se analizaban a la vez. Las mayores dificultades se encontraron en

relación a los factores resolución y cobertura, y adicionalmente al método de reducción, ya que para este último factor no se encontró ningún estudio que lo analizara. En el caso de la resolución, aunque varios estudios la han considerado, en la mayoría de los casos su análisis se limita a considerar 2 ó 3 niveles cuyos valores son muy próximos entre sí. En relación a la cobertura, la gran mayoría de los estudios que la tienen en cuenta es con fines forestales muy concretos y son muy escasos los estudios que consideran más de una de las 3 principales características de la vegetación (especie, estructura y densidad) y diferentes niveles. Esta limitación podría tomarse como indicador de que todavía persiste la necesidad de llevar a cabo estudios en este campo que analicen la influencia conjunta de varios factores sobre la precisión de los modelos y que al mismo tiempo se considere para cada uno de ellos un mayor número de niveles con valores dispares.

Por otro lado, el **análisis de sensibilidad** muestra que los factores que más afectan a la calidad de los modelos son el coeficiente de variación de la elevación, la resolución y la pendiente, así como el tipo de entorno. El método de reducción y la cobertura del suelo se muestran como factores de influencia secundaria sobre la precisión de los modelos. Una de las principales conclusiones que se pueden extraer de este análisis es la estrecha relación que existe entre la resolución y la densidad de puntos. Al tener en cuenta la resolución en el análisis de sensibilidad, la precisión de los modelos presenta grandes variaciones entre los diferentes niveles de la resolución, principalmente cuanto menor es ésta; mientras que dichas variaciones son más homogéneas y de menor magnitud entre los niveles de densidad. Dicha circunstancia estaría indicando que la resolución presenta una mayor influencia sobre la precisión de los modelos que la densidad de puntos. Por otro lado, si la resolución no se tiene en cuenta, la densidad de puntos se empodera como factor de influencia sobre la precisión de los modelos, siendo el factor que más afecta a la precisión de los MDT junto con la variabilidad del relieve (representada por el CV). En base a los resultados descritos, si bien la resolución no aparece como el principal factor de influencia en dicho análisis, la comparación de resultados teniendo este factor en cuenta y no considerándolo tanto en el propio análisis de sensibilidad como en el predictivo, indica que su efecto no es únicamente sobre la precisión de los modelos sino que su combinación con otros factores hace variar el grado de influencia que

dichos factores tienen sobre la precisión de los modelos.

Adicionalmente, el **análisis CART** permitió completar los resultados del análisis de sensibilidad al mostrar características más concretas en la relación de los diferentes factores y la precisión de los modelos. En primer lugar, se consolidó como punto de inflexión en la precisión de los modelos el valor de densidad de 0.1 pto/m². En segundo lugar, con independencia del tipo de entorno, las zonas donde se obtienen las mejores precisiones son aquellas donde el coeficiente de variación es inferior a 0.05 y la resolución inferior a 10 m siempre que la densidad se encuentre por encima de 0.05 pto/m². Si se tiene en cuenta el tipo de entorno, las peores precisiones se dan en los modelos de las muestras que representan los entornos más complejos (muestras 11, 23 y 24), creados con resoluciones inferiores a 15 m.

Los análisis predictivos pueden ser de gran utilidad para identificar las zonas que presentan los mayores desafíos en relación a la representación del relieve, proporcionándole una referencia al productor sobre donde debe centrar sus esfuerzos. Sin embargo, su utilidad puede ir más allá de un simple análisis y de proporcionar una orientación para el procesado de datos. Por un lado podría emplearse para explicar o subsanar anomalías en los resultados donde los MDT son un *input* clave, como por ejemplo en la estimación de algunas variables forestales; y por otro lado dicha información puede tomarse como referencia durante la captura de datos para aumentar la eficiencia y efectividad de esta tarea, por ejemplo aumentando la densidad de puntos en zonas donde la pendiente es elevada.

Finalmente, ha previsto programar la función DecimaTe en base a los estándares de R y se pretende su publicación como parte de un paquete de procesado de datos LiDAR.

Agradecimientos

Este trabajo fue realizado en el Grupo de Investigación Laboratorio del Territorio (GI.-1934-Te-Bio) de la Universidad de Santiago de Compostela (Galicia, España).

A mis compañer@s en el [LaboraTe](#), gracias por vuestro esfuerzo, sin vosotr@s no hubiera sido posible. De manera muy especial le agradezco a Laura Barreiro y a Eduardo M. González su valiosa e irremplazable ayuda.







CAPÍTULO 3

Las coberturas del suelo

En el campo de la identificación de coberturas/ usos del suelo, los métodos tradicionales de clasificación automática (basados en píxeles u orientados a objetos) que operan sobre datos procedentes de sensores remotos se han consolidado como la alternativa a los métodos basados en la observación directa. A lo largo de la última década, el nivel de detalle que exigen los demandantes de esta información junto con los avances tecnológicos en cuanto a técnicas de captura y herramientas de procesado, han propiciado el desarrollo de métodos de clasificación híbridos donde los métodos tradicionales son fusionados. La gran mayoría de estos clasificadores se han probado en zonas urbanas empleando para ello imágenes de resolución media. En casos puntuales, la tecnología LiDAR se empleó como fuente de datos auxiliar. En base a estos antecedentes, en este estudio se fijan los siguientes objetivos: 1) explorar el potencial de los datos LiDAR como única fuente de información para identificar 8 clases de cobertura del suelo en un entorno rural; 2) comprobar si la integración de diferentes estrategias de clasificación en un árbol de decisión elaborado en base a las variables calculadas únicamente a partir de datos LiDAR y otras características de los objetos mejora la precisión de una clasificación automática basada en píxeles empleando como método de asignación el algoritmo *random forest*; 3) analizar en qué medida la reducción de la densidad de puntos LiDAR afecta a la precisión de la clasificación empleando el método híbrido. Para dar respuesta al primer objetivo se creó una batería de 72 variables LiDAR y se evaluó su importancia relativa para la identificación de las 8 coberturas del suelo características de un entorno rural. Para ello se empleó una de las funcionalidades del algoritmo *random forest*. Esta información se usó para diseñar un árbol de decisión en el que además de incluir reglas de decisión para la asignación de clases

también se incluyeron procesos de segmentación a escala local. Este método se denominó *HyClass*. Para comprobar la influencia de la densidad de puntos, se empleó el método *PpC* para reducir artificialmente la densidad original de puntos, de forma que *HyClass* no se probó únicamente con las capas de información obtenidas a partir de la nube de puntos original sino que también se ejecutó sobre las nubes de puntos con densidad reducida. Estos experimentos permitieron dar respuesta a los objetivos de este estudio. Los resultados obtenidos muestran como *HyClass* logra una precisión general de aproximadamente el 97% empleando únicamente 7 variables LiDAR (6 de ellas se encontraban entre las 10 más relevantes según el análisis de importancia de variables realizado a partir de *random forest*). Estos resultados superan en 8 puntos porcentuales a los obtenidos con *random forest* a nivel píxel. Tal y como se esperaba, la identificación de la cobertura *pistas de tierra* presentó muchas dificultades, que se vieron agravadas por la reducción de la densidad de puntos (el error de omisión pasó del 13% - 8 pto/m² - al 49% - 1 pto/m²).

Palabras clave: Clasificación híbrida, reducción de la densidad, árbol de decisión, importancia de las variables, *random forest*

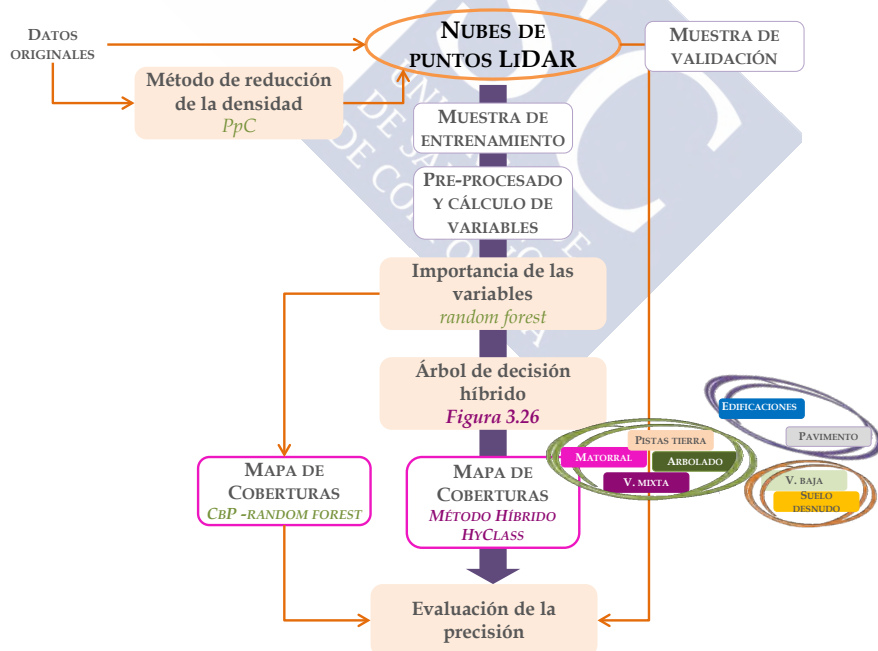


Figura 3.1: Resumen gráfico.

3.1 Introducción

El medio rural es un patrimonio esencial para el desarrollo sostenible de una región como la gallega donde el 65% de su superficie es forestal y alberga e integra a 313 municipios con más de 30.000 núcleos de población dispersos por su fisiografía. Durante los últimos cuarenta años, las áreas más dinámicas de Galicia, el denominado Eje Urbano Atlántico, ha potenciado hasta niveles extremos un hábitat fragmentado, dando la espalda al modelo de pueblos con estructura más compacta. Esta dinámica ha convertido el medio rural de las provincias interiores de la comunidad gallega en una dispersa masa de núcleos rodeados de superficies antaño agrarias, ahora arboladas, propiciando un aumento de los problemas ambientales y los costes sociales. Este proceso ha desembocado en un progresivo desorden (incumplimiento de planes de ordenación), infrautilización de recursos (abandono de tierras) y riesgo territorial (incendios en la interfaz urbano-forestal). Tomando estos antecedentes como base, existe por tanto la necesidad imperante de disponer de información detallada sobre las coberturas del suelo. Su identificación es indispensable para analizar tanto el funcionamiento de los instrumentos de gestión territorial como las dinámicas a las que se encuentra sometido el territorio, a fin de proponer medidas correctoras o nuevos mecanismos de gestión.

Uno de los principales métodos para la actualización y obtención de información referente a las coberturas del suelo ha sido, y en algunos casos sigue siendo, mediante observación e interpretación manual. Sin embargo, esta técnica requiere intérpretes capacitados y se encuentra sujeta a sus habilidades y conocimientos, consume mucho tiempo y es muy costosa (Pacifci et al., 2007). Debido a estas limitaciones, muchas han sido las iniciativas encaminadas al desarrollo de métodos de clasificación automáticos. Si bien se considera un proceso complejo, el amplio abanico de aplicaciones de los productos derivados de estas técnicas (p. ej. mapas de coberturas del suelo, actualización de bases de datos geográficas, riesgos naturales o detección de cambios) justifican los esfuerzos y medios que se le han destinado (Matinfar et al., 2007). A pesar de todas las iniciativas llevadas a cabo, el avance imparabile

de la tecnología y la disponibilidad de datos pone ante nosotros nuevos y renovados desafíos como son la integración de datos procedentes de diferentes sensores, la disponibilidad de datos de referencia, acuerdos más justos entre la efectividad y la eficiencia, los métodos de procesado, los algoritmos de clasificación,... (Weng, 2011). La complejidad de estos procesos se debe a múltiples factores. Uno de ellos, la cantidad de decisiones que es necesario tomar: ¿Qué coberturas están presentes en el área de estudio y cuáles se pueden identificar?; ¿Qué tipo de datos se emplearán y qué características mínimas deben tener?; ¿Qué variables es posible calcular y cómo se calculan?; ¿Cuáles son las más adecuadas para identificar las coberturas objetivo?; en relación a la unidad de clasificación; ¿Píxel? ¿Objetos? ¿Ambos?; ¿Qué método de asignación?; ¿Cómo cuantificar la precisión de los resultados?...

Por todo lo anterior, la identificación de coberturas del suelo a partir de datos procedentes de sensores remotos ha centrado la atención de la comunidad científica desde hace más de dos décadas (Lu y Weng, 2007, Weng, 2010, Blaschke et al., 2014, Yan et al., 2015). La aparición de sensores capaces de incrementar la velocidad, eficiencia en los costes y precisión en la obtención de información, ha permitido el desarrollo de productos cartográficos con resoluciones espaciales y precisiones inalcanzables hasta el momento (McRoberts y Tomppo, 2007). Entre ellas, se encuentra la tecnología *laser scanning*, con una antigüedad de más de tres décadas, siendo posible aprovechar todo su potencial gracias al desarrollo de sistemas altamente precisos como el GPS (Charaniya et al., 2004). En esta línea, el libre acceso a estos datos es otro de los pilares sobre los que se apoya el avance en este campo. En España, por medio del Plan Nacional de Ortofotografía Aérea, se dispone de datos LiDAR de baja densidad ($0,5 \text{ retornos} \cdot \text{m}^{-2}$ - $1 \text{ retornos} \cdot \text{m}^{-2}$) de gran parte del territorio nacional. Su actualización está prevista cada 6 años, lo que hará posible la monitorización de las características del territorio a escala nacional.

En la última década, la tecnología LiDAR se ha consolidado como método de referencia y preferente para la captura de datos topográficos (Mongus y Žalik, 2012, Maguya et al., 2013). A partir de las nubes de puntos LiDAR es posible extraer información de diversa naturaleza. En este sentido, no existe ninguna duda acerca de cuál es la información

más valiosa proporcionada por esta tecnología: la elevación, o previo procesado, la altura de los objetos situados sobre el terreno. Otros dos atributos característicos de estos datos son la intensidad y el número de retorno. Dichos atributos, representados como MDT, nMDS, MDC o MDS en relación a los primeros, o como imagen de intensidad o diferencia de elevación entre retornos en referencia a los últimos, han sido empleados en la mayoría de estudios de identificación automática de coberturas y usos del suelo desarrollados hasta el momento (Brennan y Webster, 2006, Buján et al., 2013b, Teo y Huang, 2016, Sturari et al., 2017). Sin embargo, otros estudios no se limitaron a estas características y definieron y calcularon nuevas e interesantes variables a partir de estos datos. Por ejemplo, los coeficientes de asimetría y curtosis para representar la estructura de la vegetación (Antonarakis et al., 2008); la *Density Weighted Canopy Reflection Sum* propuesta por García et al. (2010) para medir la densidad de la vegetación; ratios basados en la cantidad de retornos para identificar terreno, zonas con vegetación o edificaciones (Höfle et al., 2012, Guo et al., 2015); medidas para representar la rugosidad de la superficie como la pendiente o el coeficiente de variación (Buján et al., 2012, Guo et al., 2010) o las basadas en el nivel de *planaridad* de la superficie, como la desviación del vector normal al plano con la vertical (Kim y Sohn, 2013).

El avance en la definición de muchas de las variables anteriores se debe de manera incuestionable al ingenio de grandes investigador@s. Sin embargo, es igual de incuestionable el papel fundamental que han jugado en dicho proceso Internet, los sistemas de captura de datos y el desarrollo y disponibilidad de herramientas informáticas (Bolón-Canedo et al., 2015). Disponer de tal cantidad de información supone un desafío computacional que en el campo de la clasificación automática de datos de sensores remotos se abordó reduciendo la dimensión de las variables por dos vías: la extracción de variables y la selección de variables (Tang et al., 2014). En relación al primer caso, generalmente se realiza una transformación de los datos originales donde el resultado son nuevas variables obtenidas combinando las variables originales (Cai et al., 2018). Ejemplos de este tipo de métodos son el *Análisis de Componentes Principales*, *Análisis Discriminante Lineal* o el *Análisis de Correlación Canónica* (Varghese et al., 2012). Una de las dificultades que presentan este tipo de métodos es que las nuevas variables no tienen un significado

físico en el mundo real y por tanto, su análisis e interpretación resulta una tarea compleja (Tang et al., 2014).

Los métodos de selección de variables se basan en identificar un pequeño grupo de variables que minimizan la redundancia (*variable-variable*) y maximizan la relevancia (*variable-cobertura*) a fin de discriminar las diferentes clases de interés. De esta forma, una variable relevante es aquella que aporta información genuina y no repetida para la identificación de las clases objetivo; mientras que una variable irrelevante no se encuentra directamente vinculada con las clases a discriminar pero afecta negativamente al proceso de aprendizaje, y una variable redundante no agrega información nueva para la identificación de las clases de interés. A diferencia de lo que sucedía con los métodos anteriores, en este caso se mantiene el significado físico de las variables originales permitiendo una mejor interpretación de los resultados (Jović et al., 2015). Atendiendo a la relación de estos métodos con los métodos de aprendizaje, los primeros pueden clasificarse en métodos de *filtrado*, *wrappers* o *embedded* (Cai et al., 2018).

Los métodos del primer grupo (*filtrado*) consideran la relación entre las variables y las clases de cobertura sin emplear ningún algoritmo de clasificación. El criterio para medir la importancia de las variables es característico de cada método y resulta un *parámetro* crítico en este tipo de métodos de selección. A diferencia de los métodos de *filtrado*, en los métodos *wrappers* el proceso de aprendizaje se encuentra incluido en la selección de variables de manera que ambas tareas se ejecutan simultáneamente. Esta forma de operar proporciona precisiones más altas en la clasificación sin embargo es menos eficiente en términos de tiempo de computación (Jović et al., 2015, Huang et al., 2017, Cai et al., 2018). Finalmente, los métodos *embedded* combinan las ventajas de los métodos anteriores, de forma que son más eficientes computacionalmente que los métodos *wrappers* al mismo tiempo que la selección de variables forma parte del proceso de clasificación (Tang et al., 2014, Huang et al., 2017). En este grupo de métodos se encuentran varios tipos de algoritmos de árboles de decisión, como CART, C 4.5 o *random forest* (Breiman, 1984, Quinlan, 1993, Breiman, 2001). En la última década, muchos de los estudios que se evaluaron la importancia de las variables en los procesos de clasificación, emplearon el algoritmo

random forest (Chan y Paelinckx, 2008, Rodriguez-Galiano et al., 2012, Guan et al., 2013, Matikainen et al., 2017). Este hecho posiblemente se deba a la facilidad de uso, eficiencia en cuanto al tiempo de procesado, su implementación en una plataforma libre y gratuito y su habilidad como clasificador (Belgiu y Drăguț, 2016).

El desarrollo tecnológico también ha generado cambios en los métodos automáticos desarrollados para identificar las coberturas del suelo. Tradicionalmente, la mayoría de los procesos de clasificación tomaban como unidad básica de análisis el píxel (clasificaciones basadas en píxeles - *CbP*) (Zhang y Guindon, 2009) y como datos de entrada imágenes satélite de baja/media resolución (Tatem et al., 2001). La popularidad que alcanzaron estas técnicas para identificar automáticamente coberturas y usos del suelo propició un incremento de la demanda de estos productos; una expansión de su ámbito de aplicación, fundamentalmente en entornos urbanos y áreas rurales complejas donde edificaciones, vegetación y relieve acentuado comparten un mismo espacio; y en consecuencia, la exigencia de mayor nivel de detalle (Yan et al., 2015). Sin embargo, la resolución espacial de las imágenes se convirtió en un factor limitante a la hora de dar respuesta a esta nueva demanda. Este obstáculo se manifestó por varias vías: por medio de píxeles mixtos, cuya aparición en la mayoría de los casos se debe a que el tamaño de los objetos es inferior al tamaño del píxel, de forma que más de una cobertura se ve sintetizada en un píxel a través de un único valor (Chen et al., 2017); o por medio de la confusión entre clases debido a la similitud *espectral* entre diferentes coberturas (Myint et al., 2011).

La disponibilidad de imágenes de mayor resolución, es decir, con mayor nivel de detalle para uso civil, venía a mitigar esta problemática, sin embargo contribuyó a aumentar la heterogeneidad espectral de las coberturas. Además, un píxel ya no contenía objetos pertenecientes a diferentes coberturas sino que ahora varios píxeles definían un objeto. Esta *nueva realidad* junto con el desarrollo de sofisticadas herramientas de procesado, tal como el programa *Definiens eCognition*[®], propiciaron un cambio de paradigma. El análisis estadístico de píxeles individuales ya no era la única alternativa y la posibilidad de emplear patrones espaciales surgió como opción complementaria de la mano de los métodos

basados en objetos (clasificaciones orientada a objetos - *CoO*) (Blaschke et al., 2014, Cánovas-García y Alonso-Sarría, 2015). En estos métodos la unidad básica de análisis ya no es el píxel sino regiones continuas de píxeles con valores homogéneos, denominados objetos (o segmentos). En consecuencia, los valores originales de los píxeles ya no se emplean como tal en la *CoO*, sino que a partir de los valores de los píxeles que forman cada objeto se calculan medidas resumen, como la media o la desviación típica, a partir de una imagen (Maxwell et al., 2015).

La delimitación de dichos objetos por medio de algoritmos de segmentación es el punto clave sobre el que se apoyan estos métodos. Así, la segmentación permitió reducir la variabilidad interna de las coberturas y eliminar el llamado efecto *salt and pepper* característico de las *CbP* (Liu y Xia, 2010). Sin embargo, estas no son las únicas ventajas que se obtienen al emplear objetos en lugar de píxeles. Los objetos no solo permiten usar variables *espectrales* sino que ponen a nuestro alcance variables espaciales (área, longitud, ancho, dirección,...), morfológicas (parámetros de forma, textura,...) o de contexto (relaciones con los vecinos, análisis de proximidad,...) (Navulur, 2006, Cánovas-García y Alonso-Sarría, 2015, Chen et al., 2017).

La gran mayoría de estudios que han comparado métodos de clasificación con diferentes unidades de análisis han concluido que los resultados de las *CoO* empleando capas de información con elevada resolución son más precisos que los que se obtienen a partir de *CbP* (Cleve et al., 2008, Myint et al., 2011, Buján et al., 2013a). Adicionalmente, las *CoO* también han mostrado ser más eficientes en relación al tiempo de procesado, ya que el empleo de objetos como unidad de análisis reduce el número de casos que es necesario procesar y por tanto, también la carga computacional en comparación con las *CbP* (Hay y Castilla, 2006, Im et al., 2008b). Al mismo tiempo, este *ahorro* de cálculo permite usar técnicas de clasificación más complejas y que implican mayor esfuerzo de cálculo, lo que nuevamente puede repercutir en una mejora de los resultados (Cánovas-García y Alonso-Sarría, 2015).

Del mismo modo que la segmentación permite mejorar los resultados de la clasificación, también asume el papel de verdugo, siendo la causa de la mayoría de errores de asignación que posteriormente se

hacen evidentes con la evaluación del resultado final de la clasificación. Teniendo en cuenta que la delineación manual de objetos por medio de foto-intérpretes expertos no proporciona un resultado único, tampoco se espera una única solución de la segmentación automática (Hay y Castilla, 2006). Los algoritmos de segmentación suelen ser sensibles tanto a las características de las capas de información y del área de estudio como a variaciones de los parámetros que rigen su forma de operar. Una vez identificados los parámetros más apropiados para segmentar una escena, su aplicación a otras regiones con características similares es inmediata (Kampouraki et al., 2008). Sin embargo, resulta imposible conocer a priori el valor ideal de dichos parámetros y la intervención del usuario para fijar estos valores todavía sigue siendo un paso necesario y todo un desafío para aquéllos que deciden emplear este tipo de métodos (Cánovas-García y Alonso-Sarría, 2015). A mayores de lo mencionado, entender como funcionan los algoritmos de segmentación es una tarea compleja, fundamentalmente si se trata de algoritmos incluidos en programas comerciales como *Definiens eCognition*[®] (Hay y Castilla, 2006, Salah, 2014).

Muchos errores de segmentación se producen debido a que los algoritmos de segmentación identifican objetos presentes en una imagen, los cuales no siempre se corresponden con objetos del mundo real (Kampouraki et al., 2008). Dichos errores son de dos tipos: aquellos que se deben a una excesiva segmentación de la escena (*over-segmentation*) y los ocasionados por una segmentación insuficiente (*under-segmentation*) (Liu y Xia, 2010). En relación al primer caso, una excesiva segmentación ocurre cuando un objeto real es representado por múltiples segmentos, es decir, cuando el tamaño de los segmentos es más pequeño que el tamaño del objeto real que pretenden representar (Möller et al., 2007). Por el contrario, una segmentación insuficiente ocurre cuando un segmento representa en parte o/y en su totalidad varios objetos reales, es decir, el tamaño de los segmentos es mayor que el tamaño del objeto real que representa. Estos errores son habituales en regiones con coberturas heterogéneas en relación al tamaño, donde se emplean algoritmos de segmentación que incluyen parámetros que controlan el tamaño de los segmentos. Así, si se tienen coberturas que abarcan grandes extensiones junto a coberturas con menor superficie (continuas), un parámetro de escala bajo permitirá definir relativamente bien aquellos

objetos con menor superficie pero causará una sobre-segmentación en aquellas coberturas que abarcan un área mayor. Por el contrario, un parámetro de escala mayor, tenderá a dar objetos que se ajusten mejor a los contornos de las coberturas con mayor superficie pero ocasionarán errores por sub-segmentación en aquellas coberturas con menor área.

Dichos errores tienen un impacto negativo pero desigual en el resultado final de la clasificación. En caso de darse una segmentación excesiva, la heterogeneidad interna de las clases afectadas será mayor que en el caso de segmentaciones más ajustadas a los objetos reales. Sin embargo, podría darse que cada segmento se corresponda con una única clase (en teoría). Dado este caso, sería posible alcanzar un 100% de acierto en la identificación de dicha clase. Por el contrario, en el caso de que los segmentos sean mayores que los objetos que representan, dichos segmentos incluirán más de una clase. Esta circunstancia dará lugar a errores a la hora de asignarle una clase a dichos segmentos, pues irremediablemente alguno de los objetos reales será mal clasificado. A diferencia del caso anterior, la precisión de la identificación de estas clases siempre será inferior al 100% (Liu y Xia, 2010).

Tal y como se dejó ver anteriormente, con independencia del tipo de error por fallos en la segmentación, puede no darse una coincidencia exacta entre los contornos de los segmentos y los límites reales de los objetos. Esta es la causa de la aparición de objetos mixtos, los cuáles contienen más de una cobertura real. Se identifican dos motivos principales por los que la segmentación puede fallar y dar lugar a objetos mixtos. En primer lugar, pequeños objetos pueden no ser detectados por el algoritmo de segmentación y fusionados en un segmento junto con objetos de otras clases (Chen et al., 2018). En segundo lugar, se encuentra la confusión espectral entre objetos pertenecientes a distintas clases (Kampouraki et al., 2008). En la mayoría de los casos se debe al bajo contraste espectral entre estos objetos espacialmente próximos. Cuando esto sucede, es muy difícil mejorar el resultado de la segmentación con independencia del algoritmo que se esté empleando (Cánovas-García y Alonso-Sarría, 2015).

Para abordar los límites de las *CbP* y las *CoO* y mejorar la precisión de los procesos de clasificación de coberturas/usos del suelo, varios

estudios han optado por combinar *CbP* con *CoO* (Salah, 2014, Man et al., 2015, Zehtabian y Ghassemian, 2017). Chen et al. (2018) dividió estos métodos híbridos en 3 grupos: 1) regla de la mayoría; 2) fusión de los mejores resultados a nivel clase; y 3) conocimiento experto. Probablemente los métodos incluidos en el primer grupo, *regla de la mayoría*, sean los más sencillos de implementar y entender. De manera genérica, en primer lugar ejecutan una *CbP* empleando alguno de los algoritmos tradicionales de asignación (por ejemplo, *maximum likelihood*) y una segmentación usando una o varias de las capas de información disponibles. A continuación, superponen el resultado de la segmentación al resultado de la *CbP*. Finalmente, a cada objeto se le asigna la clase a la que pertenecen la mayoría de los píxeles contenidos en su interior. Ejemplos de este tipo de métodos híbridos son los desarrollados por Bernardini et al. (2010), Li et al. (2013), Costa et al. (2014) o Sturari et al. (2017).

Como ya se ha mencionado, la segmentación en las *CoO* permiten reducir la variabilidad interna de las coberturas, originada en gran medida por el aumento del detalle de los datos de entrada. De esta forma se consigue un aumento de la precisión con la que se identifican las coberturas más heterogéneas. Sin embargo, esta regla no se cumple mayoritariamente a escala clase. Boyaci et al. (2017) realizó una comparación entre una *CbP* empleando el algoritmo *maximum likelihood* y una *CoO* usando el algoritmo *nearest neighbor* tomando como datos de entrada imágenes Aster. A pesar de la resolución de las imágenes, la *CoO* obtuvo mejor precisión que la *CbP* (74.42% y 69.10%, respectivamente). Sin embargo, las clases *tierras de cultivo* y *masas forestales caducifolias densas* obtuvieron mejores resultados en la *CbP* que en la *CoO*. De forma similar, las clases *masas de agua*, *áreas pavimentadas* y *palmeras* fueron identificadas con mayor precisión mediante una *CbP* que mediante una *CoO* en el estudio realizado por Pu et al. (2011), aunque al igual que en el caso anterior la *CoO* fue más precisa que la *CbP* (84.58% y 72.79%, respectivamente). De manera resumida, en una escala general las *CoO* presentan mejores precisiones que las *CbP*, sin embargo si el análisis se lleva a escala clase, aquellas coberturas homogéneas en cuanto a sus valores *espectrales* pueden presentar mejores precisiones en las *CbP* que en las *CoO*. En base a estos resultados, algunos autores desarrollaron métodos que ejecutan de forma simultánea una *CbP* y una *CoO*, y

como paso final, ambas clasificaciones son fusionadas seleccionando para cada clase el resultado más preciso. Algunos ejemplos de métodos que pertenecen al grupo que fusiona los mejores resultados a nivel clase son Wang y Tseng (2004), Bhaskaran et al. (2010) o Aguirre-Gutiérrez et al. (2012).

Finalmente, los métodos que integran el último grupo de clasificadores híbridos no presentan una estructura tipo, ya que las reglas de decisión que se fijan dependen de los datos disponibles y de las clases objetivo, y al mismo tiempo existen múltiples formas de combinar los métodos de clasificación tradicionales. Probablemente, de todos los tipos de métodos híbridos estos son los más complejos. En algunos casos, el primer paso consiste realizar una *CbP* y a continuación el resultado de esta clasificación se emplea como una variable más en una *CoO* (Gonçalves et al., 2009, Chen et al., 2018). Un ejemplo de método híbrido que se basa en *conocimiento experto* es el desarrollado por Malinverni et al. (2011). En primer lugar, a partir de imágenes ADS40 de alta resolución se crea un conjunto de variables que se emplean para ejecutar una *CbP* mediante el algoritmo *AdaBoost*. A continuación, a partir de las imágenes originales se realiza una segmentación. En este punto, el resultado de la *CbP* y un conjunto de datos auxiliares (cartografía de edificaciones, ríos y carreteras) se integran con el resultado de la segmentación y se aplica el método WTA (*Winner-Takes-All*) para obtener una clasificación refinada. Si bien el método desarrollado en dicho estudio es híbrido, la inclusión de cartografía auxiliar lo convierte en semi-automático y la identificación de algunas coberturas pasan a ser dependientes de la existencia y calidad de la cartografía auxiliar. Otros métodos híbridos fueron desarrollados por Sheeren et al. (2009) y Aguilar et al. (2016).

Como último dato, citar que la totalidad de los estudios consultados para la elaboración de esta revisión de métodos híbridos usaron imágenes satélite o aéreas (25 estudios) y la mayoría emplean imágenes con resolución espacial media. Adicionalmente, sólo en dos de ellos se emplearon datos LiDAR como información auxiliar con el objetivo de abordar la problemática de la confusión espectral entre clases y la variación espectral interna de las clases (Man et al., 2015, Sturari et al., 2017). En esta línea, una de las últimas revisiones realizadas sobre identificación de coberturas en entornos urbanos empleando datos

LiDAR no hace referencia a este tipo de métodos (Yan et al., 2015) y tampoco se ha encontrado ningún estudio que incluya un método híbrido que utilice los datos LiDAR como única fuente de información. ¿El potencial de estos métodos se limita únicamente a imágenes con resolución espacial media?

En base a lo expuesto, en este estudio se busca lograr los siguientes objetivos:

- Explorar el potencial de los datos LiDAR como única fuente de información para identificar y clasificar en un entorno rural 8 clases de cobertura del suelo, entre las que se incluyen dos que hacen referencia al nivel de gestión de la vegetación.
- Comprobar si la integración de diferentes estrategias de clasificación en un árbol de decisión elaborado en base a la información disponible contribuye a mejorar la precisión de una clasificación automática basada en píxeles.
- Analizar en qué medida la reducción de la densidad de puntos LiDAR afecta a la precisión de la clasificación.

A continuación se describe brevemente la estructura que presenta este capítulo. En primer lugar, se describe el área de estudio (sección 3.2.1) y los datos disponibles (sección 3.2.2). En segundo lugar se detallan las tareas de procesado de datos, destacando la normalización de los valores de intensidad (sección 3.2.3) y la reducción de la densidad de puntos (sección 3.2.4), que conducirá a la obtención de las diferentes capas de información (secciones 3.2.5 y 3.2.6). A continuación, se citan y describen las coberturas del suelo que se pretenden identificar (sección 3.2.7), así como el proceso para identificar la información más relevante (sección 3.2.8). Para finalizar este bloque se describe *HyClass*, el método híbrido de clasificación que se propone (sección 3.2.9) y el método para evaluar los resultados de la clasificación (sección 3.2.10). En el siguiente bloque se presentan los resultados de la corrección de la intensidad (sección 3.3.1), así como del análisis de la importancia de las variables (sección 3.3.2). Finalmente, se muestran

los resultados cuantitativos y cualitativos de la clasificación *HyClass* y su comparación con el resultado de una clasificación basada en píxeles empleando el algoritmo *random forest* (sección 3.3.3). Como punto final se incluyen las principales conclusiones que se derivan del estudio realizado (sección 3.4).

3.2 Área de estudio, material y métodos

3.2.1 Zona de estudio

El área de estudio, que ocupa una superficie aproximada de 70 ha (recuadro granate en la Figura 3.2), se sitúa en la localidad rural de Vilapena (43°N 25', 7°W 10'), perteneciente al municipio de Trabada (Lugo, Galicia) en el noroeste de España.

La superficie del término municipal de Trabada es una continuidad de altas cumbres y profundos y fértiles valles que recorren desde el alto Cerrochán (776 m) hasta la Ría de Ribadeo en Ría de Abres. En esta área confluyen zonas dedicadas a labradío, pequeñas poblaciones y amplias áreas arboladas, donde las principales especies son *Eucalyptus globulus* labill. (80%), *Quercus robur* L. (15%) y *Pinus radiata* D. Don (5%) las cuales coexisten con vegetación de menor porte como el laurel o el helecho. Las características tanto orográficas como de coberturas del suelo de esta zona la convierten en una ubicación ideal para probar los métodos de clasificación propuestos.

En la Figura 3.2 se muestra la zona de estudio delimitada por un rectángulo granate sobre la ortoimagen obtenida a partir del centro de descargas de información geográfica de Galicia (CDIX) (<http://mapas.xunta.gal/visores/descargas/>). Las coordenadas UTM de las esquinas superior izquierda e inferior derecha también se incluyen en dicha figura. Finalmente, se muestra la ocupación del suelo para 2011 a partir de la información contenida en SIOSE (Sistema de Información sobre Ocupación del Suelo de España) integrado dentro del Plan Nacional de Observación del Territorio (PNOT).

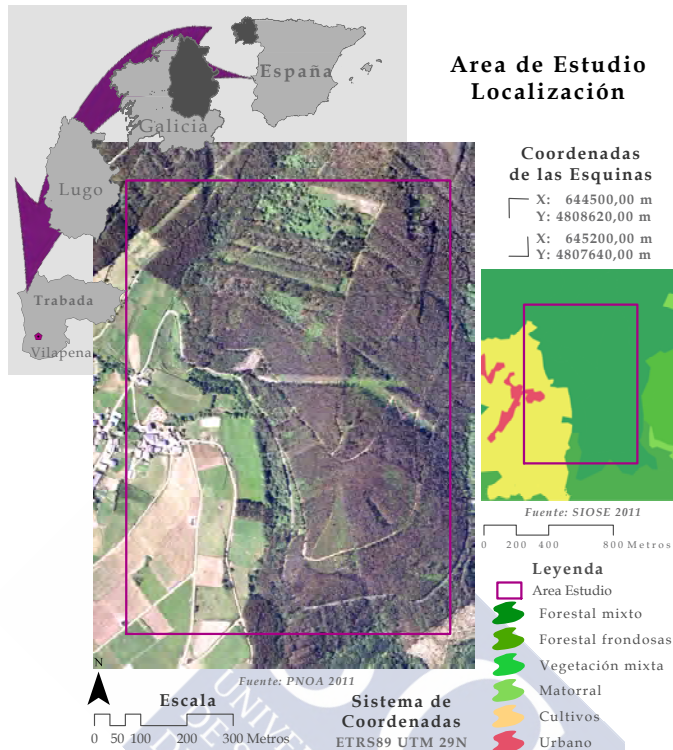


Figura 3.2: Localización de la zona de estudio. Fuente: PNOA@Instituto Geográfico Nacional de España - Xunta de Galicia y SIOSE@Instituto Geográfico Nacional de España - Xunta de Galicia.

3.2.2 Datos

A continuación se describen las características de los datos usados en esta investigación, obtenidos tanto por medio de sensores remotos (activos y pasivos) como mediante técnicas de topografía clásica.

Datos LiDAR. Los datos LiDAR fueron capturados en octubre de 2010 mediante un sensor Leica ALS50-II en el marco del proyecto de investigación *Aplicación de la tecnología LiDAR al inventario forestal y a la gestión de riesgos naturales (2009-PG239)*. Dicho sensor registró hasta 5 retornos en aquellas zonas cuya superficie es semipermeable

(fundamentalmente zonas con vegetación). Las características de la toma de datos LiDAR se incluyen en la Tabla 3.1.

Tabla 3.1: Características técnicas de la captura de datos LiDAR.

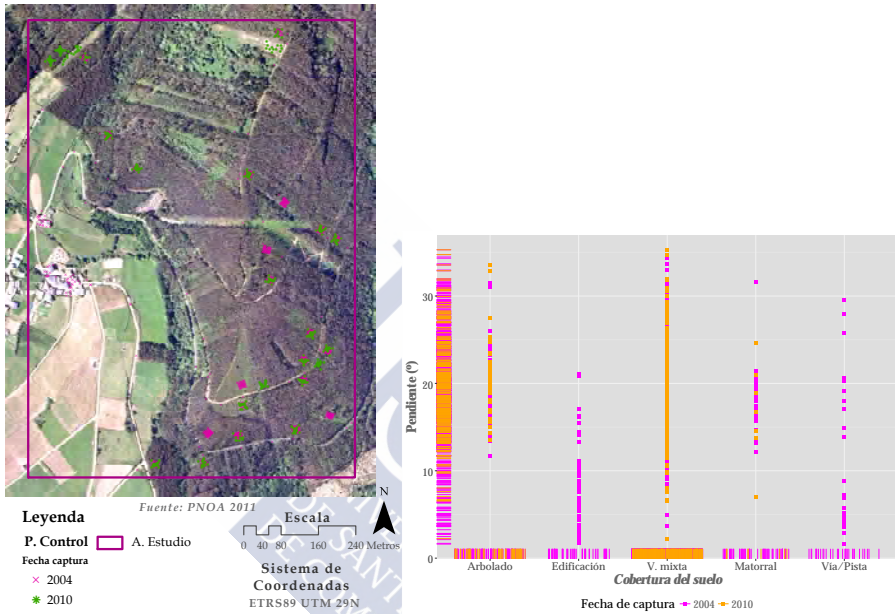
		Distribución de puntos
Fecha	Octubre 2010	<p> Leyenda pto/m²: <5 (amarillo), 5-10 (naranja), 10-15 (verde claro), 15-25 (verde oscuro), >25 (azul) A. Estudio (línea magenta) Fuente: PNOA 2011 Escala: 0, 40, 80, 160, 240 Metros Sistema de Coordenadas: ETRS89 UTM 29N </p>
Sensor	Leica ALS50-II	
Frecuencia del pulso	115700 Hz	
Ángulo de escaneo	±12°	
Frecuencia de escaneo	40 Hz	
Divergencia del rayo	0.2 mrad	
Longitud de onda	1064	
Solape	min 30%	
Nº de pasadas	6	
Densidad	5 pulsos m ⁻²	
Densidad media ponderada	8.7 pto m ⁻²	
Altura de vuelo	1900 m	
Precisión planimétrica	≤ 0.20 m	
Precisión altimétrica	≤ 0.10 m	

Puntos de control terreno. En la zona de estudio se dispone de 1656 puntos terreno de referencia (PC_R) obtenidos en los años 2004 y 2010 (1330 y 326 puntos, respectivamente) empleando métodos topográficos. La medición de estos puntos se llevó a cabo en el marco de dos proyectos de investigación financiados por el Instituto Galego de Estadística y la Consellería do Medio Rural¹ y por la Consellería de Economía e Industria de la Xunta de Galicia². En ambos casos, se empleó un GPS Trimble 5800 bifrecuencia con el que se estableció una red microgeodésica (método estático) para posteriormente, a partir de las bases observadas, realizar múltiples itinerarios y observaciones de puntos

¹Convenio de investigación titulado *Inventario Forestal mediante LiDAR. Proxecto piloto no concello de Trabada (Lugo)*. Estos datos fueron empleados en la tesis doctoral de Luis Gonçalves Seco titulada *Automatización en la generación de modelos digitales de elevación, cubicación y combustibles, a partir de datos LiDAR*, presentada en el año 2007 en la Universidad de Santiago de Compostela.

²Proyecto de investigación titulado *Aplicación de la tecnología LiDAR al inventario forestal y a la gestión de riesgos naturales (2009-PG239)*.

terreno empleando una estación total Trimble 5603. Si bien los puntos de referencia capturados en el año 2004 se encuentran cronológicamente muy lejanos al momento de captura de los datos LiDAR (año 2010), se considera que pueden ser usados para comprobar la precisión de los MDT pues en ese periodo la superficie del terreno no sufrió cambios.



(a) Distribución espacial de los PC_R . (b) Caracterización de los PC_R .

Figura 3.3: Distribución espacial y caracterización de los PC_R .

Además de obtener las coordenadas XYZ (altura elipsoidal) en el sistema de referencia ETRS89 proyección UTM huso 29, a cada punto se le asignó en campo una de las siguientes clases de cobertura: 1) arbolado sin vegetación arbustiva, 2) punto en borde de edificación, 3) vegetación mixta, 4) matorral y 5) vía pavimentada o pista forestal. En la Figura 3.3a se incluye la distribución espacial de dichos puntos en la zona de estudio mientras que en la Figura 3.3b se representa la cantidad de puntos de control en función de la cobertura del suelo, la pendiente y del año en el que tuvo lugar la toma de datos. En las Tablas C.1-C.9 del Anexo C se incluye el listado completo de las coordenadas de cada punto de referencia y la cobertura.

Ortoimagen. La ortoimagen empleada en este estudio fue adquirida en el marco del proyecto PNOA (Plan Nacional de Ortofotografía Aérea) en 2011 (Figura 3.2) bajo la dirección del Ministerio de Fomento de la Administración General del Estado (a través de la Dirección General del Instituto Geográfico Nacional - IGN - y del Centro Nacional de Información Geográfica - CNIG) y la Consellería de Medio Ambiente, Territorio e Infraestructuras de la Xunta de Galicia (a través del Instituto de Estudos do Territorio - IET). Tiene una resolución espacial de 25 cm (escala de representación 1:2.500), una resolución radiométrica de 24 bits y se encuentra compuesta por tres bandas espectrales (RGB). El sistema de referencia geodésico es ETRS89. Esta información se tomará como base para realizar la fotointerpretación de los puntos de referencia para evaluar la precisión de la clasificación de coberturas del suelo.

3.2.3 Normalización de la intensidad

En un corto espacio de tiempo se han vertido muchos esfuerzos en el desarrollo de métodos para corregir los valores de intensidad registrados por los sensores LiDAR. Posiblemente estas iniciativas se han visto impulsadas en su mayoría por el aumento del número de aplicaciones de esta información. [Yan et al. \(2015\)](#) realizaron una interesante revisión de la aplicación de la tecnología LiDAR en espacios urbanos. Destacan en este ámbito los análisis de morfología urbana y áreas verdes, control del planeamiento urbano y monitorización, diseño de espacios urbanos, análisis del impacto de políticas públicas, modelado del riesgo de inundaciones, mapas de líneas eléctricas para un mantenimiento más eficiente o la evaluación del potencial de radiación solar. Por su parte y de forma más general, [Kashani et al. \(2015\)](#) incluyó en su estudio aplicaciones concretas de la información de intensidad, donde destaca su empleo para la categorización de superficies en glaciares, corrección geométrica entre pasadas e integración de datos multi-sensor mediante la identificación de características comunes, identificación de especies forestales, mapa de zonas costeras, detección de daños estructurales, evaluación de construcciones históricas,... Estos nuevos usos plantean renovados retos tanto para la tecnología en sí como concretamente para

la componente radiométrica de los datos LiDAR.

Sin embargo, [Kashani et al. \(2015\)](#) puso de manifiesto en su revisión sobre los procesos para corregir y calibrar dichos valores, la inconsistencia que existe entre los diferentes esfuerzos. Estas inconsistencias comienzan con la falta de acuerdo en la terminología empleada tanto para denominar el propio proceso (calibración, normalización, corrección,...) como para referirse a los resultados (reflectancia, pseudo-reflectancia, reflectancia relativa, intensidad normalizada,...). En primer lugar es fundamental establecer que se entiende por intensidad. La intensidad en este contexto representa la cantidad de energía registrada por el sensor procedente de la superficie del terreno o de los objetos situados sobre ella ([Singh et al., 2010](#), [Yan et al., 2015](#)). Dicho valor es transformado por los proveedores de datos a valores de 8 bits (0 - 255), por tanto el valor de intensidad que maneja el usuario final no es el valor de energía registrada por el sensor ([Habib et al., 2011](#)).

Una de las principales ventajas que presenta la tecnología LiDAR frente a otras técnicas de captura de datos mediante sensores remotos es su capacidad para atravesar la vegetación y describir la superficie que se encuentra debajo. Esta característica unida al hecho de que teóricamente los materiales presentan diferentes comportamientos en relación a la reflectancia, dando como resultado diferentes valores de intensidad ([Song et al., 2002](#)), convierten a esta componente de los datos LiDAR en crítica para clasificar y detectar diferentes materiales, incluso en zonas bajo arbolado. Otra de las ventajas que presenta esta tecnología y en concreto la intensidad es que su registro no se ve afectado por las condiciones de iluminación como en el caso de las imágenes aéreas (sombras u oclusiones) ([Donoghue et al., 2007](#), [Höfle y Pfeifer, 2007](#)). Sin embargo, factores como la topografía y las propiedades del terreno, las características del vuelo o del sensor o las condiciones atmosféricas sí pueden afectar considerablemente al registro de la intensidad.

En relación al primero de los factores, la orografía y las características de la superficie, tales como la rugosidad o la orientación de la superficie están directamente relacionados con el tipo de reflexión que tiene lugar cuando el rayo láser impacta sobre la superficie del terreno o sobre los objetos localizados sobre él (p. ej. difusa, especular,...)

(Kukko et al., 2008). De igual forma, la composición y densidad del terreno o los objetos definen el nivel de reflectancia de cada cobertura. Teóricamente, superficies con altos niveles de reflectancia devolverán al sensor una mayor cantidad de energía que aquellos materiales con menor reflectancia (Song et al., 2002). Esta característica es intrínseca de los objetos y por lo general no se aborda como un factor a corregir, pero sí constituye un parámetro de gran interés para el desarrollo de modelos de corrección radiométrica (Kashani et al., 2015). Adicionalmente, los cambios en la elevación del terreno afectan a longitud de la trayectoria del rayo láser dando como resultado una atenuación o aumento de la señal registrada por el sensor provocando alteraciones en los valores de intensidad (Luzum et al., 2004, Höfle y Pfeifer, 2007, Mazzarini et al., 2007).

Por otro lado, las características del sensor como pueden ser la divergencia del rayo o la energía transmitida, directamente relacionada esta última con la frecuencia del pulso, influyen en la capacidad de la superficie de impacto para devolver la energía al sensor. Dependiendo del tipo de sensor, las transformaciones (medición, digitalización, escalado y en ocasiones modificación) a las que se somete la energía recibida son diferentes. Así, los niveles digitales obtenidos tras el registro son escalados para abarcar el rango disponible, que en el caso de una transformación de 8 bits iría de 0 a 255 (Höfle y Pfeifer, 2007). Este proceso de transformación es propio de cada sensor y los pasos llevados a cabo generalmente no se conocen. La falta de información sobre este proceso dificulta el calibrado de los valores de intensidad mediante valores reales de reflectancia por parte de los usuarios (Kashani et al., 2015). Adicionalmente, las características de la toma de datos como el ángulo de escaneo o variaciones de la altura de vuelo influyen en el tamaño de huella y alteran la longitud de la trayectoria que recorre el rayo láser (Luzum et al., 2004, Donoghue et al., 2007) y en consecuencia, los valores de intensidad. Cuanto mayor es la altura de vuelo mayor es la distancia que tiene que recorrer la energía ocasionando una atenuación de la señal. Del mismo modo, un aumento del rango dará lugar a un mayor tamaño de la huella y por tanto, el valor de intensidad registrado por el sensor representará una mayor superficie, aumentando el riesgo de abarcar más de un tipo de cobertura. Estos valores *mixtos* de intensidad pueden introducir ruido en la imagen creada a partir de este componente

de los datos LiDAR.

Finalmente, las condiciones atmosféricas pueden causar una atenuación de la señal registrada por el sensor (Luzum et al., 2004, Donoghue et al., 2007). En concreto, el vapor de agua, el dióxido de carbono o el oxígeno pueden retener la energía (Kashani et al., 2015). Además, si la superficie de impacto presenta altos valores de humedad dará lugar a una mayor absorción de la energía, disminuyendo también la energía devuelta al sensor (Kaasalainen et al., 2009).

A pesar de la influencia que estos factores ejercen sobre los valores de intensidad, algunos autores afirman que el efecto de la corrección de la intensidad por el rango no resulta significativa en el caso de orografía no compleja (Hasegawa, 2006), o en entornos urbanos, donde Gross et al. (2008) afirmaron que únicamente el 5% de las anomalías que presentan los valores de intensidad en estas zonas se deben al rango, pues dichas zonas no presentan una orografía compleja y las mayores variaciones de altura se deben a las construcciones, alturas que se considera que no son suficientes como para influir en los valores de intensidad; o por el ángulo de incidencia en el caso de bajos ángulos de escaneo (Holmgren y Persson, 2004), justificando así el uso de valores brutos de intensidad. Sin embargo, un numeroso grupo de autores han reconocido la necesidad de desarrollar métodos para corregir la intensidad. Kashani et al. (2015) realizó una revisión exhaustiva de los métodos desarrollados hasta el momento y estableció una escala compuesta por cuatro niveles de corrección de la intensidad. El paso de un nivel a otro implica tanto un aumento de la información necesaria para llevar a cabo la corrección como su nivel de complejidad.

De manera resumida, el nivel 0 de esta escala se refiere al proceso interno de transformación por el cual se pasa del valor de energía registrada por el sensor a un nivel digital, que posteriormente es escalado y en casos excepcionales modificado por el proveedor. El resultado de este proceso son los valores de intensidad que manejamos l@s usuari@s. El nivel 1 se refiere al proceso de corrección de la intensidad mediante el cual se busca mitigar o eliminar perturbaciones causadas por uno o varios de los factores mencionados anteriormente (García et al., 2010, Habib et al., 2011, Mesas-Carrascosa et al., 2012, Ding et al., 2013).

La normalización de la intensidad se corresponde con el nivel 2 de esta escala. Este proceso consiste en normalizar la imagen de intensidad por medio de técnicas de ajuste del contraste, como los reales radiométricos, orientados a mejorar la apariencia visual principalmente en zonas de solape entre pasadas adyacentes (Yan y Shaker, 2014). También se podrían incluir aquí aquellos reales que consideran los valores de los vecinos para realizar los ajustes, caso de los filtros de paso bajo (Song et al., 2002, Buján et al., 2013b).

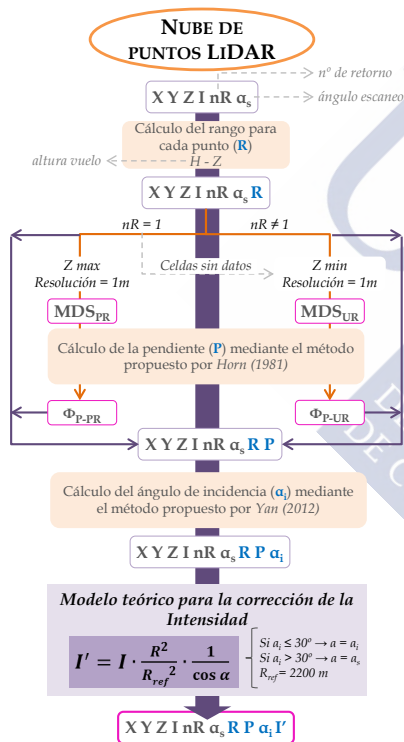


Figura 3.4: Esquema de proceso para corregir la intensidad por R y α_i .

intensidad se van a corregir en dos pasos. En primer lugar, se va a llevar a cabo una corrección de la intensidad de nivel 1, según la escala propuesta por Kashani et al. (2015), mediante la aplicación del modelo teórico empleado previamente por Coren y Sterzai (2006) y Habib et al. (2011) (Ecuación 3.1) (Figura 3.4). Mencionar que la elección de este

El resultado de los niveles 1 y 2 es "reflectancia relativa" o "pseudo-reflectancia" y se considera que estos niveles son suficientes para llevar a cabo procesos automáticos de clasificación de coberturas, como el que en este estudio se plantea. Sin embargo, si el objetivo es combinar o comparar datos procedentes de diferentes sistemas y condiciones de vuelo, es necesario realizar una calibración radiométrica (nivel 3). Este proceso permite obtener valores "reales" de reflectancia. Para calcular las constantes de calibración del sensor se emplean dianas cuya reflectancia es conocida (Kaasalainen et al., 2009).

Debido a que los datos LiDAR en la zona de estudio provienen de dos pasadas de vuelo, y a que dicha zona es extensa y el terreno muestra una alta variabilidad en cuanto a pendientes y altitudes, los valores de

tipo de corrección y modelo se encuentra totalmente condicionada por la falta de información referente a las condiciones atmosféricas durante la toma de datos.

$$I' = I * \frac{R^2}{R_{ref}^2} * \frac{1}{\cos \alpha} \quad (3.1)$$

Mediante este modelo teórico, los valores originales de intensidad (I), representación de la energía registrada por el sensor transformada linealmente a valores de 8 bits (0 - 255), son corregidos por el rango (R , distancia en metros entre la localización del sensor y el objetivo) y el ángulo de incidencia (α_i , ángulo en radianes entre la dirección del vector normal de la superficie de impacto y la dirección del pulso láser suponiendo una reflectancia Lambertiana). A fin de eliminar la dependencia de los valores de intensidad con respecto a la altura de vuelo, se realiza una normalización de los valores corregidos empleando un rango de referencia definido por el usuario (R_{ref} - m) (García et al., 2010). Así, los valores corregidos de la intensidad (I') serán equivalentes a los que se hubieran obtenido si para cada punto el rango fuese igual a R_{ref} y el ángulo de incidencia igual a 0 (Kashani et al., 2015).

En este estudio, únicamente se dispone de la altura media de vuelo ($H=1900$ m en Tabla 3.8) y no la altura de vuelo para cada punto. Por tanto, el valor de R para cada punto se aproximó como la diferencia entre la altitud media de vuelo (H) y la elevación de cada punto. Si bien no se trata de la situación óptima, se considera que tener en cuenta el rango es fundamental debido a que dicho factor es crítico para la corrección de los valores de intensidad ya que la atenuación de la energía del láser es directamente proporcional a la distancia recorrida por el haz de luz (Habib et al., 2011). Adicionalmente, el ángulo de incidencia se calculó siguiendo los pasos propuestos por Yan (2012). Para ello, fue necesario asignarle a cada punto el valor de pendiente de la superficie de impacto. Para la obtención de dichos valores de pendiente, fue necesario crear dos Modelos Digitales de Superficie. El primero de ellos se obtuvo rasterizando la nube de puntos LiDAR de forma que a cada celda cuadrada de 1 m de tamaño se le asignó el valor de elevación máxima de los puntos de primer retorno incluidos en cada

celda (MDS_{PR}). El segundo modelo se obtuvo rasterizando la nube de puntos LiDAR, de forma que a cada celda cuadrada de tamaño 1 m se le asigna el valor de elevación mínimo obtenida a partir de los puntos que no son de primer retorno. En aquellas celdas donde únicamente hay puntos de primer retorno, se les asignó el valor mínimo de elevación a partir de dichos puntos (MDS_{UR}).

Si bien una densidad media ponderada de 8.7 ptos/m² permitiría fijar una mayor resolución para la creación de los MDS, la realidad es que por un lado se están empleado los puntos de primer retorno y por otro el resto de puntos, lo que provoca que la densidad de puntos de estos dos grupos de datos se encuentre alejada del valor de 8.7 ptos/m². Adicionalmente, las zonas que no presentan solape entre pasadas presentan una menor densidad de puntos y la resolución de 1 m es la que resulta más adecuada. Con esta resolución, el 2.5% del área de estudio no contiene datos mientras que si la resolución se aumenta hasta los 50 cm la superficie sin datos sería considerablemente mayor ($\simeq 30\%$).

Una vez obtenidos los MDS, se obtuvieron los ráster de pendiente empleando la función *terrain* (paquete *raster* - v.2.4-20) (φ_p). Esta función emplea el método propuesto por Horn (1981) para calcular la pendiente de una celda a partir de los valores de elevación de las 8 celdas vecinas. Como resultado se obtiene el ráster de pendiente φ_{p-PR} a partir del MDS_{PR} y el φ_{p-UR} del MDS_{UR} . A partir de φ_{p-PR} , se le asigna a cada punto de primer retorno un valor de pendiente (P), mientras que en el caso del resto de puntos dicho valor se extrae a partir de φ_{p-UR} . Aquellos puntos localizados en celdas donde los φ_p no tienen asignado ningún valor, se les asigna como valor de pendiente el valor medio de los puntos situados en un radio de 3 m. De esta forma, únicamente al 0.5% de los puntos no se les asignó un valor de pendiente y dichos puntos fueron descartados. Finalmente, los valores de pendiente de la superficie de impacto, junto con el ángulo de escaneo y la elevación de cada punto son los datos necesarios para calcular el ángulo de incidencia (α_i) según la metodología propuesta por Yan (2012). A partir de la Ecuación 3.1 se corrige la intensidad en función del rango (R) y del ángulo de incidencia (α_i). Citar con respecto a este último parámetro, y tal como demostró Yan (2012) en su estudio, el empleo de elevados ángulos de incidencia pueden resultar en una excesiva corrección de los valores de intensidad,

fundamentalmente en zonas arboladas o en bordes de edificaciones. Para mitigar este problema, dicho autor empleó la pendiente de la superficie de impacto para controlar la excesiva corrección de la intensidad. En este caso, cuando $P \geq 30^\circ$ se empleará el ángulo de escaneo (α_s) en lugar del ángulo de incidencia (α_i) en la Ecuación 3.1. Los valores originales de intensidad no se pierden en este proceso puesto que los valores corregidos son almacenados como un atributo más de cada punto.

Debido a la persistencia de ruido en la imagen de intensidad se ha optado por aplicar un filtro de paso bajo. Esta alternativa fue usada en trabajos previos (Song et al., 2002, Buján et al., 2013b) ante la falta de los parámetros atmosféricos necesarios para llevar a cabo una corrección más rigurosa. En estos trabajos, el filtro de paso bajo (filtro de media) se aplicó a la imagen de intensidad original (Song et al., 2002) o a la corregida por el rango (Buján et al., 2013b). Los filtros de paso bajo tradicionales que se aplican sobre imágenes operan definiendo en primer lugar una matriz de filtrado de $n \times n$ píxeles. En el caso de un filtro de media, cada elemento de la matriz tiene peso 1. Dicha matriz se desplaza a lo largo y ancho de la imagen, de forma que al píxel central se le asigna un nuevo valor obtenido a partir del valor medio de los $n \times n$ píxeles vecinos incluidos en la matriz de filtrado. Este proceso da como resultado una imagen con apariencia suavizada. Sin embargo, en este estudio el filtro de paso bajo se desea aplicar a nivel punto y no a la imagen de intensidad corregida por el rango y el ángulo de incidencia. Este punto se corresponde con el segundo paso de la corrección de la intensidad.

Para la aplicación del filtro de paso bajo a nivel punto, en primer lugar fue necesario definir el equivalente a la matriz de filtrado que se emplea sobre imágenes. En este caso, la forma del área de filtrado será circular centrada en el punto al que se le aplicará el filtro de paso bajo. Para establecer la magnitud del radio (r) se calcula la distancia entre puntos adyacentes (PS - *point spacing*). Asumiendo que los puntos se encuentran regularmente distribuidos, $PS = \sqrt{1/D}$, donde D es la densidad de puntos de la nube LiDAR. En este caso $D = 8.74$ (densidad media ponderada). Así, $r = 2.5 \cdot PS$ metros y teóricamente en la zona de influencia de cada punto existirán 20 puntos, lo que asegura disponer de puntos suficientes para el cálculo del nuevo valor de intensidad (I'').

Finalmente, al punto central se le asigna como valor de intensidad el percentil del 68.3% de los valores de intensidad de los puntos (I') que se encuentran en su área de influencia ($Q68.3_{I'}$). Se optó por este estadístico en lugar de la media debido a que es menos sensible a la presencia de valores extremos (Höhle y Höhle, 2009), efecto que se desea mitigar a partir de la aplicación de este filtro. A este cálculo se añade un último condicionante. En caso de que el punto central sea de primer retorno, $Q68.3_{I'}$ se calculará a partir de los puntos de primer retorno incluidos en la zona de influencia. En caso contrario, para su cálculo se emplearán los valores de intensidad de los puntos que no son de primer retorno. En el caso excepcional de que el punto central no sea de primer retorno pero en el área de influencia sólo existan primeros retornos, el valor de intensidad final será el mismo que el obtenido tras la corrección del rango y el ángulo de incidencia ($I'=I''$). Con estas restricciones se pretende mitigar el efecto de valores de intensidad mixta en zonas que presentan varios retornos (Buján et al., 2013b). Por último, se normalizan los valores de intensidad a un rango entre 0 y 255 a partir del método *min-max scaling* (Han, 2012).

Finalmente aclarar que se han vertido tantos esfuerzos en mejorar la información de intensidad y su representación gráfica pues se considera, y así lo respaldan varios de los trabajos consultados (Song et al., 2002, Charaniya et al., 2004, Brennan y Webster, 2006, Im et al., 2008b, Niemeier et al., 2014), que dicha información puede resultar clave para diferenciar coberturas como suelo desnudo, áreas pavimentadas y zonas con vegetación baja. Por este mismo motivo, se ha optado por aplicar el filtro de paso bajo a nivel punto, con el fin último de minimizar la pérdida de información en aquellas áreas que presentan más de un retorno, especialmente en zonas con vegetación donde se espera que la intensidad de los puntos que se corresponden con el terreno presenten valores más bajos que los que representan la vegetación.

3.2.4 Reducción de la densidad de puntos

En este estudio, además de comparar los resultados de diferentes métodos de clasificación de coberturas también se pretende analizar la

robustez de cada uno de ellos ante variaciones de la densidad de puntos LiDAR. Para llevar a cabo dicho análisis es necesario disponer de nubes de puntos con diferentes densidades. En este sentido, son anecdóticos los casos en los que se dispone de dichos datos procedentes de diferentes vuelos, debido fundamentalmente a la desfavorable relación coste-beneficio. Como alternativa, la comunidad científica ha desarrollado métodos para la reducción automática y artificial de nubes originales de puntos. En el capítulo anterior se realizó una revisión sobre dichos métodos, se planteó uno nuevo (PpC - *Proportional per Cell*) y se llevó a cabo un análisis de su funcionamiento en comparación con otro métodos de reducción. El resultado fue que si bien el empleo de uno u otro método parece no tener efecto sobre la precisión final de los MDT (evaluación externa), las nubes de puntos reducidas sí presentan diferencias dependiendo del método que se use (evaluación interna). Estas diferencias se dan principalmente cuando se compara la distribución original de los puntos con la de las nubes reducidas. En dicha evaluación, el método PpC fue el que mejores resultados obtuvo.

En base a dichos resultados, en este estudio se empleará el método *Proportional per Cell* para reducir la densidad de puntos de la nube original. En la Figura 3.5 se incluye el esquema de su funcionamiento, mientras que los detalles de su forma de operar se pueden consultar en la sección 2.2.2 del Capítulo 2. De esta forma, la nube original de puntos LiDAR, cuya densidad es de 8.7 puntos/m², ha sido reducida hasta alcanzar nubes de puntos con 4, 2 y 1 puntos/m².




Figura 3.5: Esquema de funcionamiento del método de reducción PpC.

3.2.5 Obtención del Modelo Digital del Terreno

El filtrado de los puntos LiDAR para obtener los puntos terreno se hizo mediante el algoritmo **DTMofLabTe**. Se trata de un filtro híbrido que combina los principios de los filtros de densificación con un proceso de depurado. Como ya se mencionó en Capítulo 1, las principales diferencias que presenta con los filtros desarrollados hasta el momento son: 1) está formado por un conjunto de funciones implementadas en el software R que operan secuencialmente (el *output* de la primera es el *input* de la segunda ...) pero con capacidad para funcionar de manera independiente, lo que haría posible su integración a nivel individual como complemento de otros algoritmos de filtrado; 2) se define y emplea la variable penetrabilidad, que junto con las variables elevación y pendiente se usarán en diferentes puntos del proceso de filtrado; 3) como paso previo a la selección de los puntos semilla, se incluye un proceso de depurado de la nube de puntos original orientado a la eliminación de los puntos que pertenecen a edificaciones permitiendo disminuir el tamaño de ventana en la selección de los puntos semilla a la vez que se disminuyen los errores de comisión en dicha selección; 4) los puntos semilla se seleccionan mediante un novedoso método que emplea una ventana móvil con solape longitudinal entre ventanas y transversal entre "pasadas".

Como primer paso fue necesario fijar el valor de los diferentes parámetros. Los valores de los parámetros fijos se establecieron en base a la experiencia práctica de la autora, donde $np=10$; $LO=FO=0.8$; $C_R=1.5*PS$; y $I=3$. Por otro lado, los valores de los parámetros variables se ajustaron en dos fases, tal y como se describe en el apartado 1.3.1 del Capítulo 1. La combinación de parámetros seleccionada fue aquella que minimizaba los errores (Q95%) considerando las nubes de puntos con diferentes densidades (combinación de parámetros única). De esta forma, los valores de los parámetros variables para todas las nubes de puntos fueron: $C=18$, $C_S=6$ y $\delta_h=0.4$. La resolución de los MDT finales se estableció como $1.5 * point\ spacing$ (la justificación de esta decisión se incluye en el apartado 3.2.6).

Una vez creados los MDT para cada una de las densidades de puntos se evaluó su precisión. El método más extendido para evaluar

la precisión altimétrica de un MDT consiste en comparar los valores de elevación de un conjunto de puntos de control, *verdad terreno* (PC_R), con la elevación del MDT en dichos puntos. Estos puntos deben ser como mínimo tres veces más precisos que los datos empleados para generar los modelos a validar (Höhle y Höhle, 2009). En este caso, la precisión vertical de los datos LiDAR es de aproximadamente 10 cm (Tabla 3.8), lo que implica que los puntos de control deben tener una precisión de $\simeq 3$ cm, condición que cumplen los puntos de control descritos en el apartado 3.2.2. A continuación, la diferencia de elevación entre los PC_R y el MDT se emplea para calcular valores estadísticos que representarán la precisión altimétrica de los modelos. En este caso se usan los estadísticos propuestos por Höhle y Höhle (2009), el cuantil del 68.3% y el del 95%. Los resultados de la validación en función de la densidad de puntos se incluyen en la Tabla 3.2. Adicionalmente, en la Figura 3.6 se representan dichos estadísticos en función de la cobertura.

Tabla 3.2: Precisión de los MDT en función de la densidad de puntos.

	Densidad de puntos (ptos/m ²)			
	8	4	2	1
Q68.3% (m)	0.65	0.64	0.67	0.67
Q95% (m)	1.02	1.02	1.07	1.10

Los resultados de la validación altimétrica de los MDT muestran que la precisión de los modelos varía entre los 64 cm y 67 cm considerando el estadístico Q68.3% y entre 1.02 m y 1.10 m en relación al Q95%. La primera observación sobre estos resultados es la escasa variación de la precisión en relación a la densidad de puntos (considerando la densidad de puntos máxima y mínima, 2 cm en relación al Q68.3% y 8 cm en relación al Q95% - Tabla 3.2). Para profundizar más en las circunstancias que originan estas diferencias mínimas, se analizan las precisiones en función de las coberturas.

En la Figura 3.6 también se observa como no existen diferencias de precisión evidentes entre coberturas al disminuir la densidad de puntos. Esta circunstancia puede tener varias explicaciones posibles. En primer lugar, la fortaleza del algoritmo **DTMofLabTe** reside en

obtener buenos resultados en zonas con presencia de edificaciones gracias a la efectividad del proceso de depurado. La precisión (Q68.3%) que se obtiene en estas zonas es de $\simeq 20$ cm. Así, se repiten los resultados obtenidos en el Capítulo 2, donde las zonas próximas a edificaciones presentan las mejores precisiones. Si se tiene en cuenta que en el área de estudio las construcciones se localizan en zonas donde la orografía no es compleja, que la precisión de los datos LiDAR es $\simeq 10$ cm y el error debido al método de interpolación, poco se podría mejorar la precisión de $\simeq 20$ cm en estas zonas por mucho que aumente la densidad de puntos.




Figura 3.6: Precisión de los MDT en función de la densidad y la cobertura. Las líneas discontinuas representan el cuantil del 68.3% y las continuas el cuantil del 95%.

más, existe la posibilidad de que un aumento de la densidad de puntos en estas zonas repercuta negativamente en la representación del terreno pues la cantidad de puntos que sí podría aumentar son los que impactan en la vegetación baja o arbustiva. Las zonas de matorral y arbolado llegan a mejorar $\simeq 30$ cm su precisión si se comparan los MDT obtenidos a partir de las nubes con mayor y menor densidad. Sin embargo, la cantidad de PC_R en estas zonas solo representa el 15% de los puntos de control disponibles lo que reduce su peso en el cálculo de la precisión general de los modelos. Finalmente, si bien la pendiente es uno de los factores que más influye en la precisión de los modelos, no se analizó el efecto de este factor debido a que algunas clases de cobertura no presentaban datos en todos los niveles de pendiente tal y como se constata en la Figura 3.3b (tomando como referencia los niveles fijados en el Capítulo 2).

Por otro lado, la mayor cantidad de puntos de control se encuentran en zonas de vegetación mixta donde la pendiente del terreno es elevada. Estas zonas se caracterizan por vegetación muy densa que dificulta que el rayo láser llegue al terreno. Debido a esta situación, por más que la densidad de puntos aumente no se espera un aumento considerable del número de puntos terreno en estas zonas, y es

3.2.6 Variables LiDAR y especificaciones de cálculo

El objetivo de este estudio es desarrollar un proceso automático de clasificación que permita identificar 8 tipos de cobertura del suelo (su descripción se incluye en el apartado 3.2.7) tomando los datos LiDAR como única fuente de información. Las características de estas coberturas hacen necesario considerar variables que van más allá de las tradicionalmente empleadas. Dichas variables se calculan en base a tres *unidades de análisis*: punto, cilindro y vóxel. En el caso de que la unidad de análisis sea el punto, el cálculo de la variable se realizará sin tener en cuenta la relación del punto que está siendo analizado con los puntos vecinos. En el caso del cilindro, éste tiene un radio fijo (r)³, se encuentra centrado en el punto de análisis (P_i) y todos o un conjunto de los puntos contenidos en su interior (v_P) son empleados para el cálculo de la variable cuyo valor será asignado al punto central. Finalmente, caso de que la unidad de análisis sea un vóxel, la cara inferior de dicho vóxel coincidirá tanto en tamaño como en localización con las celdas de los ráster empleados en este proceso. Así, el valor de la variable, el cual se le asignará al píxel correspondiente, se obtendrá teniendo en cuenta la distribución de todos o un conjunto de puntos contenidos en su interior (v_P). Para trasladar estos valores a los objetos (resultado de la segmentación) se hará por medio del cuantil del 68.3% a partir de los píxeles contenidos en cada objeto.

De esta forma, durante el proceso de cálculo los valores de las variables pueden ser asignados a un punto o a un píxel (*elementos de asignación*) (Figura 3.7). En este último caso, el formato final de las variables será un ráster. La resolución de este ráster, y por tanto el tamaño de la base del vóxel, se fija dependiendo de la variable. Se diferencian dos casos. Por un lado, si la variable representa el valor máximo, mínimo o los cuantiles del 68.3% o 95% de un conjunto de puntos, el tamaño del píxel se establece en base a la recomendación

³La magnitud del radio del cilindro se calcula en base a la densidad original de la nube de puntos (D) y al número de puntos deseado en el cilindro (N), así como también se considera la ecuación del área del círculo. Por tanto, $r = \sqrt{\frac{N}{\pi \cdot D}}$. Tras realizar varias pruebas, $N=15$.

de resolución=*point spacing* realizada por [Salleh et al. \(2015\)](#). Sin embargo, fue necesario aplicar un coeficiente a esta relación debido a que la densidad de puntos no es homogénea en toda la zona. Esta circunstancia ocasiona la existencia de píxeles sin datos en zonas donde la densidad de puntos es muy inferior a la densidad media ponderada que se toma como referencia para calcular el *point spacing*. Así, la resolución de los ráster en estos casos es $\text{resolución} = r_1 = 1.5 * \text{point spacing}$. Por otro lado, si la variable es el resultado de un ratio o de un conjunto de puntos, según [Salleh et al. \(2015\)](#) la resolución en estos casos debe ser como mínimo 4 veces la media del *point spacing* ($\text{resolución} = r_2 = 4 * \text{point spacing}$).

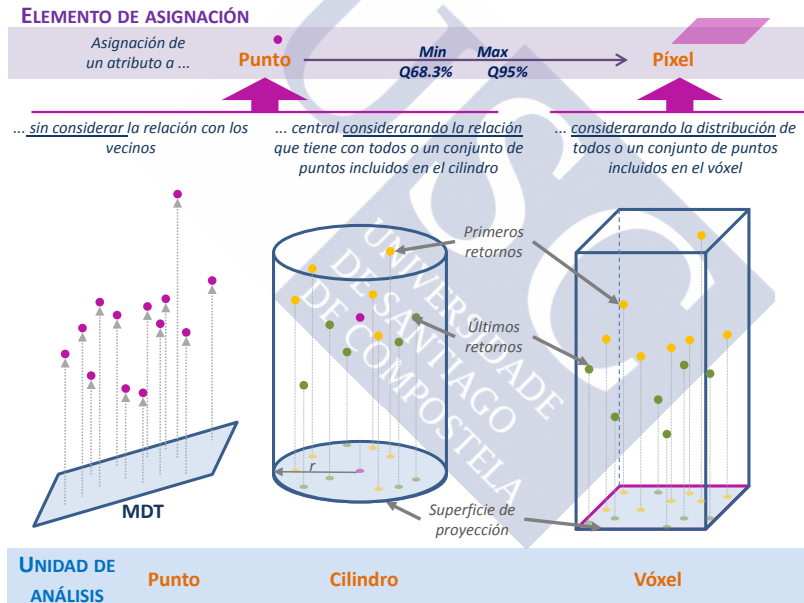


Figura 3.7: Unidades de análisis para el cálculo de variables y elementos de asignación.

Por medio del proceso anterior y teniendo en cuenta que el vector inicial de atributos es $f v = [X, Y, Z, I'', nR, Z_{MDT}]$, se calcularán 72 variables. Dichas variables pueden agruparse en 5 categorías: elevación/altura, intensidad, retornos, rugosidad y textura. A continuación se describe cada una de ellas.

3.2.6.1 En base a la elevación/altura

La elevación de los datos LiDAR es el atributo más usado para la obtención de variables y el de mayor utilidad en los procesos de clasificación. A partir de este atributo se calculan las siguientes variables (un resumen de estas variables se incluye en la Tabla 3.3):

Tabla 3.3: Variables en base a la elevación/altura.

Variable	Atributos	Escala cálculo	Elemento asignación	Res.	Cita
Δz	z, z_{MDT}	P	P	—	Kim y Sohn (2013), Guo et al. (2015), Li et al. (2016)
nMS_{PR}	$\Delta z, nR$	V	Pi	r_1	Im et al. (2008b),
nMS_{UR}	$\Delta z, nR$	V	Pi	r_1	Höfle et al. (2012),
nM_{V_m}	Δz	V	Pi	r_1	Teo y Huang (2016)
Rg_z	z	C	$P \rightarrow Pi$	r_1	Guo et al. (2011), Li et al. (2017)
$RDB_{1-8, RD}$	Δz	V	Pi	r_2	Hecht et al. (2008), García et al. (2011), Alonso-Benito et al. (2016)
$Q_X - \Delta z$	Δz	V	Pi	r_2	Kramer et al. (2016), Su et al. (2016), Ruiz et al. (2018)
CA	z	V	Pi	r_2	Antonarakis et al. (2008)
CC	z	V	Pi	r_2	Antonarakis et al. (2008)

Atributos: z -elevación, I' -intensidad corregida, nR -número de retorno, Δz -altura; **escala de cálculo:** P-punto, C-cilindro, V-vóxel; **elemento de asignación:** P-punto, Pi-píxel; **resolución:** $r_1=1.5*PointSpacing$ y $r_2=4*PointSpacing$.

0 Altura con referencia al terreno (Δz). Esta variable representa la altura de cada punto ($P_i=x_i, y_i, z_i$) con respecto al terreno. Se obtiene como resultado de restarle a la elevación de cada punto (z_i) el valor del terreno en dicho punto (z_{MDT}) (en el apartado 3.2.5 se describe el método empleado para la obtención del MDT). Esta es la única variable que se calcula a nivel punto sin necesidad de recurrir a los vecinos. Así, el valor de altura se asigna a cada punto. En la mayoría de estudios de clasificación que utilizan datos LiDAR como datos de entrada, esta variable es calculada pues se considera de gran utilidad para diferenciar edificaciones y/o zonas arboladas de vías de comunicación o zonas dedicadas a cultivos (Kim y Sohn, 2013, Niemeyer et al., 2014, Li et al., 2016).

1-3 Modelo Digital de Superficie normalizado a partir del primer (nMS_{PR}) y último retorno (nMS_{UR}); y Modelo de Vegetación media normalizado (nM_{V_m}). Estas variables representan el valor máximo de altura (Δz) de los puntos de primer

retorno (nMS_{PR}) y mínimo de la altura de los puntos que no son primer retorno (nMS_{UR}) incluidos en un vóxel, así como los valores máximos de altura considerando únicamente aquellos puntos con altura inferior a 4 m (nM_{V_m}). Los valores obtenidos son asignados a los píxeles correspondientes. En el caso de las variables nMS_{PR} y nM_{V_m} se corrigen los píxeles sin datos (valor NA) aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que únicamente se verán afectados dichos píxeles. Para la variable nMS_{UR} , a los píxeles sin datos, en primer lugar se les asigna el valor mínimo de altura de los puntos de primer retorno y en segundo lugar, se aplica un filtro de mediana como en el caso anterior para asignarle un valor de altura a aquellos píxeles con valor NA. La variable nMS_{PR} se empleó en múltiples estudios para diferenciar las coberturas vinculadas con el terreno de aquellas relacionadas con los objetos (Buján et al., 2012, Zhou, 2013, Teo y Huang, 2016). La Figura 3.8 incluye ejemplos de estas variables en formato ráster.

4 Rango de elevación (Rg_z). Esta variable hace referencia a la diferencia de elevación entre el punto LiDAR objeto de análisis ($P_i = x_i, y_i, z_i$) y el punto con menor elevación en una vecindad definida por un cilindro centrado en P_i ($z_{min} \in v_p$). El valor resultante se le asigna al punto central del cilindro. Una vez realizado este cálculo para todos los puntos, el valor de esta variable es trasladada al píxel correspondiente calculando el cuantil del 68.3% de la variable Rg_z . En los contornos de las construcciones se dan elevadas diferencias de elevación debido a la ocurrencia de retornos múltiples, circunstancia que puede ocasionar errores durante la fase de asignación de la clasificación. Para mitigar este efecto, Huang et al. (2008) aplicó una operación morfológica de apertura. En este estudio, también se adoptó esta solución y se aplicó una operación de apertura al ráster que contiene los valores del rango de elevación. Según Chehata et al. (2009) y Guo et al. (2011) esta variable puede resultar de utilidad para diferenciar las coberturas vinculadas al terreno, como los prados o vías de comunicación, de aquellas que representan objetos, evitando así la creación de un MDT. La Figura 3.8 incluye un ejemplo de esta variable en formato ráster.

5-13 Intervalos de densidad (*Relative Density Bins* - RDB₁ ($\Delta z \leq 1m$), RDB₂ $\Delta z \in (1-2m]$, RDB₃ $\Delta z \in (2-3m]$, RDB₄ $\Delta z \in (3-4m]$,

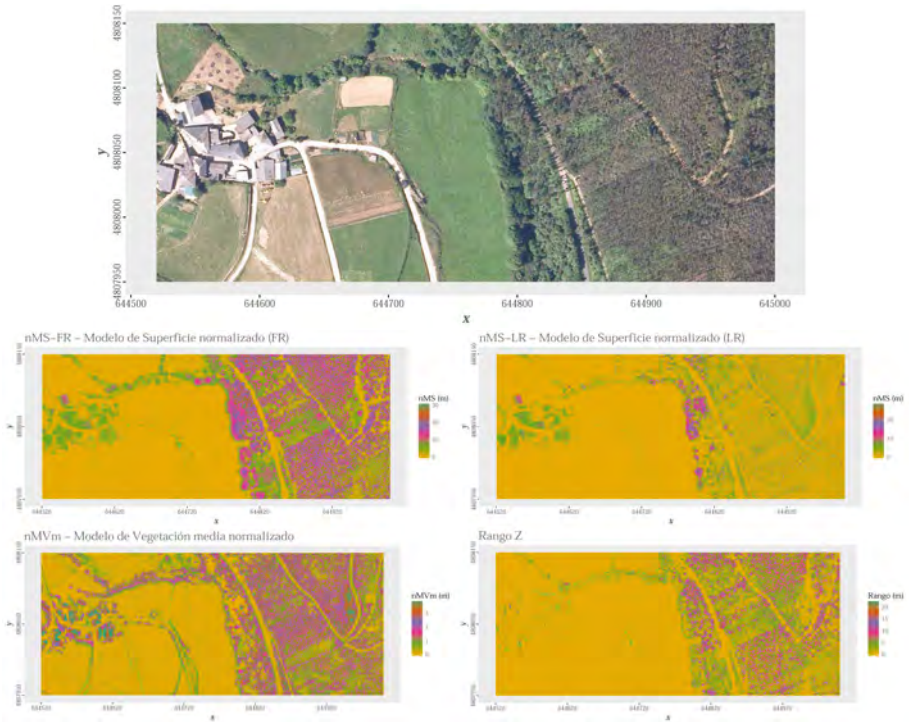


Figura 3.8: Ejemplos de las variables en base a la elevación/altura: Ortoimagen, nMS_{FR} , nMS_{UR} , nM_{V_m} y Rg_z , respectivamente. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

$RDB_5 \Delta z \in (4-6m]$, $RDB_6 \Delta z \in (6-8m]$, $RDB_7 \Delta z \in (8-12m]$, $RDB_8 \Delta z > 12m$ y la densidad relativa (RD)). Este grupo de variables representa por intervalos de altura la densidad de puntos no-terreno incluidos en un vóxel. Para su cálculo, en primer lugar se consideraron como puntos no-terreno aquellos cuya altura es mayor de 70 cm. A continuación se definieron 8 intervalos de altura: cuatro rangos de 1 m (entre 0 y 4 m - RDB_1 a RDB_4)⁴, dos rangos de 2 m (entre 4 y 8 m - RDB_5 a RDB_6), un rango de 4 m (entre 8 y 12 m - RDB_7) y un último rango con los puntos con altura mayor de 12 m (RDB_8). Así, la densidad relativa para cada rango se calculó como el cociente entre el número de puntos no-terreno en cada intervalo y el número total de puntos no-terreno

⁴En el caso de la variable RDB_1 se consideran aquellos puntos con una altura entre 0.7 m y 1 m.

incluidos en el vóxel. Este tipo de variables se emplearon para identificar tipos de combustible forestal según la clasificación Prometheus ya que proporcionan información sobre la estructura vertical de la vegetación (García et al., 2011, Alonso-Benito et al., 2016). Finalmente, la densidad relativa acumulada (RD) se calculó como el cociente entre el número de puntos no-terreno y el número total de puntos incluidos en el vóxel. Esta última variable fue empleada por Hecht et al. (2008) para diferenciar vegetación arbustiva, coníferas y caducifolias. La Figura 3.9 incluye ejemplos de estas variables en formato ráster.

14-20 Cuantiles de altura ($Q_{1-\Delta z}, Q_{5-\Delta z}, Q_{10-\Delta z}, Q_{25-\Delta z}, Q_{50-\Delta z}, Q_{75-\Delta z}$ y $Q_{90-\Delta z}$). Estas variables representan la altura máxima del X% de los puntos incluidos en un vóxel y suelen emplearse en análisis de regresión para predecir la estructura de la vegetación (González-Ferreiro et al., 2017). Para el cálculo de dichas variables generalmente se fija un límite inferior (MHT - *minimum height threshold*), de forma que en cada vóxel se considerarán solo aquellos puntos cuya altura sea superior a MHT. En este caso $MHT = 0.7$ m. Los valores obtenidos son asignados a los píxeles correspondientes. La Figura 3.10 incluye ejemplos de estas variables en formato ráster.

21-22 Coeficiente de asimetría (CA) y curtosis (CC). El coeficiente de asimetría (CA) permite comprobar si los valores de elevación de los puntos se distribuyen uniformemente alrededor de la media de la elevación de dichos puntos. La asimetría presenta tres estados: asimetría positiva ($CA > 0 \rightarrow A+$) cuando la mayoría de los puntos presentan una elevación superior a la media; asimetría negativa ($CA < 0 \rightarrow A-$) cuando la mayoría de los valores de elevación se encuentran por debajo de la media; y simétrica ($CA \approx 0 \rightarrow S$) cuando los valores de elevación se distribuyen en la misma proporción a ambos lados de la media (Ecuación 3.2). El coeficiente de curtosis (CC) determina el grado de concentración que presentan los valores de elevación en la región central de la distribución, es decir, cuán escarpada o achatada es una distribución. Es posible distinguir entre una gran concentración de valores de elevación alrededor de la media ($CC > 0 \rightarrow C+$); una concentración normal ($CC \approx 0 \rightarrow Cn$); o una baja

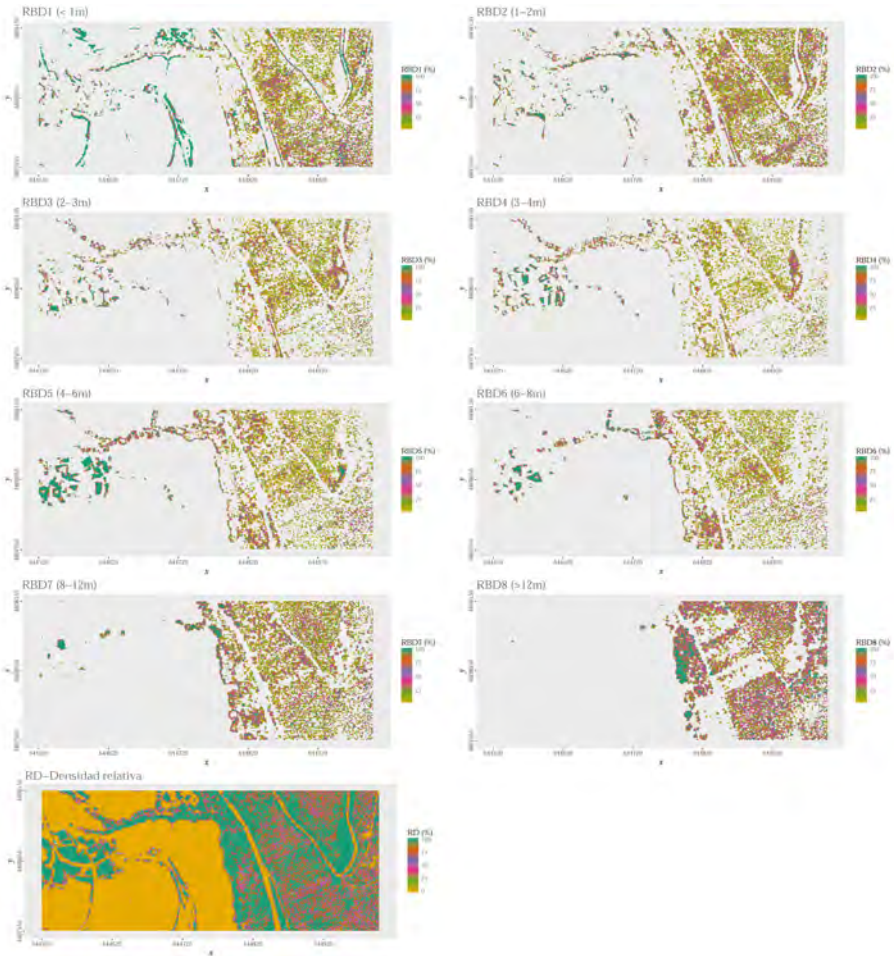


Figura 3.9: Ejemplos de las variables en base a la elevación/altura: Intervalos de densidad. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

concentración ($CC < 0 \rightarrow C^-$) (Ecuación 3.3).

$$CA = \frac{\sum_{i=1}^n (z_i - \bar{z})^3 / n}{(\sum_{i=1}^n (z_i - \bar{z})^2 / n)^{3/2}} \quad (3.2)$$




Figura 3.10: Ejemplos de las variables en base a la elevación/altura: Cuantiles de altura. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

$$CC = \frac{\sum_{i=1}^n (z_i - \bar{z})^4 / n}{(\sum_{i=1}^n (z_i - \bar{z})^2 / n)^2} - 3 \quad (3.3)$$

Estas medidas de forma proporcionan un resumen de la estructura de la vegetación en base a la distribución vertical de los puntos, motivo por el que fueron empleadas por [Donoghue et al. \(2007\)](#), [Jensen et al. \(2008\)](#), [García et al. \(2010\)](#). Concretamente, [Donoghue et al. \(2007\)](#) hipotetizó sobre que el coeficiente de asimetría podría ser de gran utilidad para diferenciar especies forestales debido a que los retornos láser pueden verse afectados por la forma y estructura de la vegetación y por su grado de densidad. Por otro lado, [Antonarakis et al. \(2008\)](#) emplearon estas variables para diferenciar masas forestales naturales de

plantaciones forestales. Tal y como indicaron estos autores, los valores de elevación de los puntos que pertenecen al terreno pueden introducir ruido en estas medidas. Para mitigar este efecto, Antonarakis et al. (2008) no consideraron los puntos terreno a la hora de calcular CA y CC . Siguiendo esta idea, se analizó el histograma de frecuencias de los valores de elevación de una zona arbolada sin vegetación arbustiva (Figura 3.11) y de una zona arbolada con vegetación arbustiva (Figura 3.12) considerando y sin considerar los mínimos locales en el cálculo de CA y CC . Dichas operaciones se realizaron a nivel vóxel y se consideraron mínimos locales en el vóxel aquellos valores $< \min(z_{vp}) + 0.7$. Si se comparan los valores de asimetría y curtosis de las Figuras 3.11 y 3.12 considerando todos los puntos, se comprueba que realidades muy distintas presentan valores de CA y CC similares, mientras que si no se consideran los mínimos locales, las medidas de asimetría y curtosis de las zonas arboladas sin vegetación arbustiva cambian de signo (Figura 3.11) mientras que las zonas con varios estratos de vegetación permanecen constantes (Figura 3.12).

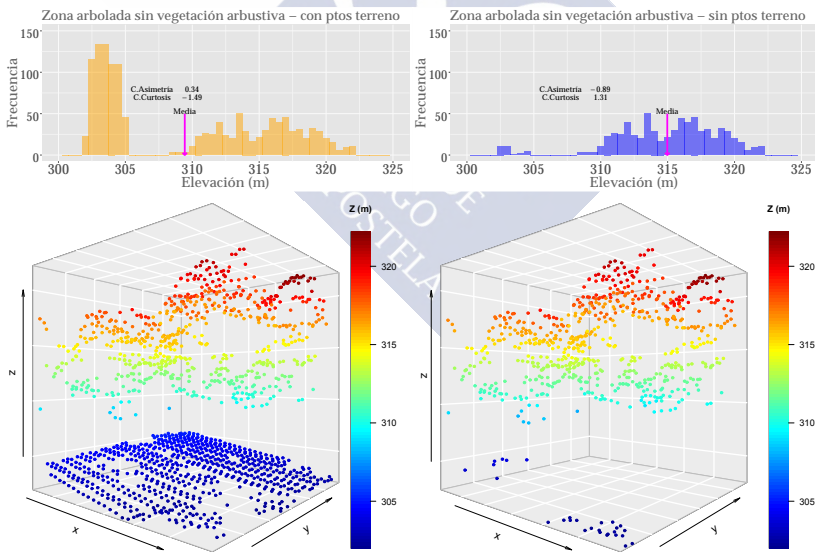


Figura 3.11: Características de las zonas arboladas sin vegetación arbustiva. Histogramas de frecuencias de los valores de elevación con y sin puntos terreno y representación 3D.

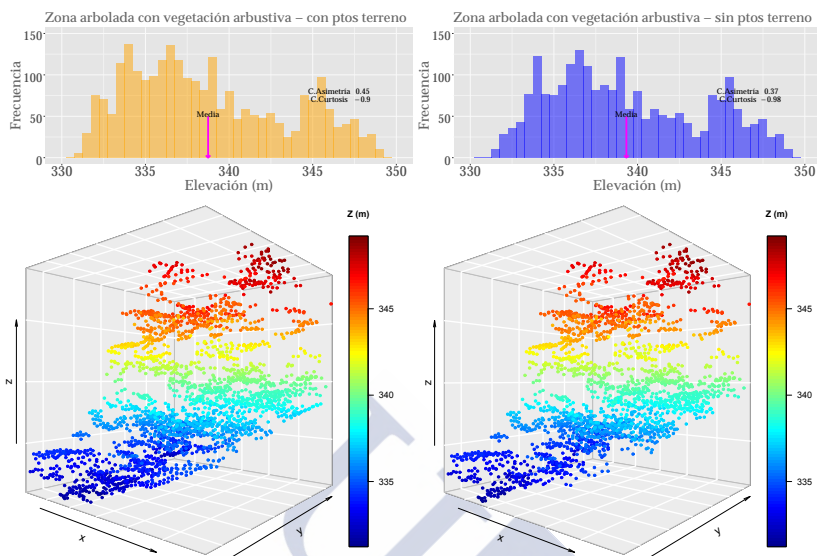


Figura 3.12: Características de las zonas arboladas con vegetación arbustiva. Histogramas de frecuencias de los valores de elevación con y sin puntos terreno y representación 3D.

En base al análisis anterior, las medidas de forma CA y CC se calcularon a nivel vóxel sin tener en cuenta los mínimos locales. Finalmente, los valores obtenidos son asignados a los píxeles correspondientes. La Figura 3.13 incluye ejemplos reclasificados de estas variables en formato ráster (en los procesos de clasificación se tendrán en cuenta estas variables sin reclasificar). En esta figura, la clase $A+$ representa los píxeles donde CA es mayor de 0.2; S donde los píxeles toman valores de CA entre 0.2 y -0.2; y $A-$ donde la asimetría es negativa, $CA < -0.2$. De forma análoga, $C+$ representa las zonas donde el $CC > 0.2$; Cn donde la curtosis es normal ($-0.2 \leq CC \leq 0.2$); y $C-$ donde la curtosis es inferior a -0.2.

3.2.6.2 En base a la intensidad

Tal y como se mencionó previamente, el empleo de la intensidad en procesos de clasificación ha aumentado considerablemente en la




Figura 3.13: Ejemplos de las variables en base a la elevación/altura: Coeficiente de asimetría y curtosis. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

última década (Yan et al., 2015). Concretamente, estudios previos han mostrado el potencial de esta información en la identificación de vías pavimentadas o para diferenciar grandes especies forestales (coníferas vs. frondosas) (Brennan y Webster, 2006, Matikainen et al., 2017). Así, a partir de la intensidad corregida (I'') se han definido las siguientes variables (un resumen de estas variables se incluye en la Tabla 3.4):

Tabla 3.4: Variables en base a la intensidad.

Variable	Atributos	Escala cálculo	Elemento asignación	Res. Cita
I''_{PR}	I'' , nR	V	Pi	r_1 Antonarakis et al. (2008), Guo et al. (2015), Teo y Huang (2016)
I''_{UR}	I'' , nR	V	Pi	r_1 Zhou (2013)
I''_{Vm}	I''	V	Pi	r_1 —
I''_D	I'' , nR	V	Pi	r_2 Antonarakis et al. (2008)
$Std_{I''}$	I''	V	Pi	r_2 Niemeier et al. (2014), Matikainen et al. (2017)
$CV_{I''}$	I''	V	Pi	r_2 —
$Q_{X\% - I''}$	I''	V	Pi	r_2 Matikainen et al. (2017)
$DWCRS$	I''	V	Pi	r_2 García et al. (2010)

Atributos: z-elevación, I'' -intensidad corregida, nR-número de retorno, Δz -altura; **escala de cálculo:** P-punto, C-cilindro, V-vóxel; **elemento de asignación:** P-punto, Pi-píxel; **resolución:** $r_1=1.5*PointSpacing$ y $r_2=4*PointSpacing$.

23-25 **Intensidad corregida empleando los primeros retornos (I''_{PR}), últimos retornos (I''_{UR}) y puntos con vegetación media (I''_{Vm}).** Aunque una serie de autores recomendaron en sus estudios el empleo conjunto de todos los retornos para crear la imagen de intensidad (Solberg et al., 2008, Hopkinson y Chasmer, 2009), en este caso dicha opción ha sido descartada pues se considera, al igual que en otros estudios previos (Donoghue et al., 2007, Buján et al., 2013b), que el efecto de píxeles mixtos, fundamentalmente en zonas arboladas, puede

afectar al proceso de clasificación de coberturas del suelo. En muchos casos, el problema de los píxeles mixtos se origina por la mezcla de valores de intensidad de puntos que pertenecen a diferentes coberturas y comparten la misma localización geográfica (píxel). Así, en este estudio se diferencia entre la intensidad de los puntos de primer retorno y del resto, de forma que las variables representan el valor del cuantil del 68.3% de la intensidad corregida de los puntos que son primer retorno (I''_{PR}) y que no lo son (I''_{UR}) incluidos en un vóxel. Por otro lado, a partir de la intensidad de los puntos con altura inferior a 4 m se crea la variable I''_{Vm} . Los valores que se obtienen son asignados a los píxeles correspondientes. Para las variables I''_{PR} y I''_{Vm} se corrigen los píxeles sin datos (valor NA) aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que únicamente se verán afectados dichos píxeles. Para la variable I''_{UR} , a los píxeles sin datos, en primer lugar se les asigna el valor de intensidad de los puntos primer retorno y en segundo lugar, se aplica un filtro de mediana como en el caso anterior para asignarle un valor de intensidad a aquellos píxeles con valor NA. La Figura 3.14 incluye ejemplos de estas variables en formato ráster.

26 Diferencia de intensidades entre retornos (I''_D). Esta variable fue empleada por Antonarakis et al. (2008) para diferenciar zonas con gravilla de áreas sin vegetación y representa la diferencia de intensidad entre el valor máximo de los puntos de primer retorno y el mínimo de aquellos que no lo son (I''_D). En los casos donde sólo existan primeros retornos se extraerá el valor mínimo de intensidad a partir de éstos. Este cálculo se realiza a nivel vóxel y los valores resultantes son asignados a los píxeles correspondientes. La capacidad de la tecnología LiDAR para representar no sólo la cobertura superficial sino también las que se encuentran bajo el arbolado, unido a que diferentes materiales presentan diferentes valores de intensidad, puede ser de utilidad para detectar la presencia de vegetación bajo arbolado. La Figura 3.14 incluye una muestra de esta variable en formato ráster.

27 Desviación estándar de la intensidad ($Std_{I''}$). Esta variable representa la desviación estándar de la intensidad corregida de los puntos incluidos en un vóxel. Los valores resultantes son asignados a cada píxel. Los píxeles sin datos (valor NA) se corrigen aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de

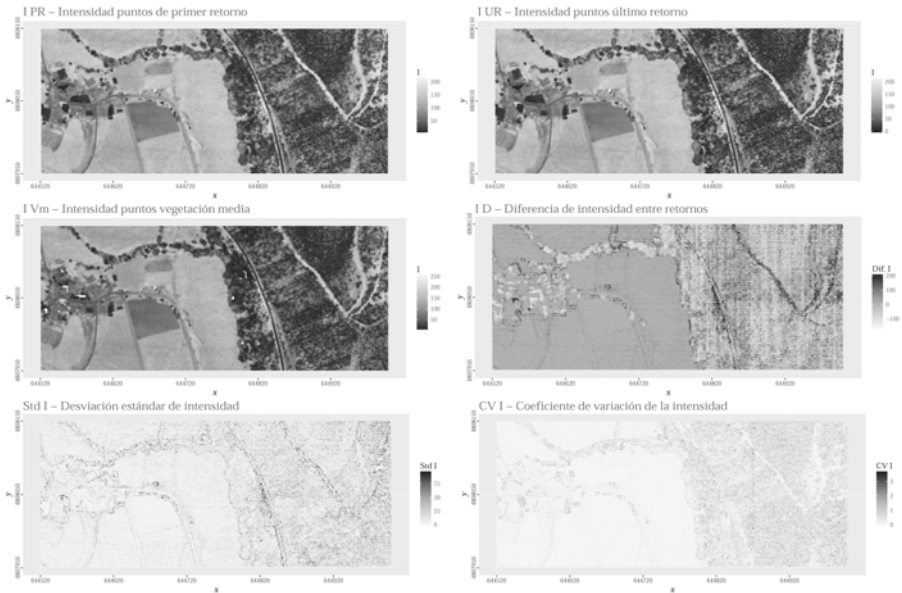


Figura 3.14: Ejemplos de las variables en base a la intensidad: I''_{PR} , I''_{UR} , I''_{Vm} , I''_D , $Std_{I''}$ y $CV_{I''}$. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

forma sólo se modificará el valor de los píxeles NA. Esta variable fue calculada por [Matikainen et al. \(2017\)](#), sin embargo tras analizar el nivel de importancia de cada variable, dicha variable no resultó ser determinante para la discriminación de las coberturas que dichos investigadores consideraron en su estudio. La Figura 3.14 incluye una muestra de esta variable en formato ráster.

28 Coeficiente de variación de la intensidad ($CV_{I''}$). El coeficiente de variación de la intensidad representa la variabilidad de la intensidad tanto del terreno como de los objetos situados sobre él. [Jutzi y Gross \(2010\)](#) y [Mesas-Carrascosa et al. \(2012\)](#) emplearon esta variable para analizar la efectividad de la normalización de la intensidad y comprobaron como zonas arboladas presentan valores de esta variable mucho mayores que el resto de coberturas. En este caso, el cálculo de $CV_{I''}$ se realizó a partir de la Ecuación 3.4 y los valores de intensidad de todos los puntos incluidos en un vóxel. Finalmente, los valores obtenidos se le asignan a los píxeles correspondientes. La Figura 3.14 incluye una

muestra de esta variable en formato ráster.

$$CV_{I''} = \frac{\sigma(I'')}{\mu(I'')} \quad (3.4)$$

29-33 Cuantiles de intensidad ($Q_{10-I''}$, $Q_{25-I''}$, $Q_{50-I''}$, $Q_{75-I''}$ y $Q_{90-I''}$). Estas variables representan la intensidad máxima del X% de los puntos incluidos en un vóxel. Para ello se consideraron todos los retornos y el valor resultante se le asignó a los píxeles correspondientes. A diferencia de las variables homólogas de altura (14 - 20), en este caso no se fijó un umbral mínimo de intensidad. [Matikainen et al. \(2017\)](#) demostró que pueden ser de utilidad para diferenciar entre zonas asfaltadas, áreas rocosas y vegetación baja. La Figura 3.15 incluye una muestra de esta variable en formato ráster.

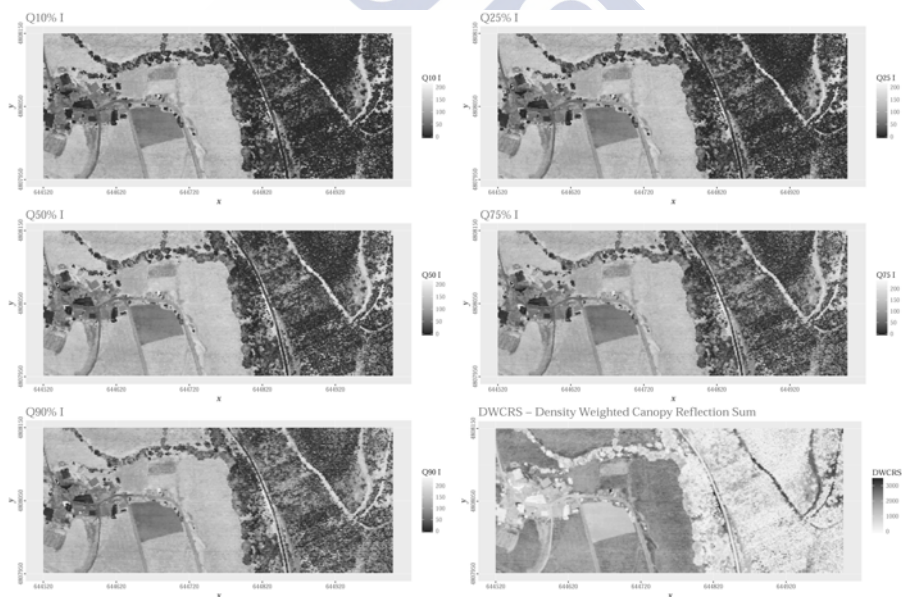


Figura 3.15: Ejemplos de las variables en base a la intensidad: Cuantiles de intensidad. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

34 *Density Weighted Canopy Reflection Sum (DWCRS)*. Esta variable fue propuesta por [García et al. \(2010\)](#) como una medida

de la densidad de la vegetación. Su cálculo se basa en sumar los valores de intensidad de todos los puntos contenidos en un vóxel y corrigiendo posteriormente este valor por la densidad de puntos. Esta corrección se basa en multiplicar el sumatorio de intensidades por el cociente de la densidad de puntos media del área de estudio y la densidad de puntos en el vóxel (Ecuación 3.5). El valor resultante de este cálculo se le asigna a los píxeles correspondientes. La Figura 3.15 incluye una muestra de esta variable en formato ráster.

$$DWCRS = \sum_{i=1}^n I'' \cdot \frac{\bar{D}}{D_{vp}} \quad (3.5)$$

3.2.6.3 En base a los retornos

Las variables incluidas en esta categoría (resumen de variables en la Tabla 3.5) surgen del empleo del atributo nR (número de retorno) de los datos LiDAR. Dicho atributo hace referencia a una de las características de los sensores LiDAR, la capacidad de registrar varios puntos, denominados retornos, a partir de un único pulso láser. En función del número y orden en que son registrados dichos puntos por el sensor, se habla de únicos (P_{SR}), primeros (P_{PR}), intermedios (P_{iR}) y últimos retornos (P_{UR}). Así, aquellas superficies permeables, por ejemplo la vegetación, presentará pulsos con más de un retorno mientras que las superficies opacas como las cubiertas de las edificaciones o el suelo desnudo, presentarán un único retorno. Así, la mayoría de los primeros e intermedios retornos serán característicos de zonas con vegetación, mientras que la mayoría de retornos únicos se encontrarán en las cubiertas de las edificaciones. Finalmente, el suelo desnudo será representado tanto por únicos como por últimos retornos (Kim, 2015). En este estudio, la cantidad total de puntos incluidos en un vóxel se denomina N_{vp} , y la cantidad de únicos, primeros, intermedios y últimos retornos viene dado por N_{SR} , N_{PR} , N_{iR} y N_{UR} , respectivamente. Las variables que serán calculadas teniendo en cuenta esta información son las siguientes:

Tabla 3.5: Variables en base a los retornos.

Variable	Atributos	Escala cálculo	Elemento asignación	Res.	Cita
MS_D	z, nR	V	Pi	r ₁	Chehata et al. (2009) , Guan et al. (2013) , Guo et al. (2015) , Matikainen et al. (2017)
nD $_{\Delta z}$	Δz , nR	V	Pi	r ₂	Arefi et al. (2003) , Huang et al. (2008) , Guan et al. (2013)
PNT	Δz , nR	V	Pi	r ₂	Kim y Sohn (2013) , Li et al. (2016, 2017)
RR	nR	V	Pi	r ₂	Höfe et al. (2012) , Teo y Huang (2016)
RT	Δz , nR	V	Pi	r ₂	Guo et al. (2015) , Kim (2015)
RV	Δz , nR	V	Pi	r ₂	
RE	Δz , nR	V	Pi	r ₂	

Atributos: z-elevación, I¹-intensidad corregida, nR-número de retorno, Δz -altura; **escala de cálculo:** P-punto, C-cilindro, V-vóxel; **elemento de asignación:** P-punto, Pi-píxel; **resolución:** r₁=1.5**PointSpacing* y r₂=4**PointSpacing*.

35 Diferencia de elevación entre retornos (MS_D). Esta variable representa la diferencia de elevación máxima de los puntos de primer y/o único retorno y la elevación mínima de los puntos intermedios, últimos y/o únicos retornos incluidos en un vóxel. Los valores que se obtienen son asignados a los píxeles correspondientes. El cálculo de esta variable se materializa restando al MS_{PR} el MS_{UR} . Para el cálculo de estos modelos se siguen los mismos pasos que para el cálculo de las variables n MS_{PR} (1) y n MS_{UR} (2), pero en lugar de emplear el atributo altura se utiliza la elevación. Esta variable representa el estado de penetrabilidad de una superficie, de forma que se espera que tome valor 0 en superficies opacas mientras que en zonas de vegetación su valor debería ser $\neq 0$. En base a este razonamiento, se tienen en cuenta los únicos retornos tanto en el minuendo como en el sustraendo pues de no ser así, aquellas celdas que solo presentan este tipo de puntos tendrían una diferencia de elevación > 0 en superficies opacas (en caso de que la ausencia de intermedios y últimos retornos se interpretase como valor 0), contradiciendo el supuesto anterior. Este mismo proceder se observó en el estudio realizado por [Li et al. \(2016\)](#). Se espera que esta información sea de utilidad para diferenciar zonas edificadas de superficies con vegetación ([Brennan y Webster, 2006](#), [Chehata et al., 2009](#), [Li et al., 2016](#)). La Figura 3.16 incluye una muestra de esta variable en formato ráster.

36 Diferencia normalizada de altura (nD $_{\Delta z}$). La diferencia

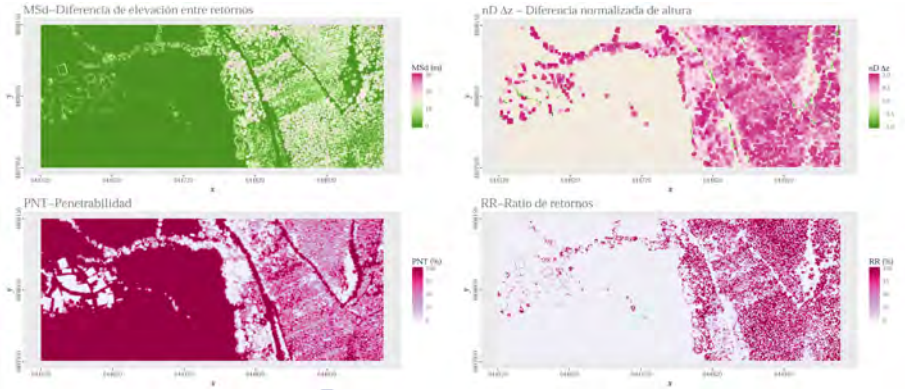


Figura 3.16: Ejemplos de las variables en base a los retornos: MS_D , $nD_{\Delta z}$, PNT y RR. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

normalizada de altura se trata de un índice de vegetación que se basa en datos LiDAR. Dicho índice fue definido por [Arefi et al. \(2003\)](#) como el cociente entre la diferencia de altura de los puntos de primer (valor máximo de Δz_{PR}) y último retorno (valor mínimo de Δz_{UR}) y la suma de dichos valores (Ecuación 3.6). El cálculo de esta variable se realiza a nivel vóxel y el valor resultante se le asigna al píxel que corresponda. Los contornos de las edificaciones, al igual que sucedía con el rango de elevación (Rg_z), presentan altos valores de esta variable (≈ 1) debido a las elevadas diferencias de altura. Nuevamente, para corregir los valores de $nD_{\Delta z}$ en estas zonas se aplicó una operación morfológica de apertura. Esta variable presenta un gran potencial para la identificación de zonas que presentan vegetación no muy densa ([Huang et al., 2008](#)). En la Figura 3.16 se incluye una muestra de esta variable en formato ráster donde se observa que las zonas con vegetación presentan los valores más altos ($nD_{\Delta z} \approx 1$) mientras que el terreno o las cubiertas de las edificaciones presentan valores próximos a 0.

$$nD_{\Delta z} = \frac{\Delta z_{PR} - \Delta z_{UR}}{\Delta z_{PR} + \Delta z_{UR}} \quad (3.6)$$

37 Penetrabilidad (PNT). En base a los ratios empleados por [Kim y Sohn \(2013\)](#) (*density ratio*) y [Li et al. \(2016, 2017\)](#) (*echo ratio*),

se definió la variable penetrabilidad (PNT). Su cálculo se realizó a nivel vóxel empleando la función PNT (Figura 1.5, apartado 1.2.3.2 del Capítulo 1) (Ecuación 3.7). En este caso, el tamaño de malla es igual a r_2 y el residual mínimo a partir del cual un punto es considerado objeto (δ) es 2.5 m. Los valores resultantes son asignados al píxel que corresponda. A continuación, se corrigen los píxeles sin datos (valor NA) aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que únicamente se verán afectados dichos píxeles. Esta variable representa el grado de permeabilidad de una superficie y puede ser de gran utilidad para diferenciar superficies impermeables (p. ej. cubiertas de edificaciones) de las que no lo son (p. ej. vegetación). De igual forma, también puede ser de ayuda para diferenciar entre tipos de vegetación. La Figura 3.16 incluye una muestra de esta variable en formato ráster.

$$PNT = \frac{N_{\Delta z < 2.5}}{N_{vP}} \cdot 100 \quad (3.7)$$

Para el cálculo de las 4 variables siguientes es necesario clasificar los puntos en simples (*SR*), primeros (*PR*), intermedios (*iR*) y últimos (*UR*) retornos. A diferencia de los datos usados por Höfle et al. (2012), los puntos LiDAR empleados aquí no contienen información sobre el pulso al que pertenece cada punto y únicamente registran el número de retorno de cada punto (hasta 4 retornos por pulso). Por este motivo no se pudo realizar la clasificación a nivel punto tal y como indica Höfle et al. (2012). Sin embargo, sí fue posible obtener una aproximación a nivel píxel de la cantidad de cada tipo de punto. Para ello se establecieron las siguientes reglas: 1) el número de *UR* en cada celda coincidirá con el número de puntos de aquel número de retorno mayoritario, es decir, si en una celda se localizan 2 puntos de 2º retorno, 1 punto de 3ª retorno y 1 punto de 4º retorno, la cantidad de *UR* será 2 (la mayoría es el número de puntos de 2º retorno); 2) la cantidad de *PR* es igual al de *UR* en cada celda; 3) los puntos cuyo número de retorno es 1 pertenecen a la clase *SR* o *PR*, conociendo *PR* se puede calcular *SR*; 4) la cantidad de *iR* se obtendrá restando al número total de puntos de cada celda el número de *SR*, *PR* y *UR*. Mediante este proceso se obtuvieron 4 ráster (resolución= r_2) donde cada celda almacena el número de *SR*, *PR*, *iR*

y UR , respectivamente. Estos ráster serán los datos de entrada de las ecuaciones que permiten calcular las 4 variables siguientes. Se asume que mediante esta aproximación pueden producirse errores debido al ángulo de escaneo, ocasionando que puntos de un mismo pulso se localicen en diferentes celdas, sin embargo dichos errores se asume que no influirán significativamente en el cálculo de las variables.

38 Ratio de retornos (RR). Esta variable fue propuesta por Höfle *et al.* (2012) como una opción más eficiente a los *echo ratios* que se basan en análisis a nivel punto en una vecindad local. El ratio entre retornos representa la proporción de PR e iR en relación a la cantidad de UR y SR (Ecuación 3.8). Este cálculo se realizó a nivel píxel. Teo y Huang (2016) indicaron que las regiones que presentan altos valores de este ratio tienen mayor probabilidad de contener vegetación, ya que dichas zonas se caracterizan por presentar un elevado número de PR e iR retornos, frente a aquellas que contienen edificaciones, donde predominan los SR . La Figura 3.16 incluye una muestra de esta variable en formato ráster.

$$RR = \frac{N_{PR} + N_{iR}}{N_{UR} + N_{SR}} \cdot 100 \quad (3.8)$$

39 Retorno terreno (RT). En zonas donde no hay vegetación, la superficie del terreno se encuentra representada por simples retornos (SR), mientras que en zonas de vegetación, cuando ésta no es muy densa, son los últimos retornos (UR) los que representan el terreno (Kim y Sohn, 2013). En base a estas premisas, Kim y Sohn (2010) definió el *ratio retorno terreno* (RT) como la proporción de SR y UR con respecto al total de puntos (Ecuación 3.9). Como resultado, el terreno presenta elevados valores de RT . Sin embargo, como se observa en la Figura 3.17 (RT -Retorno terreno), las cubiertas de las edificaciones presentan valores similares a los del terreno debido a la presencia de SR (recuadro amarillo en la Figura 3.17). Para mitigar este error, se volvió a calcular el ráster donde cada píxel almacena la cantidad de SR , pero en este caso únicamente se consideraron aquellos simples retornos cuya altura es inferior a 2 m (mínima altura que se considera tiene una construcción en el área de estudio). El resultado se incluye en la Figura 3.17 (RT -Retorno terreno con restricción de altura) donde se

comprueba que $RT \approx 0$ en las zonas edificadas. Este cálculo se realizó a nivel píxel. En los casos donde el elemento de asignación es un objeto, el valor de esta variable para cada objeto será la media de los valores de los píxeles incluidos en el interior de cada uno.

$$RT = \frac{N_{SR} + N_{UR}}{N_{vP}} \quad (3.9)$$

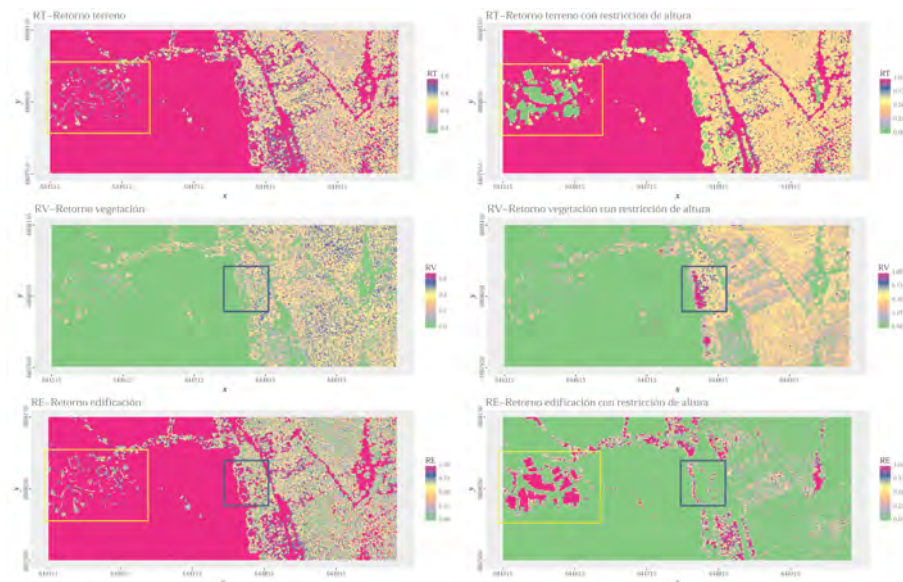


Figura 3.17: Ejemplos de las variables en base a los retornos: RR , RT , RV y RE . (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

40 Retorno vegetación (RV). Las zonas con vegetación no demasiado densa se caracterizan por la existencia de múltiples retornos, es decir, primeros (PR) e intermedios (iR) retornos (Kim y Sohn, 2013). Teniendo en cuenta esta circunstancia, Kim y Sohn (2010) definió el *ratio retorno vegetación* (RV) como la proporción de PR e iR con respecto al total de puntos. Como resultado, las zonas con vegetación alta presentan altos valores de RV . Sin embargo, puede observarse en la Figura 3.17 (RV -Retorno vegetación) como esto no sucede en las zonas con presencia de vegetación muy densa, donde $RV \approx 0$ (zona delimitada por un cuadrado azul en la Figura 3.17) debido a que en estas zonas

predominan los SR . Para corregir este error, se tuvo en cuenta el dato de altura máxima de las edificaciones en la zona (12 m). Considerando este límite de altura, se calculó un nuevo ráster donde se almacenó la cantidad de SR cuya altura supera los 12 m ($SR_{\Delta z > 12}$). Así, la ecuación propuesta por Kim y Sohn (2010) se modificó y RV pasó a representar la proporción de $SR_{\Delta z > 12}$, PR e iR con respecto al total de puntos (Ecuación 3.10). El resultado se incluye en la Figura 3.17 (RV -Retorno vegetación con restricción de altura) donde se observa como las zonas con vegetación densa del recuadro azul presentan ahora un $RV \approx 1$. Al igual que en los casos anteriores, el cálculo de esta variable se realizó a nivel píxel.

$$RV = \frac{N_{SR_{\Delta z > 12}} + N_{PR} + N_{iR}}{N_{VP}} \quad (3.10)$$

41 Retorno edificación (RE). Las áreas que presentan construcciones se caracterizan por la presencia de SR (Kim y Sohn, 2013). Teniendo en cuenta esta característica, Kim y Sohn (2010) definió el *ratio retorno edificación* (RE) como la proporción de SP con respecto al total de puntos. De esta forma, las zonas con edificaciones presentan valores altos del ratio RE tal y como se puede comprobar en la Figura 3.17 (RE -Retorno edificación, recuadro amarillo). Sin embargo, en dicha imagen se observa como esta situación también se da en zonas con vegetación densa (recuadro azul) y en zonas sin presencia de vegetación alta o arbustiva debido a que estas superficies se comportan y son impermeables, respectivamente. Para corregir estos errores, se calculó un nuevo ráster de SR donde cada celda almacena la cantidad de SR que presentan una altura entre 2 m y 12 m ($SR_{\Delta z \in [2.5, 12]}$). La ecuación propuesta por Kim y Sohn (2010) se modificó considerando únicamente los SR cuya altura se encuentran dentro de dicho rango (Ecuación 3.11). El resultado se incluye en la Figura 3.17 (RE -Retorno edificación con restricción de altura) donde se observa como el terreno y las zonas con vegetación densa// (recuadro azul) presentan ahora un $RE \approx 0$. Nuevamente el cálculo

para obtener esta variable se realizó a nivel píxel.

$$RE = \frac{N_{SR_{\Delta z \in [2.5, 12]}}}{N_{vP}} \quad (3.11)$$

3.2.6.4 En base a la rugosidad

La rugosidad de una superficie puede relacionarse con su nivel de complejidad. De manera simplificada, se pueden agrupar las variables que representan la rugosidad de una superficie en 2 categorías. Por un lado, se encontrarían aquellas variables que representan la variabilidad de un determinado atributo de los datos, en este caso, la elevación (Teo y Huang, 2016). De esta forma, la variación de la elevación en un entorno local puede ser de utilidad para caracterizar la estructura de los objetos, particularmente la vegetación (García et al., 2010). Por otro lado se encuentran aquellas variables que miden el grado de planaridad de una superficie. Estas variables han demostrado su potencial para diferenciar superficies lisas como el terreno desnudo o las cubiertas de las edificaciones, de superficies rugosas como puede ser el caso de la vegetación (Chehata et al., 2009, Kim y Sohn, 2013). De esta forma, se han definido y calculado las siguientes variables relacionadas con la rugosidad (un resumen de estas variables se incluye en la Tabla 3.6):

Tabla 3.6: Variables en base a la rugosidad.

Variable	Atributos	Escala cálculo	Elemento asignación	Res.	Cita
Std_z	z	C	P→Pi	r ₁	Im et al. (2008a),
$Std_{\Delta z > 0.7}$	Δz	V	Pi	r ₁	Sasaki et al. (2012), Yao y Wei (2013), Teo y Huang (2016)
P	z	C	P→Pi	r ₂	Buján et al. (2012)
CV_z	z	V	Pi	r ₂	Guo et al. (2010)
N_z	z	C	P→Pi	r ₂	Chehata et al. (2009), Guan et al. (2013), Kim y Sohn (2013)
RMS	z	C	P→Pi	r ₂	(Rutzinger et al., 2008, Kim, 2015)
D_N	z	C	P→Pi	r ₂	(Li et al., 2017)

Atributos: z -elevación, I^n -intensidad corregida, nR -número de retorno, Δz -altura; **escala de cálculo:** P-punto, C-cilindro, V-vóxel; **elemento de asignación:** P-punto, Pi-píxel; **resolución:** $r_1=1.5*PointSpacing$ y $r_2=4*PointSpacing$.

42-43 Desviación estándar de la elevación (Std_z) y la altura ($Std_{\Delta z > 0.7}$). La primera variable, Std_z , representa la desviación estándar máxima de los puntos incluidos en un vóxel. Para su cálculo, en primer lugar a cada punto se le asigna la desviación estándar de la elevación de los puntos contenidos en un cilindro centrado en el punto que se está analizando (cálculo de la desviación estándar a nivel punto). Una vez que a cada punto se le asignó un valor de desviación estándar, se calcula a nivel vóxel el cuantil del 95% de este atributo y finalmente el valor resultante se le asigna al píxel que corresponda. Los píxeles sin datos (valor NA) se corrigen aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que sólo se modificará el valor de los píxeles NA. Se optó por este cálculo alternativo de la desviación estándar de la elevación después de comparar estos resultados con los que se obtendrían al calcular la desviación estándar a nivel vóxel directamente. Por otro lado, la variable $Std_{\Delta z > 0.7}$ sí representa la desviación estándar de la altura de los puntos contenidos en cada vóxel pero considerando únicamente aquellos con una altura ≥ 0.7 . Los valores resultantes son trasladados al píxel que corresponda. A los píxeles sin datos (valor NA) se les asigna el valor 0. Estas variables pueden verse como representación de la rugosidad de la superficie de impacto del láser y pueden emplearse para distinguir entre coberturas u objetos que presentan diferentes niveles de rugosidad (Teo y Huang, 2016). Así, se espera que las zonas con vegetación tengan valores más altos de estas variables que aquellas zonas que contienen construcciones o que representan el terreno (Guo et al., 2015). El resultado de estas variables en formato ráster se incluye en la Figura 3.18.

44 Pendiente (P). De forma genérica, la pendiente (P) representa la tasa de cambio de la elevación. En este estudio la pendiente se calculó a nivel punto. Para ello se definió una vecindad local por medio de un cilindro centrado en el punto de análisis y se calculó la pendiente entre dicho punto y todos los puntos incluidos en el cilindro. A partir de estos valores se calculó el cuantil del 68.3%, siendo éste el valor de pendiente que se le asigna al punto de análisis. Finalmente, esta variable se traslada al píxel correspondiente calculando el cuantil del 95% de la pendiente de los puntos incluidos en cada vóxel. Los píxeles sin datos (valor NA) se corrigen aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que sólo se modificará el valor de los píxeles NA.

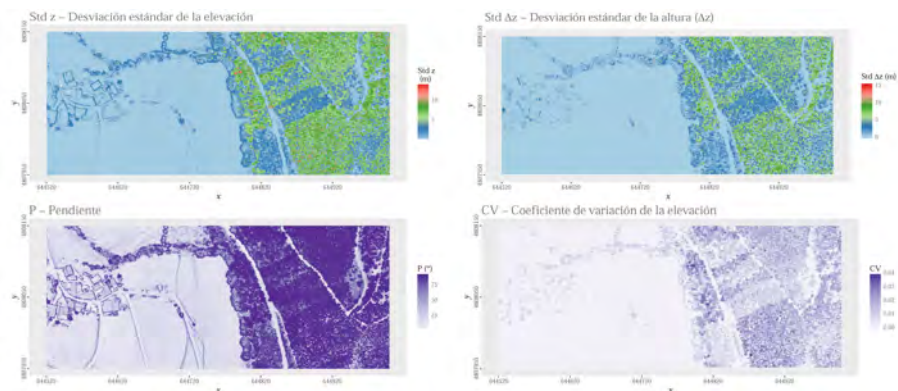


Figura 3.18: Ejemplos de las variables en base a la rugosidad: Std_z , $Std_{\Delta z}$, P y CV_z . (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

Generalmente, cuando se emplea la variable pendiente a nivel píxel ésta se calcula a partir del MDS o nMDS en formato ráster (Buján et al., 2012). Sin embargo, en este estudio se calculó a nivel punto debido a que en el momento de trasladarla a los objetos se respeta más fielmente los valores reales de pendiente que si éstos se derivan del valor de un píxel, el cuál proviene a su vez de un MDS o nMDS. En la Figura 3.18 se incluye un ejemplo de esta variable en formato ráster. En dicha imagen se observa claramente como las zonas con vegetación presentan los valores más elevados de pendiente mientras que las cubiertas de las edificaciones, las vías de comunicación y el terreno desnudo o con vegetación baja presentan los valores más bajos.

45 Coeficiente de variación de la elevación (CV_z). El coeficiente de variación de la elevación representa la variabilidad del terreno y los objetos situados sobre él en relación a la elevación. Guo et al. (2010) mostró en su estudio que la pendiente del terreno presentaba una correlación positiva con el CV de la elevación. Según dicho autor esta situación se debe a que las zonas que presentan una elevada variabilidad topográfica generalmente se corresponden con aquellas zonas donde la pendiente del terreno también lo es. Debido a la posibilidad de la existencia de correlación entre la pendiente y el coeficiente de variación de la elevación, en este caso el cálculo de CV_z se realizó a partir de la Ecuación 3.12 y los valores de elevación de todos los

puntos incluidos en un vóxel y no a nivel punto por medio de un cilindro como con la variable P . Finalmente, los valores obtenidos se le asignan a los píxeles correspondientes y a aquéllos a los que no se les asignó ningún valor (valor NA) se corrigen aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que sólo se modificará el valor de los píxeles NA. La Figura 3.18 incluye una muestra de esta variable en formato ráster.

$$CV_z = \frac{\sigma(z)}{\mu(z)} \quad (3.12)$$

Por otro lado, la superficie del terreno libre de objetos y las cubiertas de las edificaciones pueden ser representadas por medio de planos en un entorno local. La *planaridad* de estas superficies puede emplearse para diferenciarlas de la vegetación. En este estudio, para representar la *planaridad* de cada punto se definió la vecindad local de cada uno por medio de un cilindro vertical de radio r cuyo eje central pasa por el punto de análisis P_i (el proceso de cálculo para obtener el valor de r se incluye en el apartado 3.2.6 de este estudio). A diferencia de las variables anteriores de rugosidad, en este caso únicamente se consideran aquellos puntos dentro del cilindro cuya distancia vertical al punto analizado no sea superior al valor del radio r , tal y como se indica en la Figura 3.19. A partir de los puntos seleccionados se ajusta un plano (Π_p) por medio de un modelo lineal (función *glm* incluida en el paquete *stats* - v.3.4.2 de R). Este plano permite calcular las siguientes variables (46 - 48):

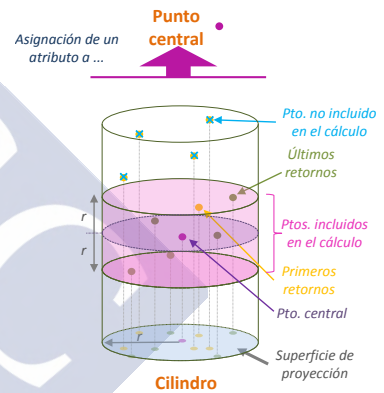


Figura 3.19: Esquema del análisis de puntos a partir de un cilindro.

46 **Ángulo normal (N_z)**. Esta variable representa el ángulo que forma el vector normal al plano Π_p con la dirección de la vertical. N_z se le asigna a cada punto. A partir de los puntos incluidos en cada vóxel se

calcula el cuantil del 68.3% de N_z y se le asigna al píxel correspondiente. Los píxeles sin datos (valor NA) se corrigen aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que sólo se modificará el valor de los píxeles NA. Esta variable fue empleada en varios estudios de clasificación a nivel punto para diferenciar aquellos puntos pertenecientes al terreno o a cubiertas de edificaciones (valores bajos de N_z) de los puntos que representan la vegetación (Chehata et al., 2009, Guan et al., 2013, Kim y Sohn, 2013). La Figura 3.20 incluye una muestra de esta variable en formato ráster.

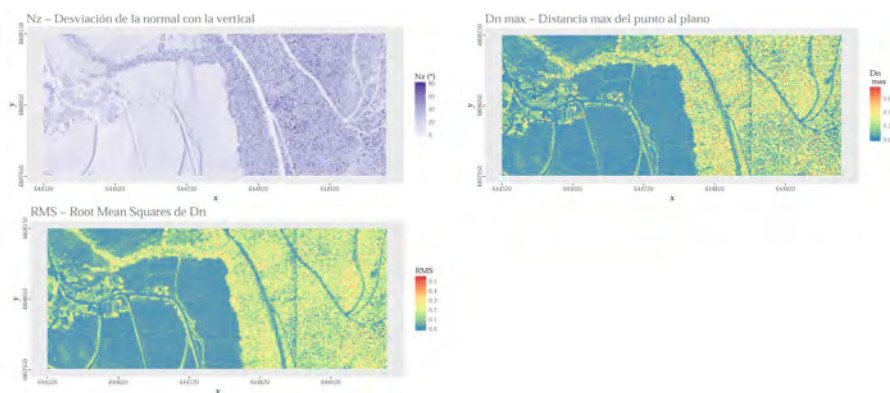


Figura 3.20: Ejemplos de las variables en base a la rugosidad: N_z , RMS y D_N máxima y mínima. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

47 Media cuadrática de D_N (RMS_{D_n}). Esta variable representa la media cuadrática de las distancias entre los puntos y los planos Π_p . Se empleó este estadístico para representar cuantitativamente el ajuste general de los planos Π_p a los puntos incluidos en cada vóxel. Los píxeles sin datos (valor NA) se corrigen aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que sólo se modificará el valor de los píxeles NA. Por medio de este estadístico se evitan posibles efectos del signo de la variable D_N . La gran mayoría de los estudios que emplearon esta variable lo hicieron en el marco de clasificaciones a nivel punto (Kim, 2015, Li et al., 2017). Valores bajos de RMS_{D_n} indican la presencia de superficies suavizadas como son las cubiertas de las edificaciones. Sin embargo, Kim (2015) advirtió que esta variable puede no ser apropiada para representar la rugosidad de zonas donde se produce intersección de múltiples planos.

48 **Distancia del punto P_i al plano Π_p (D_N).** Esta variable representa la distancia vertical entre el punto central del cilindro que está siendo analizado (P_i) y el plano Π_p (Kim y Sohn, 2010, Li et al., 2017). D_N se le asigna a P_i . Para trasladar esta variable al píxel correspondiente se calcula el cuantil del 95% de los valores de D_N de los puntos incluidos en cada vóxel. Los píxeles sin datos (valor NA) se corrigen aplicando un filtro de mediana con un tamaño de ventana de 3x3 (celdas), de forma que sólo se modificará el valor de los píxeles NA. En la Figura 3.20 se incluye un ejemplo de esta variable en formato ráster.

Esta variable al igual que la anterior presentan algunos errores en aquellas zonas donde la densidad de puntos es mucho menor a la densidad media ponderada (zona inferior derecha). Estos errores tienen su origen en el cálculo del radio del cilindro centrado en cada punto. Tal y como se comentó en el inicio de este apartado, dicho radio se calcula en base a la densidad media ponderada de la nube de puntos LiDAR. Cuanto mayor es la densidad, menor será el radio del cilindro para cumplir la condición de contener 15 puntos. Sin embargo, en zonas donde la densidad de puntos es mucho menor que la densidad tomada como referencia, dicho cilindro contendrá menos puntos y en consecuencia el plano que permite calcular el vector normal se obtendrá a partir de menos puntos. Como se observa en la Figura 3.20, esto ocasiona que zonas que presentan vegetación arbolada tengan residuales similares a los que presentan las superficies planas como las cubiertas de las edificaciones. En el momento de analizar los resultados de los diferentes métodos de clasificación, se comprobará en que medida estos errores pueden afectar a la precisión de las clasificaciones.

3.2.6.5 En base a la textura

Uno de los métodos más populares para representar matemáticamente la textura es la *grey-level co-occurrence matrix* (GLCM) propuesto por Julesz (1962). La matriz de co-ocurrencia es un histograma bidimensional que representa la frecuencia con la que determinadas combinaciones de niveles de gris (a nivel píxel) se dan en una imagen

considerando una distancia d y una relación espacial entre pares de píxeles. Existe una matriz de co-ocurrencia según se considere el vecino situado en posición horizontal (0°), el vertical (90°) o en ambas diagonales (45° y 135°) (Ciriza et al., 2012). Estas variables de textura han sido empleadas en procesos automáticos de clasificación, inicialmente a partir de imágenes multispectrales y más recientemente empleando los atributos elevación (Teo y Huang, 2016), altura (Im et al., 2008a) o intensidad (Guan et al., 2013) de los datos LiDAR. En este estudio se crearán 8 medidas de textura por cada uno de los atributos LiDAR mencionados: media (T_μ), varianza (T_{σ^2}), contraste (T_{Con}), disimilaridad (T_{Dis}), homogeneidad (T_{Hom}), entropía (T_{Ent}), *second-moment* (T_{S-M}) y correlación (T_{Cor}).

La *media GLCM* no representa la media de los valores de gris de los píxeles incluidos en un ventana, sino que representa el valor del píxel ponderado por la frecuencia de su co-ocurrencia en combinación de un determinado valor del píxel vecino, mientras que la medida de *varianza* representa la varianza de los niveles de gris en una ventana y en una dirección dada. Por otro lado, el *contraste* es la medida opuesta a la *homogeneidad*, ya que representa la cantidad de variación local presente en la imagen. Esta medida aumenta exponencialmente a medida que nos alejamos de la diagonal. La *disimilaridad* es similar a la medida anterior con la diferencia de que su incremento a medida que nos alejamos de la diagonal es lineal. La entropía resalta aquellas combinaciones de píxeles menos comunes. El *second-moment* es una medida de la homogeneidad local, tomando valores altos cuando en la matriz de co-ocurrencia tiene pocas entradas de gran magnitud y es baja cuando las entradas son similares. Finalmente, la *correlación* mide la dependencia lineal de los niveles de gris del píxel central con los píxeles vecinos.

Para el cálculo de estas medidas se empleó la función *gcm* incluida en el paquete *gcm* (v.1.6.1.) del software R, tomando como datos de entrada las variables nMS_{PR} (1), MS_{PR} empleada para el cálculo de MS_D (35) y I'_{PR} (23) en formato ráster. Adicionalmente también se estableció que el cálculo de las medidas de textura se realizase en todas las direcciones. Como resultado se obtienen 8 medidas de textura por cada variable en formato ráster. Estas medidas son las siguientes (resumen en la Tabla 3.7):

Tabla 3.7: Variables en base a la textura.

Variable	Atributos	Escala cálculo	Elemento asignación	Res. Cita
TI_{μ} , TI_{σ^2} , TI_{Con} , TI_{Dis} , TI_{Hom} , TI_{Ent} , TI_{S-M} , TI_{Cor}	I''_{PR}	—	Pi	r_1 Guan et al. (2013), Yao y Wei (2013), Matikainen et al. (2017)
TZ_{μ} , TZ_{σ^2} , TZ_{Con} , TZ_{Dis} , TZ_{Hom} , TZ_{Ent} , TZ_{S-M} , TZ_{Cor}	MS_{PR}	—	Pi	r_1 Samadzadegan et al. (2010), Huang et al. (2011), Teo y Huang (2016)
$T\Delta z_{\mu}$, $T\Delta z_{\sigma^2}$, $T\Delta z_{Con}$, $T\Delta z_{Dis}$, $T\Delta z_{Hom}$, $T\Delta z_{Ent}$, $T\Delta z_{S-M}$, $T\Delta z_{Cor}$	nMS_{PR}	—	Pi	r_1 Im et al. (2008a), Sasaki et al. (2012)

Atributos: z-elevación, I''-intensidad corregida, nR-número de retorno, Δz -altura; **escala de cálculo:** P-punto, C-cilindro, V-vóxel; **elemento de asignación:** P-punto, Pi-píxel; **resolución:** $r_1=1.5*PointSpacing$ y $r_2=4*PointSpacing$.

49-56 **Medidas de textura en base a la intensidad. GLCM:** media (TI_{μ}), varianza (TI_{σ^2}), contraste (TI_{Con}), disimilaridad (TI_{Dis}), homogeneidad (TI_{Hom}), entropía (TI_{Ent}), *second-moment* (TI_{S-M}) y correlación (TI_{Cor}). Las medidas de textura en base a los valores de intensidad de los puntos LiDAR se han tenido en cuenta en pocos estudios. Guan et al. (2013) demostraron la utilidad de la media y del *second-moment* para la identificación de pastos. Por otro lado, Matikainen et al. (2017) calculó la homogeneidad para intentar diferenciar las vías pavimentadas de las áreas con vegetación baja, mientras que la entropía fue calculada a nivel vóxel por Yao y Wei (2013) con el propósito de emplearla en la identificación de árboles individuales. Como ya se mencionó, en este estudio las variables de textura de la intensidad se calcularon tomando como datos de entrada la variable I''_{PR} (23) en formato ráster. En la Figura 3.21 se incluyen ejemplos gráficos de las medidas de textura de la intensidad.

57-64 **Medidas de textura de la elevación. GLCM:** media (TZ_{μ}), varianza (TZ_{σ^2}), contraste (TZ_{Con}), disimilaridad (TZ_{Dis}), homogeneidad (TZ_{Hom}), entropía (TZ_{Ent}), *second-moment* (TZ_{S-M}) y correlación (TZ_{Cor}). De forma similar al caso anterior, las medidas de textura tomando como base la elevación de los puntos LiDAR no han sido muy empleadas. Uno de los escasos estudios donde estas medidas se han creado a partir del MDS es el de Teo y Huang (2016). En su caso únicamente calcularon la entropía y




Figura 3.21: Ejemplos de las variables en base a la textura de la intensidad: TI_{μ} , TI_{σ^2} , TI_{Con} , TI_{Dis} , TI_{Hom} , TI_{Ent} , TI_{S-M} y TI_{Cor} . (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

la homogeneidad como indicadores de la rugosidad de las coberturas del suelo. En este estudio las variables de textura de la elevación se calcularon tomando como datos de entrada la variable MS_{PR} en formato ráster. En la Figura 3.22 se incluyen algunos ejemplos de las medidas de textura de la elevación.

65-72 **Textura de la altura GLCM (Grey level co-occurrence matrix):** media ($T\Delta z_{\mu}$), varianza ($T\Delta z_{\sigma^2}$), contraste ($T\Delta z_{Con}$), disimilaridad ($T\Delta z_{Dis}$), homogeneidad ($T\Delta z_{Hom}$), entropía ($T\Delta z_{Ent}$), *second-moment* ($T\Delta z_{S-M}$) y correlación ($T\Delta z_{Cor}$). Finalmente, las medidas de textura tomando como base la altura de los puntos LiDAR tampoco se han empleado mucho. [Im et al. \(2008a\)](#)




Figura 3.22: Ejemplos de las variables en base a la textura de la elevación: TZ_{μ} , TZ_{σ^2} , TZ_{Con} , TZ_{Dis} , TZ_{Hom} , TZ_{Ent} , TZ_{S-M} y TZ_{Cor} . (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

empleó 4 de las medidas calculadas en este estudio (homogeneidad, contraste, entropía y correlación) con la idea de usarlas para mejorar la identificación de zonas edificadas, arbolado, vegetación baja y vías pavimentadas. Por otro lado, [Sasaki et al. \(2012\)](#) calculó las 8 medidas de textura empleadas en este estudio para identificar diferentes especies forestales. En este estudio a partir de la variable nMS_{PR} (1) en formato ráster, representativa de la altura, se calcularon las medidas de textura. La Figura 3.34a incluye ejemplos de estas medidas de textura.




Figura 3.23: Ejemplos de las variables en base a la textura de la altura: $T\Delta z_{\mu}$, $T\Delta z_{\sigma^2}$, $T\Delta z_{Con}$, $T\Delta z_{Dis}$, $T\Delta z_{Hom}$, $T\Delta z_{Ent}$, $T\Delta z_{S-M}$ y $T\Delta z_{Cor}$. (Imágenes creadas a partir de la nube de puntos LiDAR sin reducir.)

3.2.7 ¿Qué coberturas del suelo serán identificadas?

Poseer cartografía actualizada de las coberturas del suelo es fundamental para abordar problemas relacionados con la gestión territorial. Disponer de esta información de manera periódica permitiría evaluar el grado de cumplimiento y seguimiento de planes de ordenación para mejorar la gestión territorial (por ejemplo, detección de construcciones fuera de ordenación, identificación de coberturas-usos no permitidos,...); analizar el crecimiento urbano; detectar y cuantificar la pérdida/infrautilización de tierras agrícolas y de biodiversidad; analizar el nivel de gestión de las zonas con vegetación arbolada (por ejemplo, detección del trazado de

pistas forestales, nivel de gestión de las masas forestales,...); evaluación del riesgo de incendios,...

Teniendo presentes las aplicaciones anteriores, las principales clases que se demandan en cada caso y las características de la zona de estudio, se buscará identificar 8 coberturas del suelo (Figura 3.24) a partir de un método de clasificación híbrido que tomará como únicos datos de entrada variables calculadas a partir de datos LiDAR. Entre las clases identificadas se entremezclan coberturas tradicionales que detectadas en estudios previos mediante procesos automáticos de clasificación (por ejemplo *pavimento*, *suelo desnudo* o *edificaciones*) (Charaniya et al., 2004, Im et al., 2008a, Zhou, 2013, Matikainen et al., 2017) con clases vinculadas al nivel de gestión de la vegetación (por ejemplo *vegetación mixta* o *arbolado sin vegetación arbustiva*) (Antonarakis et al., 2008, García et al., 2011, Alonso-Benito et al., 2016).




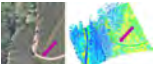
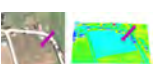
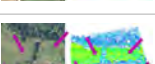



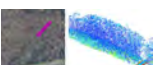
Figura 3.24: Aplicaciones y coberturas del suelo.

En la Tabla 3.8 se incluye la denominación de las diferentes coberturas del suelo que se identificarán en este estudio y una descripción resumida de cada una. En dicha tabla también se incluye para cada clase un ejemplo gráfico.

3.2.8 *Random Forest*: Importancia de las variables

A inicios de este siglo, los métodos de clasificación no paramétricos basados en la generación "masiva" de clasificaciones despertaron el

Tabla 3.8: Descripción de las clases de coberturas del suelo.

Coberturas	Descripción
<i>Pavimento</i>	 Pv - Se incluyen en esta clase las vías pavimentadas.
<i>Pistas de tierra</i>	 Ps - Se incluyen en esta clase las pistas/caminos de tierra tanto forestales como de uso agrario.
<i>Suelo desnudo</i>	 Sd - Esta clase representa tanto las tierras de labor sin vegetación como zonas forestales sin vegetación o desarboladas.
<i>V. baja</i>	 Vb - Se incluyen zonas de pasto, prados y huertos con vegetación.
<i>V. arbustiva</i>	 Vr - Zonas que presentan arbustos o matorral de mediano y alto porte (<4 m de altura).
<i>Arbolado</i>	 Va - Zonas forestales arboladas así como árboles aislados en prados, jardines o a lo largo de vías de comunicación o límites de parcelas que no presentan vegetación arbustiva (1 único estrato).
<i>V. mixta</i>	 Vm - Zonas donde confluyen en el mismo espacio vegetación arbolada con vegetación arbustiva (> 1 estrato).
<i>Edificaciones</i>	 Ed - Edificaciones rurales caracterizadas por ser de pequeño tamaño (< 12 m), no poseer más de dos plantas más bajo y cuyos tejados presentan diferentes materiales.

La imagen de la izquierda se corresponde con la ortoimagen de la cobertura y la imagen de la derecha es una captura de los datos LiDAR coloreados en función de los valores de intensidad, que van desde el azul oscuro (intensidad $\simeq 0$), pasando por el amarillo (intensidad $\simeq 100$) hasta llegar al verde (intensidad $\simeq 255$).



interés de la comunidad científica que se encontraba centrada en la identificación automática de coberturas/ usos del suelo a partir de la integración de datos procedentes de sensores remotos (Gislason et al., 2006). En esta época, el método *bagging* (Breiman, 1996) era uno de los métodos no paramétricos más empleados. Tomándolo como punto de partida, Breiman (2001) desarrolló el algoritmo *random forest*. En la fase de entrenamiento, este algoritmo de ensamblado no paramétrico construye sucesivamente *Ntree* árboles de decisión (similares a CART) empleando un conjunto de observaciones seleccionadas aleatoriamente de

la muestra de referencia. Esta muestra de entrenamiento se denomina muestra *in-bag* y está compuesta por aproximadamente dos tercios de las observaciones que forman la muestra de referencia. El tercio de observaciones restante se denomina muestra *out-of-the bag* y se emplea para estimar la precisión del modelo, la cuál se representa por el error *out-of-bag* (OOB). La principal diferencia entre este algoritmo y el método *bagging* es la forma de construir los árboles. Mientras que en el método *bagging* cada nodo se divide considerando todas las variables, el algoritmo *random forest* seleccionada aleatoriamente $Mtry$ variables, y son éstas las que se emplean para dividir los nodos. En cada nodo, el algoritmo busca los valores críticos por encima o por debajo de los cuales hay un cambio significativo en la probabilidad de presencia. Una vez creados los $Ntree$ árboles, la predicción de cada árbol cuenta como un voto para la clase que corresponda, de forma que la etiqueta que se seleccionada como predicción será aquella que recibe más votos (voto mayoritario) (Belgiu y Drăguț, 2016).

Tal y como se deduce del párrafo anterior, el algoritmo *random forest* cuenta con dos parámetros principales: número de árboles que serán generados ($Ntree$) y el número de variables que serán seleccionadas y evaluadas en cada nodo ($Mtry$). Algunos estudios han demostrado que la precisión final de la clasificación es menos sensible a variaciones del parámetro $Ntree$ que a las del parámetro $Mtry$ (Ghosh et al., 2014). En relación al primer parámetro, muchos estudios han fijado en 500 el parámetro $Ntree$ (Gislason et al., 2006, O'Connell et al., 2015). Belgiu y Drăguț (2016) citó como posible origen de este valor el hecho de que se trata del valor por defecto empleado en la función *randomForest*, incluida en el paquete con el mismo nombre del software R. Aun teniendo esta idea presente, dichos autores consideran que 500 es un valor aceptable para el parámetro $Ntree$, aunque valores que van desde 100 hasta 10000 también han sido usados (Guan et al., 2013, Vogels et al., 2017). Por otro lado, en cuanto al parámetro $Mtry$, aunque el algoritmo *random forest* se caracteriza por su elevado nivel de eficiencia en cuanto al tiempo de procesado, es necesario tener en cuenta que valores altos de dicho parámetro aumentarán el tiempo de procesado. Limitar el número de variables, además de reducir considerablemente el tiempo de procesado, también permite disminuir la correlación entre árboles (Gislason et al., 2006). Así, generalmente el valor de este parámetro se fija como la raíz

cuadrada del número de variables disponibles.

Si bien el mayor potencial del algoritmo *random forest* reside en su habilidad como clasificador, el principal interés de su uso en este estudio es por una de sus funciones adicionales, es decir, como método para evaluar la importancia de las variables (IV). El análisis de la importancia de las variables disponibles para llevar a cabo una clasificación no sólo es de utilidad para aumentar la eficiencia y precisión del proceso de clasificación, sino que también facilita la comprensión de los datos y la interpretación de resultados (Genuer et al., 2010). RF genera dos medidas durante su ejecución que pueden ser usadas para representar la importancia de cada variable: *Mean Decrease in Gini* (MDG) y *Mean Decrease in Accuracy* (MDA). El MDG se basa en medir cuánto una variable reduce la medida de impureza de Gini para una determinada cobertura, mientras que MDA cuantifica cuánto varía el error de predicción (OOB) cuando los datos para una variable se permutan aleatoriamente mientras que el resto no se modifica. Algunos estudios han mostrado como el MDG puede introducir sesgos en el análisis al favorecer a ciertas variables (Strobl et al., 2007). Por este motivo, en este estudio la IV se representa por medio de la medida MDA.

Empleando la medida MDA, la importancia de la variable V^j se define de la siguiente manera. Para cada árbol t , se emplea la muestra OOB_t para calcular el error de la clasificación (e_{OOB_t}). A continuación, los valores de V^j en la muestra OOB_t se permutan aleatoriamente sin modificar los valores del resto de variables dando lugar a la muestra $O\tilde{O}B_t^j$. A su vez, esta muestra se emplea para calcular el error de la clasificación ($e_{O\tilde{O}B_t^j}$). Finalmente, la importancia de la variable V^j viene dada por la Ecuación 3.13 (Genuer et al., 2010). De esta forma, si una variable no se encuentra asociada con las coberturas que se busca identificar, su uso no influirá en la predicción y por tanto, la variación del error y en consecuencia su importancia, tenderá a cero. En caso contrario, si la variable se encuentra asociada a alguna de las coberturas, su uso afectará a la predicción y por tanto su importancia en el proceso

aumentará (Janitza et al., 2016).

$$IV^j = \frac{1}{Ntree} * \sum_t^{Ntree} (eO\tilde{O}B_t^j - eOOB_t) \quad (3.13)$$

En este estudio, se empleó la función *randomForest* incluida en el paquete *randomForest* (V.4.6-14) (Liaw y Wiener, 2002) del software R (V.3.4.2) para calcular y analizar la importancia de las variables (IV) en la identificación de 8 coberturas del suelo. El número de árboles de clasificación se fijó en 5000 (parámetro *Ntree*) mientras que el número de variables a considerar en cada nodo se fijó en 10 (parámetro *Mtry*). Para obtener la IV fue necesario activar la opción *importance*. Para aplicar esta función se seleccionaron aleatoriamente 100 puntos de referencia por cobertura del suelo. En el Anexo C.2 se describe tanto el material como la metodología empleada para seleccionar estos puntos. El resultado de la función *randomForest* permitirá analizar la importancia general de las variables para identificar las diferentes coberturas del suelo, su importancia para cada cobertura individualmente así como las variables más útiles para diferenciar coberturas con características similares. Finalmente, dicha función también proporciona un árbol de clasificación y su error asociado. Estos resultados pueden considerarse como el resultado de llevar a cabo una clasificación basada en píxeles y se compararán con los obtenidos a partir de la clasificación híbrida desarrollada en este estudio. Esta comparación permitirá comprobar en qué medida el método híbrido mejora (o no) la clasificación basada en píxeles empleando el algoritmo *random forest*.

3.2.9 *HyClass*: Clasificación híbrida

Como ya se mencionó previamente, para seleccionar el método de clasificación que mejor se adapte a los objetivos fijados, es necesario tener en cuenta varios factores. Entre estos factores destacan principalmente dos: los datos de entrada y las coberturas objetivo (Lu y Weng, 2007). El método de clasificación que se propone en este estudio puede incluirse en el grupo de métodos que se basan en *conocimiento*

experto definido por Chen et al. (2018). La idea central sobre la que se desarrolló surgió del estudio realizado por Cánovas-García y Alonso-Sarría (2015). Estos autores propusieron un método para obtener el valor óptimo del parámetro *scale* del algoritmo multirresolución implementado en *Definiens eCognition*[®]. A partir de los análisis que realizaron, concluyeron que la ejecución de procesos de segmentación a escala global (se considera que este término se refiere a la totalidad del área de estudio) puede producir resultados inapropiados en algunas coberturas. Dichos autores propusieron como alternativa su ejecución a nivel local lo que permitiría ajustar los parámetros del algoritmo de segmentación a las diferentes coberturas o grupos de coberturas.

Tomando como base la idea anterior, en este estudio se propone el método de clasificación *HyClass*. Se trata de un método híbrido de clasificación de coberturas del suelo que a diferencia de los métodos desarrollados hasta el momento 1) emplea como únicos datos de entrada una nube de puntos LiDAR e 2) integra en un árbol de decisión, método de asignación escogido por su flexibilidad, sencillez y facilidad de comprensión, procesos de segmentación a escala local con reglas de decisión para la asignación de clases a los píxeles/objetos. Las variables empleadas tanto para la segmentación como para el establecimiento de las reglas de decisión y umbrales se han establecido en base a los resultados del análisis de importancia de las variables descrito en el apartado anterior.

Para diseñar el árbol de decisión que conforma *HyClass*, se consideró la jerarquía entre las coberturas incluida en la Figura 3.25. En esta Figura se observan 3 niveles de clasificación construidos tomando como referencia el atributo de altura obtenido a partir de los datos LiDAR. El *nivel 0* está formado por dos coberturas básicas y genéricas: *terreno* (generalmente zonas con una altura inferior a 1 m) y *objetos*. A continuación, el *nivel 1* procede de subdividir las dos coberturas anteriores para llegar a un mayor nivel de detalle (5 coberturas). De esta forma, a partir de las zonas que representan el *terreno* se pueden identificar *zonas pavimentadas*, como las carreteras y zonas que no presentan vegetación (*suelo desnudo*). Adicionalmente, una parte de las zonas *terreno* van a contener regiones que presentan vegetación baja como son los prados. Estas zonas junto con aquellas derivadas

de las áreas que se identifican con *objetos* y que presentan vegetación no arbolada, formarán la clase *vegetación no arbolada*. Por otro lado, las zonas de objetos también se podrían dividir en *zonas arboladas* y *edificaciones*. Finalmente, en el *nivel 2* se incluyen las 8 coberturas del suelo que se pretenden identificar en este estudio y pueden dividirse en 3 grupos: 1) las clases vinculadas con el terreno (*pavimento - Pv*, *pistas de tierra - Ps*, *suelo desnudo - Sd* y *vegetación baja - Vb*), 2) las que se relacionan con los objetos (*vegetación mixta - Vm*, *vegetación arbolada - Va* y *edificaciones - Ed*) y 3) la *vegetación arbustiva (Vr)*, que por sus características puede contener tanto zonas terreno como áreas que presentan *objetos*. Otra cobertura particular es la *Vm* pues se caracteriza por la existencia en el mismo espacio de vegetación arbustiva y vegetación arbolada.

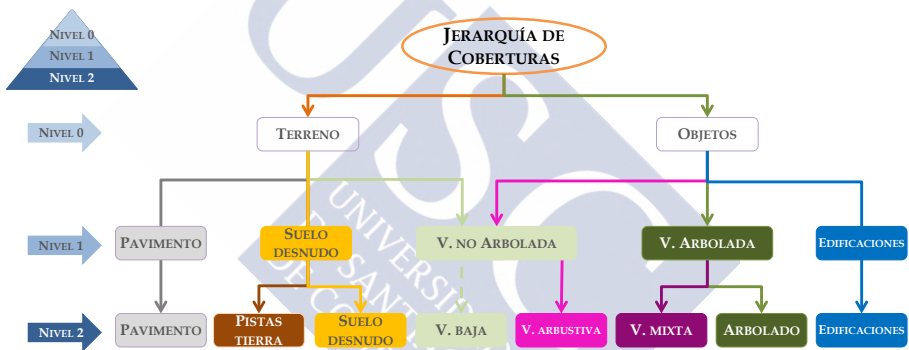


Figura 3.25: Jerarquía de las coberturas del suelo.

La Figura 3.26 muestra el árbol de decisión que constituye el método de clasificación *HyClass*, con los valores finales de los diferentes parámetros de segmentación, los umbrales de cada variable empleados para la asignación de coberturas a los píxeles/objetos y la leyenda con el significado de los signos empleados. Dicho árbol se desarrolló íntegramente en el software propietario *Definiens eCognition®* (v.7.0) (Definiens, 2007). Si bien no es lo más habitual, alguno de los resultados del apartado anterior se adelantarán en este apartado debido a que es imposible explicar el proceso de formación de este árbol sin hacer referencia a los resultados de la importancia de las variables (incluidos todos en el apartado 3.3.2 de resultados). Adicionalmente, con el propósito de tener una orientación de los valores característicos de cada

cobertura en relación a las variables más relevantes, dichos valores se representan por medio de diagrama de cajas en la Figura 3.27.

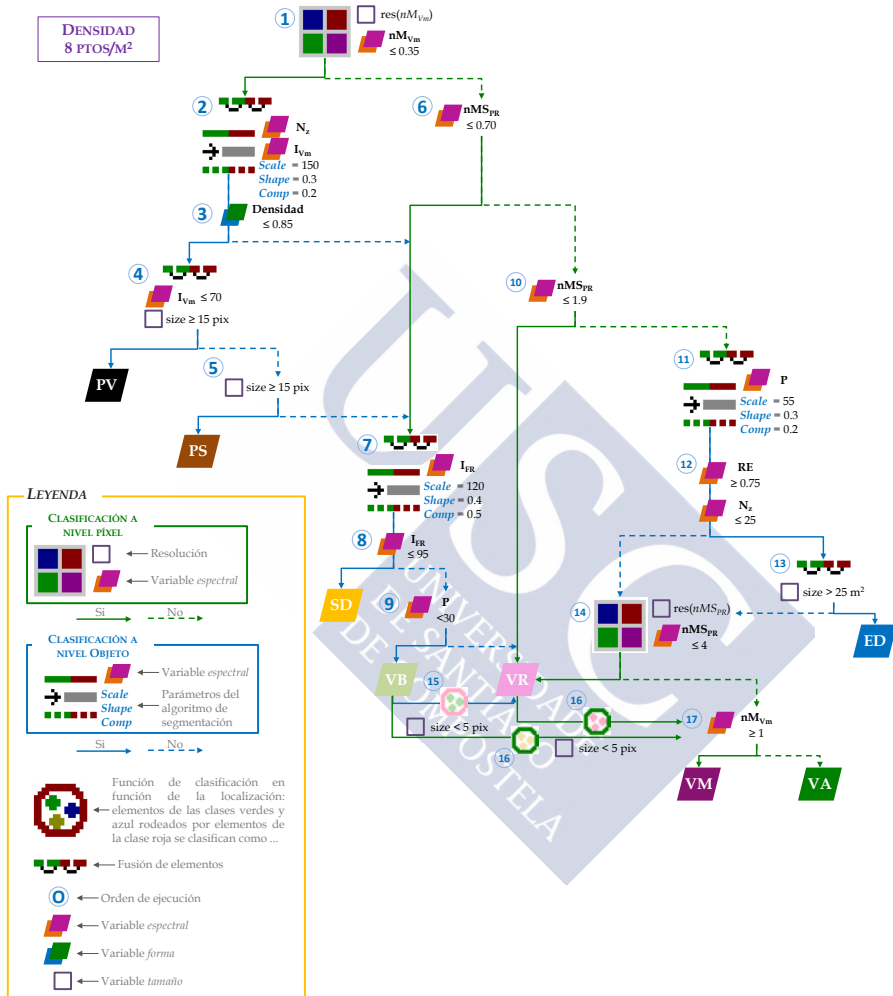


Figura 3.26: Árbol de decisión que constituye *HyClass*.

En la Figura 3.26 se observa como el árbol de decisión presenta tres ramas principales. En primer lugar, la que permite identificar las coberturas *Pv* y *Ps* (operaciones de la 1 a la 5). La segunda rama se dirige a diferenciar las clases *Sd*, *Vb* y *Vr* (operaciones de la 6 a la 10).

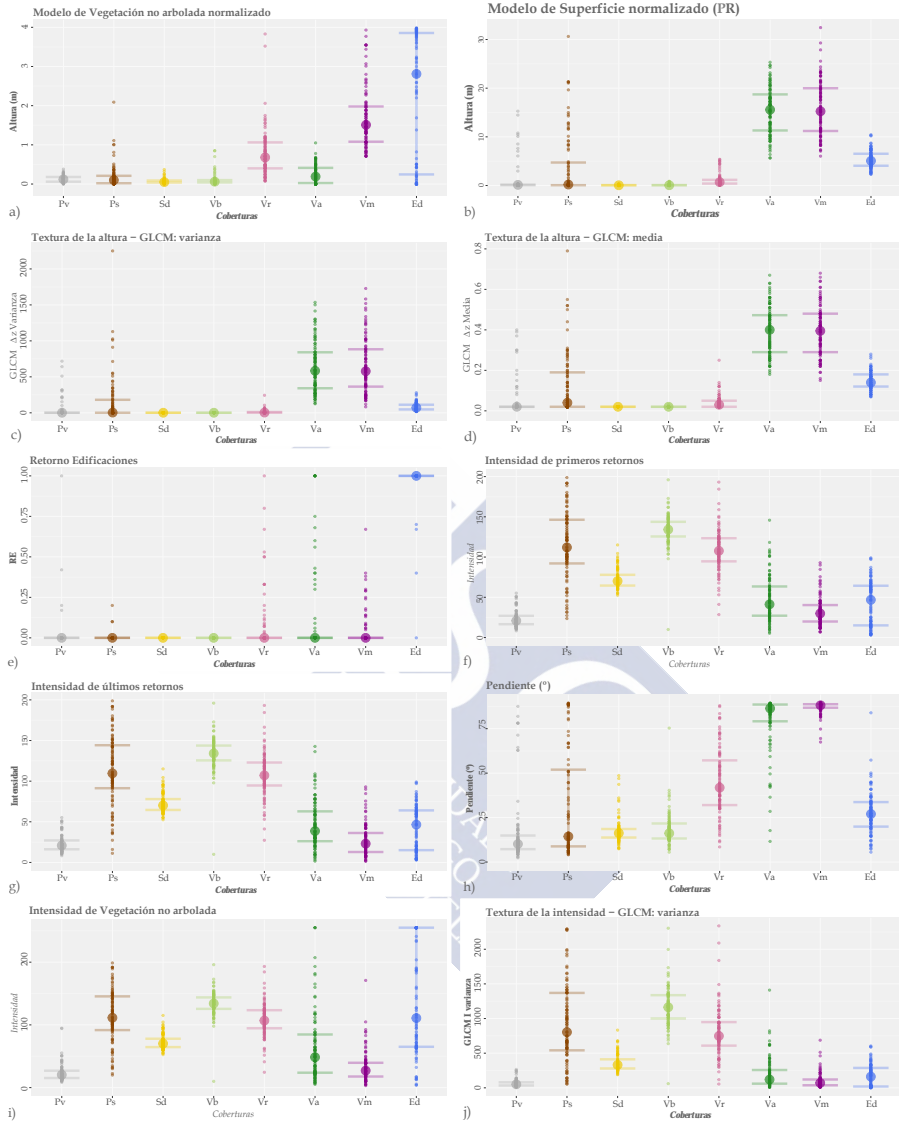


Figura 3.27: Características de las muestras de entrenamiento en relación a las 10 variables más importantes (empleando la nube de puntos original).

Por último, en la rama final se busca discriminar las clases V_m , V_a y E_d (operaciones de la 11 a la 17). A continuación se justifican las decisiones

tomadas para su elaboración y se describen los procesos que se incluyen en cada una de ellas.

3.2.9.1 Coberturas Pv y Ps

Buján et al. (2013b) estudiaron de manera teórica la posibilidad de discriminar en un entorno rural diferentes coberturas del suelo y cambios en las mismas a partir de datos LiDAR multi-temporales. Una de las conclusiones de este estudio hace referencia al papel fundamental que desempeña el Modelo Digital de Superficie normalizado para diferenciar las coberturas vinculadas al terreno (por ejemplo, vías de comunicación o prados) de las que se relacionan con los objetos (por ejemplo, edificaciones o arbolado). Otros estudios previos como el de Im et al. (2008a) o Sasaki et al. (2012) también llegaron a la misma conclusión. En la Figura 3.27b se observa como esta afirmación se cumple para diferenciar las clases Vm , Va y Ed (objetos) de las clases Vb y Sd (terreno) sin embargo no se incluyen las coberturas Pv y Ps . Estas últimas toman valores similares a todas las coberturas anteriores, lo que dificulta más de lo que es habitual su identificación. A diferencia de los estudio mencionados previamente, aquí se busca identificar todo el trazado de las vías, incluyendo los tramos ocultos por la vegetación. Para ello, las muestras de entrenamiento se localizaron en estas zonas (Figura 3.28) y así lo ponen de manifiesto los valores de altura *anormalmente* elevados de estas clases (Figura 3.27b).

Teniendo en cuenta la variable nM_{Vm} (3), la variabilidad de estas coberturas, al igual que la de la clase Va , se reduce de manera evidente y se equipara con el resto de coberturas terreno en cuanto a valores de altura (Figura 3.27a). Así, esta información puede ser de utilidad para identificar aquellas regiones sin vegetación susceptibles de contener vías de comunicación. En este caso se seleccionan aquellos píxeles con un valor de altura en el $nM_{Vm} \leq 0.35$ m (*criterio 1*). En la Figura 3.29 se muestra sombreadas en amarillo las zonas que cumplen con este criterio. En dicha imagen también se ha incluido el trazado de las vías pavimentadas y de las pistas de tierra. Esta imagen permite tanto comprobar que sí es posible identificar los tramos de vía que transcurren

bajo arbolado como localizar visualmente aquellas zonas arboladas que no presentan vegetación arbustiva.

A continuación, atendiendo al análisis de la importancia de variables a nivel clase, aquellas relacionadas con la intensidad, concretamente la I''_{Vm} (25) y la N_z (46) son las variables que se mostraron más relevantes para las clases Pv y Ps , respectivamente. Adicionalmente, el algoritmo *random forest* se empleó para evaluar la posibilidad de diferenciar estas clases a nivel píxel obteniéndose una precisión de $\approx 90\%$ (escenario 1 donde se calculó la importancia de las variables para diferenciar las clases Vb , Sd , Ps y Pv). Si bien la precisión lograda con *random forest* es elevada, se consideró que estos resultados podrían mejorarse mediante el empleo del algoritmo de segmentación multi-resolución (en adelante, ASM) y el posterior uso de alguna de las *variables de forma* implementadas en *Definiens eCognition*[®].



Figura 3.28: Ejemplo de muestras de entrenamiento Pv y Ps en tramos ocultos por vegetación.

En los últimos 15 años, el ASM desarrollado por Baatz y Schäpe (2000) e incluido en *Definiens eCognition*[®] desde 2002, se ha convertido en uno de los algoritmos más populares y empleados en OBIA (*Object-Based Image Analysis*) (Lu y Weng, 2007, Cánovas-García y Alonso-Sarría, 2015). Se trata de un método de segmentación *bottom-up region merging*. En un primer paso considera cada píxel de la imagen como un objeto (*semillas*). A continuación, iterativamente se evalúa la posibilidad de unir dos objetos adyacentes para formar un nuevo objeto de mayor tamaño. De manera inevitable, la unión de objetos aumentará la heterogeneidad interna del objeto resultante. Dicha fusión se hará efectiva si el aumento de la heterogeneidad es inferior a un umbral previamente establecido (criterio de homogeneidad local). El proceso

finaliza cuando no es posible fusionar más objetos.



Figura 3.29: Zonas susceptibles de P_v o P_s .

del incremento de la heterogeneidad al fusionar objetos. Al mismo tiempo, el parámetro *shape* tiene dos componentes, *compactness* y *smoothness*. *Compactness* controla el equilibrio entre la forma de los objetos y la longitud de sus bordes. En la Figura 3.30 se incluye la descripción de cada uno de estos parámetros y la relación que existe entre ellos. Estos parámetros, junto con la ponderación de cada imagen usada en la segmentación, se emplean para calcular el incremento de la heterogeneidad interna que tendría lugar si dos objetos vecinos se fusionaran.

En la última década se han propuesto varios métodos para

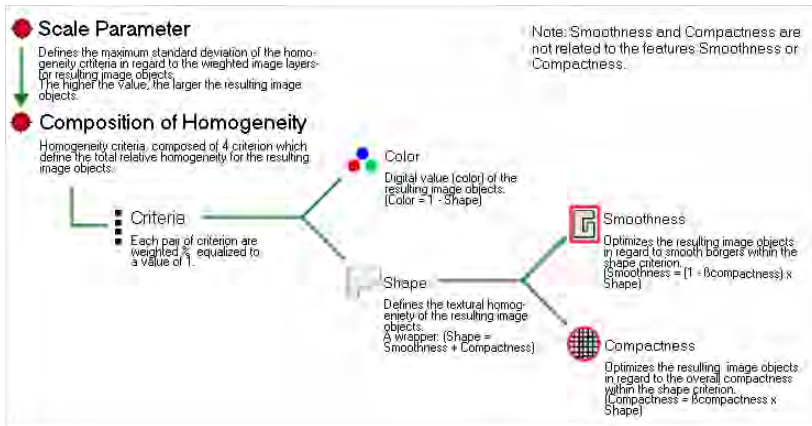


Figura 3.30: Definición y relación entre los parámetros del ASM (fuente: [Definiens \(2007\)](#)).

determinar de forma automática los valores óptimos de los parámetros anteriores ([Espendola et al., 2006](#), [Möller et al., 2007](#), [Cánovas-García y Alonso-Sarría, 2015](#)). Sin embargo, ejecutar todas las combinaciones *posibles* de estos parámetros es un proceso muy laborioso y costoso, por ello en algunos casos se optó por optimizar uno de ellos ([Cánovas-García y Alonso-Sarría, 2015](#)). Adicionalmente, cuando el contraste espectral entre coberturas es bajo, identificar los parámetros óptimos es una tarea que roza el imposible con independencia del método que se use. A pesar de estos esfuerzos, el cálculo automático de parámetros no es una técnica demasiado extendida. Prueba de ello es el gran número de estudios que para fijar los valores de estos parámetros siguen empleando métodos manuales basados en la experiencia del usuario y en el análisis visual de los resultados ([Tian y Chen, 2007](#), [Myint et al., 2011](#), [Maxwell et al., 2015](#), [Matikainen et al., 2017](#)).

En este estudio, los valores de los diferentes parámetros fueron fijados en base a experiencias previas y a la inspección visual de los resultados. También se consideraron las recomendaciones hechas por [Baatz y Schäpe \(2000\)](#), donde estos autores consideran que el criterio espectral (*colour*) es más relevante que el criterio *shape*, recomendando el empleo de valores inferiores a 0.5 para este último parámetro. [Cánovas-García y Alonso-Sarría \(2015\)](#) citó en su estudio que valores entre 0.1 y 0.4 son habituales

en estudios que incluyen clasificaciones orientadas a objetos y en su caso, dicho parámetro se fijó en 0.3. Los valores de estos parámetros para este estudio se incluyen en la Figura 3.26 (en las Figuras C.4 a C.6 del Anexo C se incluyen los mismos datos adaptados a las nubes de puntos con densidad reducida).

Retomando la descripción de las operaciones incluidas en el árbol de decisión de *HyClass* (Figura 3.26), las zonas susceptibles de contener vías de comunicación (resultado del *criterio 1* - Figura 3.29) son objeto de segmentación. Para ello se tuvieron en cuenta las dos variables más relevantes en relación a estas coberturas: I''_{V_m} (25) y N_z (46). Así, estas dos variables se emplean como capas *espectrales* y se fijan los parámetros $scale=150$, $shape=0.3$ y $compactness=0.2$ (*criterio 2*). En este proceso, la variable I''_{V_m} (25) se pondera el doble que N_z (46). Si bien esta última muestra más claramente las vías en zonas no ocultas, la variable de intensidad registra mejor los tramos ocultos por la vegetación. Como resultado de la segmentación, en la mayoría de los casos las vías de comunicación se representan por medio de objetos estrechos y alargados en torno al eje central de las vías. Debido a la forma característica de estos objetos, se considera la opción de emplear alguna de las variables de forma implementadas en *Definiens eCognition*[®]. Después de varias pruebas, la variable *Density* fue la que ofrecía los mejores resultados. Dicha variable describe la distribución en el espacio de los píxeles de un objeto y se calcula a partir del número de píxeles incluidos en el objeto y su radio aproximado en base a la matriz de covarianza (Definiens, 2007). De esta forma, un objeto con forma cuadrada será más denso que un objeto alargado. En este caso, aquellos objetos con un valor de densidad inferior a 0.85 (*criterio 3*) se consideran vías. Para diferenciar la cobertura Pv de la clase Ps se empleó la variable I''_{V_m} (25). Así, aquellos objetos formados por más de 15 píxeles con una $I''_{V_m} \leq 70$ se consideraron Pv (*criterio 4*). De los objetos restantes, aquellos con un tamaño superior a 15 píxeles se consideraron Ps (*criterio 5*). Aquellas áreas representadas por los objetos con un tamaño inferior a 15 píxeles y/o con una densidad > 0.85 se fusionan con las zonas que cumplen el *criterio 6*.

3.2.9.2 Coberturas Sd , Vb y Vr

Una vez identificadas las coberturas Pv y Ps , las coberturas terreno restantes pueden ser *fácilmente* diferenciadas de las coberturas vinculadas a los objetos empleando los valores de altura del nMS_{PR} (1). Teniendo en cuenta los umbrales de estas coberturas en relación a dicha variable (Figura 3.27b) y que la precisión de los MDT es de ≈ 70 cm (Q68.3%) (apartado 3.2.5), se estableció dicho valor como umbral para identificar las zonas susceptibles de ser Sd o Vb (*criterio 6*). Las zonas que cumplen esta condición se unieron a aquellas áreas que no cumplían con los *criterios 3* y *5* descritos en el apartado anterior. A continuación, estas zonas fueron segmentadas empleando el ASM. En este caso, se empleó como única capa *espectral* la variable I''_{PR} (23), una de las más relevantes para la discriminación de estas coberturas según el análisis de la importancia de las variables. Los parámetros empleados fueron $scale=120$, $shape=0.4$ y $compactness=0.5$ (*criterio 7*). Como se comprueba, el valor del parámetro $scale$ es menor que el empleado en el *criterio 4* ya que las zonas que se pretenden identificar en este caso son de menor tamaño y para ello es necesario fijar un umbral para fusionar objetos más restrictivo. Por el contrario, los valores de los otros dos parámetros son mayores. Fue posible aumentar el peso de la forma de los objetos en el proceso de segmentación debido a que existe menos solape *espectral* entre las clases Sd y Vb (Figura 3.27f) que el que presentaban las coberturas Pv y Ps (Figura 3.27i).

Una vez realizada la segmentación, se analizan los valores de las coberturas Sd y Vb en relación a las variables más relevantes (Figura 3.27). A partir de este análisis se observó como la clase Sd presenta valores de intensidad (I''_{PR} (23)) inferiores a 100 mientras que las observaciones de la clase Vb superan este valor. Después de realizar varias pruebas, aquellos objetos con $I''_{PR} \leq 95$ se considerarán Sd (*criterio 8*). Un valor similar de intensidad fue empleado por Antonarakis et al. (2008) para diferenciar las mismas clases. Los objetos descartados en este paso pueden pertenecer a la clase Vb o a la clase Vr . A partir del algoritmo *random forest* se evaluó la posibilidad de diferenciar estas clases a nivel píxel y la precisión que se obtuvo fue del 91% (escenario 2 donde se obtuvieron las variables más relevantes para

diferenciar estas clases). Este análisis reveló que además de las variables nMS_{PR} (1) y nM_{Vm} (3), la información más relevante para diferenciar estas coberturas son las variables de textura de la altura $T\Delta z_{Con}$ (67), $T\Delta z_{Dis}$ (68), $T\Delta z_{Ent}$ (70), $T\Delta z_{S-M}$ (71) y $T\Delta z_{Hom}$ (69); y las variable de rugosidad P (44) y RMS_{Dn} (47). Después de varias pruebas, la variable P (44) fue la que mejores resultados proporcionó. Analizando los valores de esta variable para las dos clases (Figura 3.27h), en general las zonas con Vb no se encuentran en regiones con pendientes superiores a 30° . Finalmente, esta información se empleó para diferenciar las zonas con Vb de aquellas que presentan Vr (*criterio 9*).

A partir del proceso anterior, la clase Vr no queda totalmente definida, pues hasta el momento solo se han identificado aquellas zonas donde la vegetación arbustiva no supera los 70 cm de altura (*criterio 6*). Sin embargo, en la zona de estudio el matorral puede alcanzar los 4 m de altura. Así, el siguiente paso es identificar el resto de zonas susceptibles de contener vegetación arbustiva. Para ello, nuevamente se emplearon los valores de altura de los objetos (nMS_{PR} (1)). Identificadas todas las coberturas terreno y teniendo en cuenta que tanto las edificaciones como la vegetación arbolada (Va y Vm) presentan una altura superior a 2 m, se consideraron zonas con vegetación arbustiva aquellos píxeles no clasificados donde $nMS_{PR} \leq 1.9$ (*criterio 10*). Finalmente, el resto de zonas con vegetación arbustiva, es decir, aquellas con valores de altura entre 1.9 m y 4 m, no pueden ser identificadas todavía debido a la confusión con la clase Ed . Por ello, en primer lugar se identificará esta clase y posteriormente se completará la clasificación de las zonas pertenecientes a la clase Vr .

3.2.9.3 Coberturas Ed , Vm y Va

Después de identificar las clases anteriores, restan las coberturas que no están vinculadas con el terreno. Como primer objetivo se busca clasificar las construcciones y dejar las coberturas relacionadas con el arbolado para el final. A partir del algoritmo *random forest* se analizó la posibilidad de clasificar dichas clases a nivel píxel. La precisión obtenida en este caso fue del 97% (escenario 3). Si bien dicha precisión

es muy difícil de superar, el árbol de decisión que da este resultado es bastante complejo, implicando el uso de 16 variables. Antes de incluirlo en el árbol de procesos de *Definiens eCognition*[®], se analizaron las variables más relevantes para discriminar dichas clases buscando una alternativa. De manera destacada el nM_{Vm} (3) es la variable más relevante. Dicho resultado es completamente lógico ya que la diferenciación de las coberturas Va y Vm pasa inevitablemente por su uso. Adicionalmente, las variables de rugosidad P (44), Std_z (42) y $Std_{\Delta z > 0.7}$ (43) y el ratio RE (41) también mostraron su importancia en la identificación de las coberturas vinculadas a los objetos.

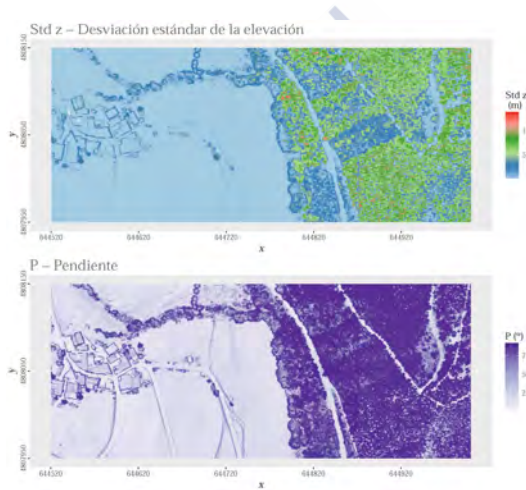


Figura 3.31: Ejemplo de delimitación de contornos de edificaciones en las variables Std_z (42) y P (44).

A partir de las variables anteriores, se observó que tanto la capa Std_z (42) como la P (44) mostraba los límites de las construcciones de manera nítida (Figura 3.31). Si bien muchos estudios han abordado el reto de delinear las edificaciones a partir del nM_{FR} (Wurm et al., 2011, Belgiu et al., 2014), su uso resulta más adecuado para entornos urbanos que para zonas donde la presencia de vegetación arbolada no

es minoritaria como es el caso de los entornos rurales. En base a la experiencia previa de Buján et al. (2012), donde se usó la variable pendiente en una segmentación para aislar las construcciones y facilitar su clasificación en un entorno rural, en este estudio se ejecutó el ASM tomando como base dicha información. Después de varias pruebas, la P (44) ofreció los mejores resultados. Así, los parámetros de segmentación empleados en este caso fueron $scale=55$, $shape=0.3$ y $compactness=0.2$ (criterio 11). A continuación, haciendo uso de otra de las variables anteriores, aquellos objetos con un $RE \geq 0.75$ (Figura 3.27e) y $N_z \leq 25$ (Figura 3.27h) fueron seleccionados como posibles construcciones (criterio 12). Los objetos que cumplían con las condiciones anteriores fueron

fusionados y finalmente se consideraron construcciones aquellos objetos cuya superficie superara los 25 m² (*criterio 13*).

Una vez identificadas las edificaciones, ninguna de las coberturas relacionadas con el arbolado se solapan con la clase V_r en relación al nMS_{PR} (1) (Figura 3.27b). Así, el siguiente paso es clasificar como V_r aquellos píxeles con $nMS_{PR} \leq 4$ m (*criterio 14*). Este mismo umbral fue empleado por Riaño et al. (2003) para diferenciar la vegetación arbolada del resto de vegetación. Las dos operaciones siguientes emplean una función característica de *Definiens eCognition*[®] que identifica objetos de una determinada clase encerrados por objetos de otra clase. Una vez realizada esta identificación, los primeros pueden ser re-asignados a otra clase. En primer lugar, esta función se empleó para mejorar el resultado de la identificación de las zonas que presentan vegetación arbustiva. Así, aquellos objetos clasificados como V_b que agrupen menos de 5 píxeles y se encuentren rodeados por píxeles clasificados como V_r , pasan a ser V_r (*criterio 15*). Esta función se empleó nuevamente con el propósito de mitigar el efecto *salt and pepper* ocasionado por la clasificación a nivel píxel de la cobertura V_r y por la existencia de píxeles aislados de la clase V_b . De manera similar al caso anterior, aquellos grupos de píxeles de la clase V_r o V_b formados por menos de 5 píxeles y que se encuentren encerrados por objetos que todavía no han sido clasificados pasan a ser *no-clasificados* (*criterio 16*).

Finalmente, los píxeles *no-clasificados*, es decir, aquellos que cumplen el *criterio 16* y los que presentan una altura superior a 4 m, serán clasificados como V_a o V_m . La principal diferencia entre estas coberturas es la existencia o no de matorral bajo el arbolado. En este punto, para establecer el siguiente criterio se ha tenido en cuenta el resultado de *random forest* a nivel píxel (*escenario 3* donde se calculó la importancia de las variables para diferenciar las clases Ed , V_a y V_m - $E_{OOB}=3.01\%$) y los valores de estas coberturas en relación a la variable nM_{V_m} (3) (Figura 3.27a). Así, se realizó una clasificación a nivel píxel empleando la variable nM_{V_m} (3). Para establecer el umbral se observó como el límite de alturas de estas coberturas en relación a la variable nM_{V_m} (3) se encuentra próximo a los 0.8 m, valor similar al error que presenta el MDT ($Q_{68.3\%} \approx 0.70$ m). Tras realizar varias pruebas, aquellos píxeles donde $nM_{V_m} \geq 1$ serán clasificados como V_m mientras que el resto se

considerará V_a (*criterio 17*).

3.2.10 Evaluación de la precisión

La necesidad de dar respuesta a la creciente demanda de productos cartográficos con requerimientos de precisión específicos ocasionó un aumento de la complejidad de los procesos de clasificación. El resultado de estos procesos constituye una representación simplificada de la realidad. Toda generalización lleva aparejada la pérdida de información y es inevitable la existencia de errores en dichos productos. Esta situación provocó que los métodos para evaluar la precisión de los resultados llegaran a considerarse de vital importancia, pues su empleo comercial únicamente es posible si su calidad es conocida (Rwanga y Ndambuki, 2017). Sin embargo, la evaluación de la precisión de estos productos no sólo es importante como guía para decidir si la calidad de un producto se adapta a una determinada aplicación sino que también permite evaluar si dichos errores pueden trasladarse a análisis donde esa información es usada (Foody, 2002).

Los primeros métodos que se emplearon para evaluar las discrepancias entre la representación de la realidad y la propia realidad eran fundamentalmente subjetivos pues se basaban en inspecciones visuales. Sin embargo hoy en día, se emplean medidas estadísticas que proporcionan valores de precisión objetivos. En esta línea, la matriz de confusión es el método más empleado para cuantificar la precisión del resultado de una clasificación (Foody, 2002). Esta matriz se construye a partir de una muestra de observaciones. Tras comparar la cobertura real de cada elemento de la muestra (j) con la cobertura asignada tras la clasificación (i), se obtiene una matriz cuadrada donde las columnas representan la *verdad terreno* y las filas el resultado de la clasificación. Cada celda de la matriz indica el número de observaciones en el mapa asignadas a una categoría en relación a la *verdad terreno* (n_{ij}). Los elementos de la diagonal principal de la matriz representan la cantidad de aciertos mientras que el resto de elementos indican los errores. La matriz de observaciones de la Figura 3.32 es un ejemplo teórico de matriz de confusión. Teniendo en cuenta la recomendación realizada por Olofsson et al. (2014), los el-

elementos de esta matriz se transformaron en proporciones de población (p_{ij}) a partir de la Ecuación 3.14. p_{ij} representa la proporción del área de estudio que pertenece a la cobertura i en el mapa y a la cobertura j en el mundo real. Un ejemplo teórico de esta matriz de población se incluye en la Figura 3.32.

$$p_{ij} = \frac{n_{ij}}{\sum_{j=1}^J n_{ij}} \cdot \frac{N_i}{\sum_{i=1}^J N_i} \tag{3.14}$$




Figura 3.32: Matriz de confusión tradicional y conversión a matriz de población estimada. En color magenta se marcan los elementos que se tienen en cuenta para el cálculo de las medidas de acuerdo y en naranja los que intervienen en el cálculo de las medidas de desacuerdo.

A partir de la matriz anterior es posible calcular una serie de estadísticos que reflejan cuantitativamente el acuerdo entre la realidad y el resultado de la clasificación. Entre los más empleados, destacan los siguientes: la precisión general (P), precisión del usuario (P_U), precisión del productor (P_P) y el coeficiente Kappa (Brennan y Webster, 2006, Antonarakis et al., 2008, Dengsheng et al., 2010).

En este contexto, la *precisión general* representa la proporción de observaciones clasificadas correctamente y se obtiene a partir del sumatorio de los elementos de la diagonal principal de la matriz de población (Ecuación 3.15). Si $P=1$ existe un acuerdo perfecto entre

los datos de referencia y la clasificación.

$$P = \sum_{j=1}^J p_{jj} \quad (3.15)$$

Adicionalmente, para representar la precisión a nivel clase se distinguen dos vías: en base a la *verdad terreno*, donde se tienen en cuenta además de la celda que se corresponde con la diagonal principal, los marginales de las columnas de la matriz de población para calcular la medida denominada *precisión del productor*; y en base a la clasificación, donde en lugar de considerar los marginales de las columnas se emplean los de las filas de la matriz de población para calcular la medida denominada *precisión del usuario*. La P_P es la medida complementaria a los errores de omisión y refleja cuan bien los tipos de coberturas reales pueden ser clasificados, es decir, la probabilidad de que la clase j real sea identificada mediante la clasificación (Ecuación 3.16). En cuanto a la P_U , es la medida complementaria de los errores de comisión y representa como de bien coincide un elemento clasificado con su correspondiente clase en el mundo real, es decir, la probabilidad de que una zona determinada del mapa identificada como clase i realmente pertenezca a dicha clase (Ecuación 3.17).

$$P_P = p_{jj} / \sum_{i=1}^J p_{iJ} \quad (3.16)$$

$$P_U = p_{ii} / \sum_{j=1}^J p_{Jj} \quad (3.17)$$

Es habitual que de manera previa a la clasificación se establezca una *precisión objetivo* que marcará el valor mínimo aceptable de precisión. Generalmente se considera que el resultado de una clasificación es suficientemente preciso si P es igual o superior a la *precisión objetivo*. Sin embargo, algunos investigadores consideran esta comparación insuficiente y recomiendan el cálculo de intervalos de confianza para cada

una de las medidas de precisión citadas y que sean tenidos en cuenta a la hora de evaluar la idoneidad de una clasificación (Foody, 2008, Olofsson et al., 2014). Para calcular los intervalos de confianza al 95%, en primer lugar se obtuvo la varianza de las medidas P , P_U y P_P aplicando las ecuaciones 5 ($\hat{V}(P)$), 6 ($\hat{V}(P_U)$) y 7 ($\hat{V}(P_P)$) incluidas en el estudio de Olofsson et al. (2014) y posteriormente se multiplicó la raíz cuadrada de dichas varianzas por 1.96.

En base a la consideración de que los valores de las medidas que se basan en el porcentaje de elementos correctamente clasificados en ciertos casos pueden ser debidos al azar y no a un acuerdo real entre la *verdad terreno* y el resultado de la clasificación, se emplea como medida de precisión complementaria el coeficiente Kappa de Cohen (1960) (K). Se trata de una medida más robusta que un simple porcentaje de acuerdo puesto que en el cálculo de K se tiene en cuenta el acuerdo que puede deberse al azar.

A pesar de que el coeficiente Kappa se considera una medida "vital" para evaluar la precisión de mapas temáticos o clasificaciones obtenidos a partir de datos procedentes de sensores remotos (Congalton y Green, 2009), en la última década ha sido objeto de múltiples críticas (Foody, 2008, Wu et al., 2009, Salk et al., 2018). Este coeficiente es considerado una medida conservadora al sobrestimar el acuerdo debido al azar lo que produce a su vez que la precisión de la clasificación representada por esta medida sea inferior a la real (Wu et al., 2009). Además de esta limitación, probablemente una de las críticas más repetidas sobre el uso del coeficiente Kappa sea que no proporciona información adicional a la ofrecida por el porcentaje de aciertos (P), desestimándose su uso (Liu et al., 2007). En este sentido, uno de los estudios más interesantes y críticos tal vez sea el elaborado por Pontius y Millones (2011) (*Death to Kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment*). Dichos autores se basan en tres razones para no usar K como medida de la precisión de una clasificación: 1) K es un ratio y en determinadas circunstancias (p. ej. denominador=0) su interpretación es difícil; 2) la información que ofrece no permite identificar de forma simple características de los conflictos a fin de mejorar los resultados de la clasificación; 3) el efecto del azar en el valor de medidas como la precisión general se consideran irrelevantes y

por tanto no hay necesidad de corregir este efecto.

Considerando los argumentos expuestos, Pontius y Millones (2011) propuso como alternativa al coeficiente Kappa dos estadísticos, que a diferencia de los anteriores no se centran en medir el acuerdo entre los datos de referencia y la clasificación sino el desacuerdo: desacuerdo por cantidad (Q) y desacuerdo por localización (A). Estos autores demostraron que analizar los errores proporciona información adicional a la ofrecida por las medidas de acuerdo y puede ser de gran utilidad para mejorar los resultados de la clasificación. Estudios recientes han reforzado esta idea (Maxwell et al., 2015, Alonso-Benito et al., 2016, Salk et al., 2018).

El desacuerdo por cantidad de una categoría g (q_g) representa las diferencias entre los datos de referencia y la clasificación en relación a la *superficie* que ocupa la cobertura g (Ecuación 3.18). En el caso de que la proporción de superficie real de una cobertura g sea igual a la del mapa, $q_g=0$. El desacuerdo general por cantidad (Q) se obtiene dividiendo entre 2 el sumatorio de los q_g de todas las coberturas (Ecuación 3.19)⁵. Así, esta medida representa la diferencia general entre los datos de referencia y la clasificación en relación a la superficie.

$$q_g = \left| \left(\sum_{i=1}^J p_{ig} \right) - \left(\sum_{j=1}^J p_{gi} \right) \right| \quad (3.18)$$

$$Q = \frac{\sum_{g=1}^J q_g}{2} \quad (3.19)$$

Por otro lado, el desacuerdo por localización de una categoría g (a_g) representa las diferencias entre los datos de referencia y la clasificación en relación a la *distribución espacial* de la cobertura g (Ecuación 3.20). El desacuerdo general por localización (A) se obtiene dividiendo entre 2 el sumatorio de los a_g de todas las coberturas (Ecuación 3.21). Así,

⁵Se divide entre dos debido a que la sobrestimación de una categoría viene acompañada de la subestimación de otra, de forma que la misma proporción de desacuerdo es incluida dos veces en el sumatorio.

esta medida representa la diferencia general entre los datos de referencia y la clasificación en relación a la distribución espacial de las coberturas evaluadas de forma conjunta.

$$a_g = 2 \cdot \min\left[\left(\sum_{i=1}^J p_{ig}\right) - p_{gg}, \left(\sum_{j=1}^J p_{gi}\right) - p_{gg}\right] \quad (3.20)$$

$$A = \frac{\sum_{g=1}^J a_g}{2} \quad (3.21)$$

Finalmente, la suma de Q y A da como resultado el error general de la clasificación (D), medida complementaria de la precisión (Ecuación 3.22.)

$$D = 1 - P = Q + A \quad (3.22)$$

En este estudio, se seleccionaron aleatoriamente 800 puntos de referencia (100 observaciones por cobertura) para comprobar la precisión de las clasificaciones. En el Anexo C.2 se describe tanto el material como la metodología empleada para seleccionar estos puntos. Aclarar que esta muestra es independiente de la muestra de referencia empleada en la fase de entrenamiento. A continuación, a partir de los resultados de las clasificaciones, se extrajo la clase a la que fueron asignados dichos puntos, se construyó la matriz de confusión y se transformó ésta a partir de la Ecuación 3.14 tal y como se indica en Pontius y Millones (2011). Finalmente, a partir de esta matriz se calculan las medidas de acuerdo y desacuerdo definidas en la revisión previa. Este proceso se realizó tanto para el resultado de la clasificación empleando la nube de puntos original como para los obtenidos a partir de las nubes de puntos con densidad reducida.

3.3 Resultados y discusión

3.3.1 Evaluación de la normalización de la intensidad

Como primer paso para evaluar los resultados de la normalización de la intensidad se llevó a cabo una inspección visual de la intensidad original (Figura 3.33a) en comparación con la imagen resultante del proceso de normalización (corrección por el rango + corrección por el ángulo de escaneo + filtro de paso bajo + expansión del histograma) (Figura 3.33b). Dicho análisis se centró en aquellas zonas que presentan algún conflicto: 1) solape entre pasadas; 2) y 3) bandeado por el patrón de escaneo del sensor; y 4) áreas sin datos.

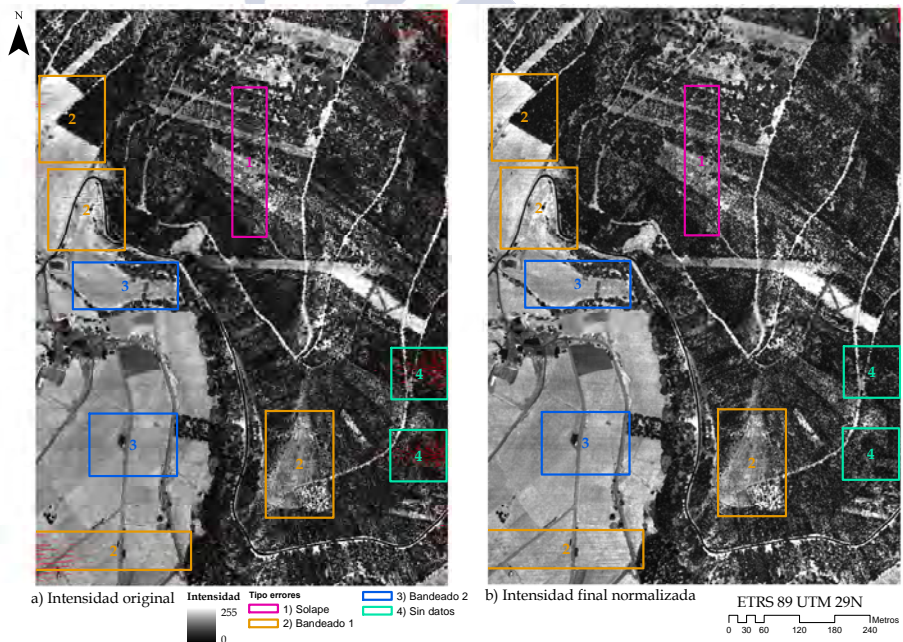


Figura 3.33: Resultados de la corrección de la intensidad.

En la Figura 3.33, recuadro rosa (1), se observa una leve diferencia de los valores de intensidad entre pasadas. Este error puede ser debido a la confluencia de varios factores: al patrón de escaneo en "Z" del


sensor Leica ALS50-II, lo que ocasiona un considerable aumento de la densidad de puntos y a que el ángulo de escaneo es máximo en esta zona. En el borde de las pasadas, los puntos se agrupan formando líneas, aumentando el número de puntos en las celdas donde estos puntos se localizan y por tanto el peso que su intensidad tiene en el valor final de dichas celdas. Sin embargo, las zonas arboladas tienen un comportamiento homogéneo en relación a la reflectividad lo que produce que su efecto sobre la imagen de intensidad no sea muy evidente. Tras el proceso de normalización de la intensidad (Figura 3.33b) este efecto fue mitigado. En los estudios realizados por Mesas-Carrascosa et al. (2012) y Yan y Shaker (2014), también se dio esta circunstancia, sin bien en el primer caso no se citaron las posibles causas por las que se puede estar dando este fenómeno, en el segundo se relacionó con la pendiente de la superficie de impacto. En ambos casos, tras la normalización de la intensidad, este error fue mitigado pero no depurado totalmente.

En referencia al efecto de bandeo presente en la imagen de intensidad original, se distinguen dos tipos. El primero se relaciona con el patrón de escaneo, lo que produce, tal y como ya se mencionó, que los puntos LiDAR se dispongan en línea aumentando la densidad de puntos en unas celdas en perjuicio de las celdas vecinas (recuadros naranja en la Figura 3.33). Tras la normalización, este efecto se suavizó en algunas zonas (recuadros naranja situados en la esquina superior izquierda) mientras que dicho efecto persistió en otras (recuadro naranja situados en la esquina inferior izquierda). El segundo tipo de bandeo se vincula al efecto del relieve del terreno y ángulo de incidencia del láser (recuadros azul en la Figura 3.33). Este efecto fue totalmente corregido tras la normalización. El efecto de bandeo también se observó en el estudio realizado por Yan y Shaker (2014), y en su caso además de relacionarlo con discrepancias en el solape entre pasadas también lo vinculó con la orientación de la superficie de impacto. Finalmente, las celdas sin datos (píxeles en rojo en la Figura 3.33) fueron corregidas gracias a la aplicación del filtro de paso bajo en estas celdas (recuadros verde en la Figura 3.33).


La Figura 3.34 se elaboró con dos propósitos: por un lado mostrar el efecto del método propuesto por Yan (2012) para mitigar la excesiva corrección de la intensidad; y por otro lado, el efecto de la normalización

en función del rango (escala de color). Para elaborar estas gráficas se seleccionaron aleatoriamente 100 puntos LiDAR con valores originales de intensidad entre 70 y 71 (círculos azul). A continuación, se representaron dichos puntos considerando la intensidad normalizada obtenida a partir de la Ecuación 3.1 sin aplicar el método de Yan (2012) para abordar el problema de la excesiva corrección de la intensidad (Figura 3.34a); corrigiendo este efecto en superficies cuya pendiente es superior a 35° (Figura 3.34b) y reduciendo este umbral de pendiente hasta los 30° (Figura 3.34c). En la primera gráfica de la Figura 3.34 se comprueba la existencia de la excesiva corrección de la intensidad identificado por Yan (2012). En dicha gráfica se observa como los valores de intensidad corregidos aumentan a medida que crece el ángulo de incidencia, llegando a superar éstos a los valores de intensidad originales cuando $\alpha_i > 55^\circ$. Para corregir este efecto, Yan (2012) propuso sustituir el ángulo de incidencia por el ángulo de escaneo en la Ecuación 3.1 a partir de ángulos de incidencia entre 30° y 40° .


En la Figura 3.34b se muestran los resultados de esta corrección al fijar dicho umbral en 35° (puntos coloreados en tonos naranja). En este punto se aprecia claramente un "escalón" en los valores de intensidad corregidos. Este resultado fue el motivo por el cual el umbral del ángulo de incidencia se redujo hasta los 30° (Figura 3.34c), favoreciendo la continuidad en los valores de intensidad corregidos. Estos resultados refuerzan los obtenidos por Yan (2012) y ponen de manifiesto la necesidad de llevar a cabo este tipo de análisis para identificar el valor del ángulo de incidencia más adecuado para mitigar las excesiva corrección de la intensidad. Por otro lado, imitando el análisis realizado por García et al. (2010), estas gráficas también muestran el efecto de la normalización al variar el rango. Partiendo de puntos con la misma intensidad original (entre 70 y 71) y con independencia del ángulo de incidencia, se aprecia como aquellos puntos con menor elevación (mayor rango) presentan mayores valores de intensidad normalizada que los puntos más cercanos al sensor (menor rango). Este mismo efecto se observó en el estudio de García et al. (2010), aunque en su caso únicamente se normalizó la intensidad por el rango. A partir de ángulos de incidencia superiores a 30° en Figura 3.34c se comprueba que tampoco existen patrones de comportamiento en relación al ángulo de escaneo, hecho que refuerza la evidencia de Coren y Sterzai (2006) acerca de que



(a) Excesiva corrección de la intensidad.



(b) Mitigación de la excesiva corrección de la intensidad para $\alpha_i \geq 35^\circ$



(c) Mitigación de la excesiva corrección de la intensidad para $\alpha_i \geq 30^\circ$

Figura 3.34: Comparación de la intensidad original (círculos azul) con el resultado de las correcciones en función del ángulo de incidencia y el rango (puntos sombreados).

la intensidad no se ve afectada cuando el ángulo de escaneado es inferior a 10° .

Varios estudios han demostrado que la homogeneización de los valores de intensidad mediante procesos de normalización puede mejorar la caracterización de las coberturas del suelo y por tanto su identificación por medio de un proceso de clasificación (Habib et al., 2011, Mesas-Carrascosa et al., 2012). Para comprobar que la heterogeneidad de los

valores de intensidad se ha reducido tras la normalización, se llevó a cabo un análisis similar a los realizados por Mesas-Carrascosa et al. (2012) y Yan y Shaker (2014). Para ello se identificaron 56 muestras cuadradas de 5 m de lado representativas de las coberturas arbolado, construcciones, matorral, pistas de tierra, carreteras, suelo desnudo y vegetación baja (8 muestras por tipo de cobertura). Su distribución en el área de estudio se realizó tomando como base la ortoimagen y el MDS. A partir de los puntos incluidos en cada muestra cuadrada se calculó el coeficiente de variación de los valores de intensidad antes (CV_I) y después de la normalización ($CV_{I''}$). La Figura 3.35 incluye el coeficiente de variación para cada cobertura y muestra. Las barras representan el CV_I de la intensidad no normalizada mientras que la línea continua azul refleja el $CV_{I''}$ de la intensidad normalizada.




Figura 3.35: Comparación del coeficiente de variación de intensidad antes y después de su normalización en relación a diferentes coberturas del suelo.

De entre todas las coberturas analizadas, las zonas con arbolado son las que presentan la mayor variabilidad en relación a la intensidad. Esta situación se debe tanto a la heterogeneidad de *materiales* que forman esta cobertura como a el reducido nivel de *planaridad* que presentan (Yoon et al., 2008, Yan, 2012). Los resultados incluidos en la Figura 3.35 muestran una mejoría del CV de $\approx 40\%$ en zonas arboladas y de $\approx 60\%$ en las muestras con vegetación baja. En teoría, estas últimas zonas se caracterizan por presentar valores homogéneos de intensidad, sin embargo los datos en zonas de vegetación baja empleados en esta

investigación son los que se ven más afectados por errores de registro de la intensidad, tal y como se pudo ver en la Figura 3.33. Estos resultados son muy diferentes a los obtenidos por Jutzi y Gross (2010) y Mesas-Carrascosa et al. (2012), donde las zonas forestales y los pastizales tras la normalización de la intensidad no mostraron mejoría en relación al CV. Mesas-Carrascosa et al. (2012) atribuyó estos resultados a que las muestras en estas zonas no eran puras, incluyendo píxeles con sombras y suelo desnudo, dando como resultado altos valores de desviación típica que enmascararon el efecto de la normalización de la intensidad.

En general, los tejados de las edificaciones presentan una notable mejoría del CV tras la normalización de la intensidad. Los resultados para estas zonas, incluidos en la Figura 3.35, permiten apreciar varias casuísticas. En primer lugar, la muestra con el valor más bajo del CV_I (0.1) se corresponde con una cubierta formada por un único plano (muestra 10). Aunque esta muestra presenta el menor CV_I y el ángulo de incidencia es pequeño, la mejoría tras la normalización es la mayor entre las muestras de edificaciones ($\approx 60\%$). En el extremo opuesto se encuentran las muestras que se corresponden con las cubiertas más complejas (intersección de varios planos con diferente orientación y/o pendiente) (muestras 9, 12 y 15 con CV_I igual a 0.5, 0.5 y 0.34 respectivamente), donde las mejoras del CV son menores (20%, 30% y 45%, respectivamente).

Por otro lado, las muestras en zonas de matorral, salvo la muestra 19, presentan una variabilidad similar a la de las cubiertas de las edificaciones. Esta similitud puede ser debido a que muchas de estas zonas son bastante homogéneas en relación a la altura y a la especie. En estas zonas, la mejora media del CV es $\approx 50\%$. Finalmente, las muestras con los menores CV_I son las que se corresponden con las pistas de tierra, suelo desnudo y carreteras asfaltadas (CV medios originales de 0.13, 0.15 y 0.19, respectivamente). Aunque presentan bajos valores de intensidad y pequeños ángulos de incidencia, la mejora del CV es similar al que presentan el resto de coberturas (54%, 40% y 41%, respectivamente).

A modo de resumen, los análisis realizados para evaluar los resultados de la normalización de la intensidad indican que dicho proceso ha permitido mejorar la información referente a la intensidad, disminuyendo

la variabilidad en todas las coberturas analizadas. Adicionalmente, con el propósito de mitigar la excesiva corrección de la intensidad al emplear el ángulo de incidencia, se puso de manifiesto la necesidad de determinar para cada estudio y conjunto de datos el valor del umbral de pendiente más apropiado.

3.3.2 Análisis de la importancia de las variables

Existen múltiples métodos que permiten identificar las variables más relevantes para diferenciar coberturas del suelo mediante procesos automáticos de clasificación. En este estudio se empleó el algoritmo *random forest*. El análisis de los resultados de la IV se centrará en tres puntos clave: 1) en un contexto global; 2) en un contexto por categoría; y 3) considerando diferentes escenarios.

En relación al **contexto global**, se consideraron las 72 variables y las 8 coberturas del suelo al ejecutar el el algoritmo *random forest*. El resultado de este proceso se incluye en la Figura 3.36. Para facilitar la interpretación de los resultados, los 5 bloques de variables se representan por medio de colores. Así, las variables de elevación/altura se muestran en color magenta; las variables en base a la intensidad en color azul; en verde las que se basan en los retornos; en malva las de rugosidad y en naranja las de textura. Guan et al. (2013) evaluaron la importancia de varios bloques de variables (12 variables de la altura LiDAR, 9 variables de intensidad LiDAR y 27 variables a partir de valores medios y textura de 3 bandas espectrales) para diferenciar 4 coberturas del suelo (árboles, suelo desnudo, edificios y vegetación baja). A partir de sus resultados no es posible identificar los bloques más relevantes ya que no se aprecian grandes diferencias entre variables. Sin embargo, en la Figura 3.36 sí es posible hacer este análisis. De esta forma, se observa como dos de las variables de altura son las más relevantes (color magenta). También las variables de textura en base a la altura (color naranja) presentan un alto nivel de importancia junto a la gran mayoría de las variables de intensidad (color azul). De manera más irregular, algunas de las variables basadas en los retornos (color verde) y la rugosidad (color malva) también se muestran relevantes. Por otro lado, gran parte de

las variables de altura y textura de la intensidad, y la totalidad de las variables de textura de la elevación muestran niveles de importancia bajos.




Figura 3.36: Importancia de las variables a escala global usando *Random Forest* (empleando la nube de puntos original). $E_{OOB}=10.76\%$

Tal y como se mencionó previamente, la IV se representa por medio del error OOB (*OOB mean decrease in accuracy*). De acuerdo a estos

valores y de manera destacada, el nM_{Vm} (3) y el nMS_{PR} (1); y a continuación las variables de textura $GLCM T\Delta z_{\sigma^2}$ (66) y $GLCM T\Delta z_{\mu}$ (65) son las variables más relevantes. En relación a las primeras, se esperaba que desempeñaran un papel destacado, pues el nMS_{PR} (1) se considera fundamental para diferenciar las coberturas vinculadas al terreno de las que se relacionan con los objetos (Im et al., 2008a, Sasaki et al., 2012, Buján et al., 2013b), además se ha mostrado como una de las variables LiDAR a partir de análisis de IV Chehata et al. (2009), Guo et al. (2010), Niemeyer et al. (2014); mientras que el nM_{Vm} (3) en teoría podrían facilitar la identificación de las zonas que presentan o no matorral, fundamentalmente bajo arbolado. A continuación, las variables que se presentan más relevantes se encuentran relacionadas con los retornos, caso de RE (41), con la intensidad de los datos LiDAR (I''_{PR} (23), I''_{UR} (24) y I''_{Vm} (25)), la rugosidad por medio de la pendiente (P (44)) y la textura de la intensidad ($GLCM I''_{\mu}$ (49)).

En el extremo opuesto se encuentran las variables de elevación que representan los intervalos de densidad (RDB_{1-8} (5-12)) y los coeficiente de asimetría (CA (21)) y curtosis (CC (22)). Los intervalos de densidad fueron empleados por Alonso-Benito et al. (2016) para identificar tipos de combustible en un entorno forestal. Tres de los tipos de combustibles que identificaron, para los que obtuvieron buenos resultados, presentan muchas similitudes con las clases Va y Vm . Sin embargo, aquí se muestran como poco importantes. Este resultado puede ser debido a que en el estudio de Alonso-Benito et al. (2016) eran las únicas variables que proporcionaban información sobre la existencia de vegetación bajo arbolado mientras que en el estudio que aquí se presenta, y a la vista de los resultados, existen variables con mayor potencial para dicha tarea. En el análisis del escenario 3, al final de este apartado, se hará referencia a la poca relevancia que han mostrado estas dos últimas variables.

Por otro lado, las Figuras 3.37 y 3.38 muestran la importancia de las diferentes variables para cada una de las coberturas (**contexto por categoría**). En primer lugar se observa como las variables relacionadas con la intensidad (barras azul) presentan una importancia mucho mayor para las coberturas terreno (Pv , Ps , Sd y Vb - Figura 3.37) que para las vinculadas a objetos (Va , Vm y Ed - Figura 3.38). A medio camino entre ambos grupos se encuentra la clase Vr , cuyas características se solapan

con ambos grupos. La importancia de la intensidad para identificar las coberturas *terreno* fue puesta de manifiesto por Song et al. (2002), donde analizaron la reflectividad de los pulsos LiDAR en relación a diferentes coberturas, entre las que se encontraban el asfalto, el suelo desnudo y la vegetación baja. El contenido de clorofila de la vegetación baja o los cultivos dan como resultado altos valores de intensidad al emplear longitudes de onda en el infrarrojo cercano, mientras que las zonas de suelo desnudo presentarán baja reflectividad y por tanto bajos valores de intensidad. Posteriormente, Guan et al. (2013) también analizaron por medio del algoritmo *random forest* qué variables tenían mayor impacto en la identificación de clases como el suelo desnudo o la vegetación baja. Si bien la variable $GLCM I''_{\mu}$ se encontraba entre las 10 variables más relevantes, el nMS_{PR} se situaba claramente como la variable más importante. Estos mismos resultados se observan en las Figuras 3.37a y 3.37b.

A diferencia del caso anterior, ni las variables relacionadas con la textura ni las vinculadas a la altura presenta una relevancia destacada en relación a las coberturas Pv y Ps . Sin embargo, llama la atención la importancia de la variable N_z (46) con respecto a la clase Ps (Figura 3.37d) y no para la clase Pv , donde I''_{V_m} (25) es la variable más relevante (Figura 3.37c). La importancia de N_z también la observaron Guan et al. (2013), aunque es su caso dicha variable se mostró relevante para la clase *terreno*, la cuál estaba compuesta fundamentalmente por vías pavimentadas. Adicionalmente, en el caso de la cobertura Ps se observa un aumento de la importancia de las variables relacionadas con la rugosidad ($Std Z$ (42) o P (44)) en perjuicio de las variables de intensidad. Una posible explicación puede ser las características del entorno donde se encuentran y el material del que están compuestas unas y otras. En el caso de las pistas forestales, éstas se localizan en zonas con orografía compleja y en sus márgenes se encuentra más cantidad de vegetación y más densa que en el caso de las vías pavimentadas, generalmente ubicadas en zonas menos abruptas y más desprovistas de vegetación. Adicionalmente, el material de estas últimas suele ser bastante uniforme y su reflectividad baja, mientras que las pistas forestales presentan características más heterogéneas. Tal vez esta pueda ser la explicación a que variables relacionadas con la rugosidad tengan más relevancia con éstas últimas y variables de intensidad tengan mayor

importancia en el caso de las vías pavimentadas.

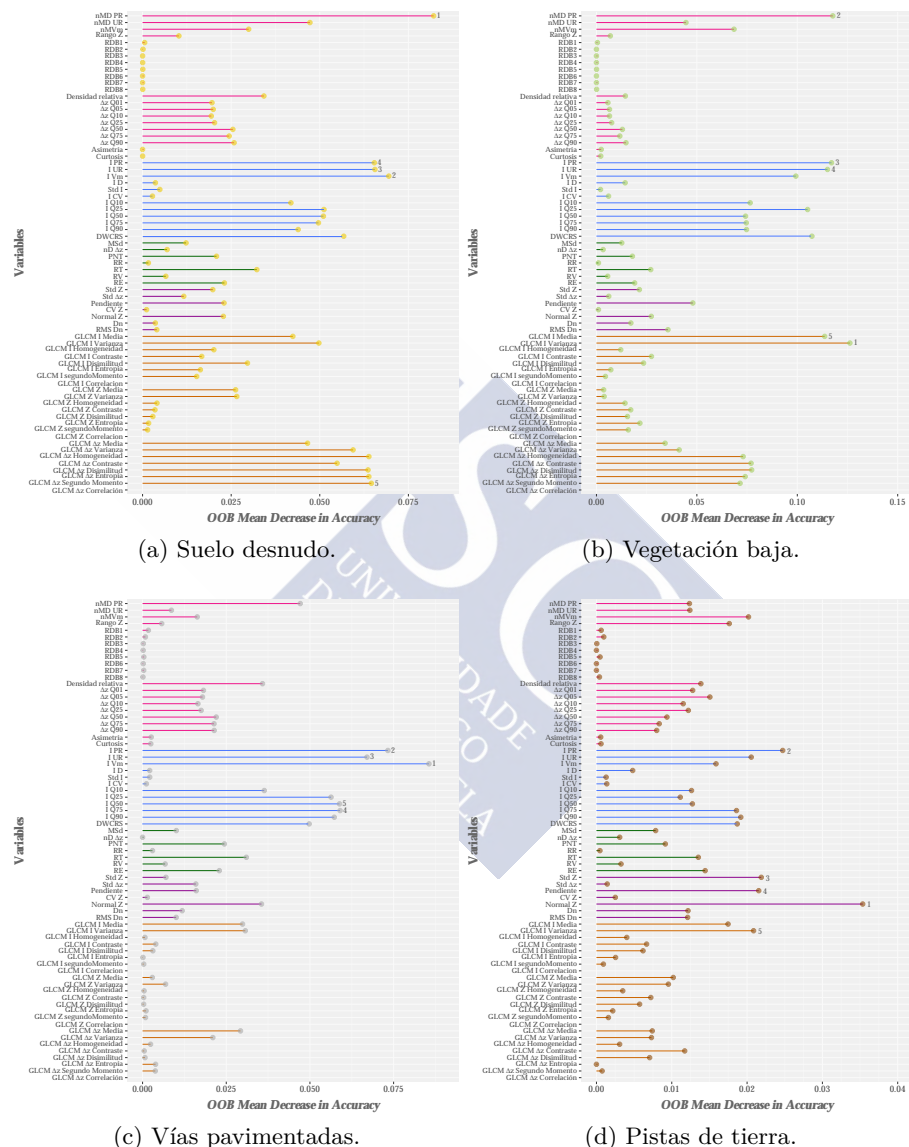


Figura 3.37: Importancia de las variables en función de la cobertura usando *Random Forest* (empleando la nube de puntos original) (Parte I).

Las coberturas vinculadas a los *objetos* se caracterizan por presentar un grupo muy reducido de variables relevantes mientras que el resto presenta muy poca importancia. Las variables RE (41) y nM_{Vm} (3) son claramente las más destacadas para las clases Ed y Vm , respectivamente (Figuras 3.38a y 3.38c). En el caso de la cobertura *vegetación arbolada*, nMS_{PR} (1), $GLCM T\Delta z_{\mu}$ (65), nM_{Vm} (3) y $GLCM T\Delta z_{\sigma^2}$ (66) son por este orden las variables más importantes (Figura 3.38b). Además de ser un grupo muy reducido, en el caso de las clases Ed y Vm también son muy específicas. El *ratio retorno edificación* (RE (41)) en el caso de las edificaciones es un caso muy claro. Esta variable es una adaptación de la propuesta originalmente por Kim y Sohn (2010), donde a diferencia del ratio original, en este caso únicamente se consideraron como *únicos retornos* aquellos puntos cuya altura se encontraba entre 2 y 12 m a fin de evitar valores altos de esta variable en masas forestales densas. A priori dicha modificación no fue contraproducente a la vista del resultado obtenido en el cálculo de la IV. En el caso de esta cobertura destaca la poca importancia que presentan las variables relacionadas con la altura, principalmente nMS_{PR} (1), pues en estudios previos se mostraron como las más influyentes para la identificación de edificaciones (Chehata et al., 2009). Por otro lado, se esperaba que el nM_{Vm} (3) se mostrase como una de las variables más relevantes para la *vegetación mixta*, aunque no era la única la que podía revelar la presencia de vegetación bajo arbolado, pues menos los modelos normalizados de altura, el resto de variables de altura podían desempeñar esta función (por lo menos en teoría). En relación a esta cobertura, también se observa una ligera importancia de las variables de rugosidad (P (44), $Std_{\Delta z > 0.7}$ (43) y $Std Z$ (42)), probablemente debido a la presencia de mayor cantidad de retornos múltiples que en la mayoría de coberturas.

Finalmente, si se comparan los resultados de la IV de la cobertura Vr (Figura 3.37c) con las gráficas de las clases Sd , Vb , Pv y Ps (Figuras 3.37a a 3.37d) y con las de Ed , Va y Vm (Figuras 3.38a a 3.38c), se observa como la IV de la cobertura Vr es similar a la de las clase Sd y Vb en relación a la relevancia de las variables de altura nMS_{PR} (1) y nM_{Vm} (3), variables que pueden ser fundamentales para diferenciar entre estas 3 coberturas. También presenta similitudes con los resultados para la cobertura Va con respecto a la importancia de la textura de la altura y por otro lado, también a la pérdida de importancia de las variables de



Figura 3.38: Importancia de las variables en función de la cobertura usando *Random Forest* (empleando la nube de puntos original) (Parte II).

intensidad como en el caso de las pistas de tierra. En este último caso, dicha pérdida es en favor de variables de altura y no de rugosidad como se observó en el análisis de variables de la clase Ps .

Por último, se analizó la importancia de las variables para separar diferentes coberturas del suelo. Para ello **se consideraron tres escenarios**: *escenario 1*, diferenciar las coberturas Vb , Sd , Ps y Pv (Figura 3.39); *escenario 2*, diferenciar Vb de Vr (Figura 3.40); y por último, *escenario 3*, identificación de las coberturas Ed , Va y Vm (Figura 3.41). Adicionalmente, se incluye en el título de cada figura el error de clasificación (E_{OOB}) obtenido a partir del algoritmo *random forest*.

Como primer escenario se consideraron las cuatro coberturas *terreno* (Vb , Sd , Ps y Pv). De acuerdo a los resultados del análisis de la IV (Figura 3.39) se vuelve a poner de manifiesto la relevancia de la intensidad para discriminar las coberturas *terreno* y la poca importancia de las variables de en base a la altura, a los retornos y a la rugosidad. En este último caso, existen tres excepciones, las variables N_z (46), $Std Z$ (42) y P (44). Estas variables ya mostraron en el análisis de coberturas individuales su relevancia para la identificación de la clase Ps (Figura 3.37d). A pesar de la gran cantidad de variables calculadas, la imagen de intensidad tradicional (I'_{PR} (23)) se mantiene como la información por excelencia para diferenciar las coberturas *terreno* en el caso de usar datos LiDAR. Im et al. (2008a) mediante un análisis de sensibilidad para identificar la contribución de diferentes variables para la identificación de 5 coberturas entre las que se encontraban vías pavimentadas y zonas con vegetación baja, concluyeron que la intensidad es un atributo crítico en los procesos de clasificación donde únicamente se emplean datos LiDAR. Esta variable resultó ser una pieza clave para diferenciar coberturas que presentan valores similares de altura, como son las zonas pavimentadas y las áreas con vegetación baja. Más recientemente, Matikainen et al. (2017) analizaron en qué medida el empleo de datos LiDAR multi-espectrales (3 bandas) permite disminuir la confusión entre las coberturas asfalto, gravilla, vegetación baja y zonas rocosas en comparación con los resultados obtenidos a partir de una nube de puntos LiDAR tradicional (1 canal). Adicionalmente evaluaron la importancia de las diferentes variables en dicho proceso. Teniendo

en cuenta sólo las variables derivadas del canal 2 (datos análogos a los empleados aquí), las variables $Q_{90\%}-I''$, $Q_{75\%}-I''$ y $Q_{50\%}-I''$ resultaron más importantes que el valor medio de la intensidad. Si bien en la Figura 3.39 se observa la importancia de estas variables en menor grado que I''_{PR} (23) y I''_{UR} (24), es necesario recordar que estas últimas han sido calculadas empleando el cuantil del 68.3%, lo que las aproxima a los resultados aportados por Matikainen et al. (2017).




Figura 3.39: Escenario 1. Importancia de las variables para diferenciar las coberturas V_b , S_d , P_s y P_v usando *Random Forest* (empleando la nube de puntos original). $E_{OOB}=9.25\%$

En el segundo escenario se analizaron qué variables son más relevantes para diferenciar las coberturas V_r y V_b . Estas coberturas representan vegetación de porte medio-bajo y sus valores de reflectancia en relación a la intensidad tienden a ser similares. Pese a que existen estudios previos donde variables obtenidas a partir de valores de intensidad, como el valor medio o la diferencia de intensidad entre retornos, resultaron de utilidad para discriminar coberturas *terreno* con valores de intensidad similar (Antonarakis et al., 2008), el resultado del análisis de IV para las clases V_r y V_b muestra como las variables derivadas de la intensidad presentan poca importancia

para la identificación de dichas clases (Figura 3.40). Por el contrario, las variables más relevantes se relacionan con la altura (nM_{Vm} (3) y nMS_{PR} (1)). Estas variables pueden emplearse para diferenciar parte de la superficie que presenta *vegetación arbustiva*, pues la clase Vb no alcanza valores por encima de los 0.70 - 1 m de altura. Sin embargo, restaría diferenciar las áreas con Vr de las de *vegetación baja* (prados, zonas de cultivo,...) con altura entre los 0.5 y 1 m. En este caso, tal y como se muestra en la Figura 3.40 se podría recurrir a variables de textura de la altura como $GLCM T\Delta z_{Con}$, $GLCM T\Delta z_{Dis}$ y $GLCM T\Delta z_{Ent}$ o variables de rugosidad como la P (44) o RMS_{Dn} (47).




Figura 3.40: Escenario 2. Importancia de las variables para diferenciar las coberturas Vb y Vr usando *Random Forest* (empleando la nube de puntos original). $E_{OOB}=9\%$

En relación al tercer escenario, donde se han considerado las coberturas Ed , Va y Vm , la variable más importante resultó ser el nM_{Vm} (3) (Figura 3.41). Como ya se detalló previamente, esta variable pretende representar la altura de la vegetación media (objetos con altura inferior a 4 m). Adicionalmente, las variables de rugosidad P (44) o $Std Z$ (42) o RE (41) en base a los retornos también muestran su importancia para discriminar dichas coberturas. Esta última variable, junto con $RMS Dn$ (47), también mostró su relevancia para la identificación de

construcciones en el estudio de [Kim y Sohn \(2013\)](#). Por otro lado, también llama la atención que variables calculadas específicamente para diferenciar V_a de V_m , como el coeficiente de asimetría (CA (21)) o curtosis (CC (22)), que han mostrado poseer potencial para identificar diferentes estructuras forestales, tanto en la teoría (ver apartado 3.2.6.1) como en la práctica ([Antonarakis et al., 2008](#)); o la PNT (37), se encuentren entre las variables menos relevantes. Pudiera ser que estas variables se encuentren *eclipsadas* por el nM_{V_m} , variable también específica para caracterizar las coberturas V_a y V_m y no empleada por [Antonarakis et al. \(2008\)](#) y [Kim y Sohn \(2013\)](#). En referencia a las capas CA (21) y CC (22), otra posible causa puede ser su resolución. Probablemente un tamaño de píxel de ≈ 1.5 m (4^* *point spacing*) para su cálculo fuese insuficiente a pesar de una densidad de puntos elevada (8 puntos/ m^2). Otros autores también emplearon los intervalos de densidad para llevar a cabo esta tarea, sin embargo aquí estas variables tampoco se han mostrado relevantes [Martinuzzi et al. \(2009\)](#), [Alonso-Benito et al. \(2016\)](#).




Figura 3.41: Escenario 3. Importancia de las variables para diferenciar las coberturas Ed, Va y Vm usando *Random Forest* (empleando la nube de puntos original). $E_{OOB}=3.01\%$

3.3.3 Análisis de la clasificación híbrida

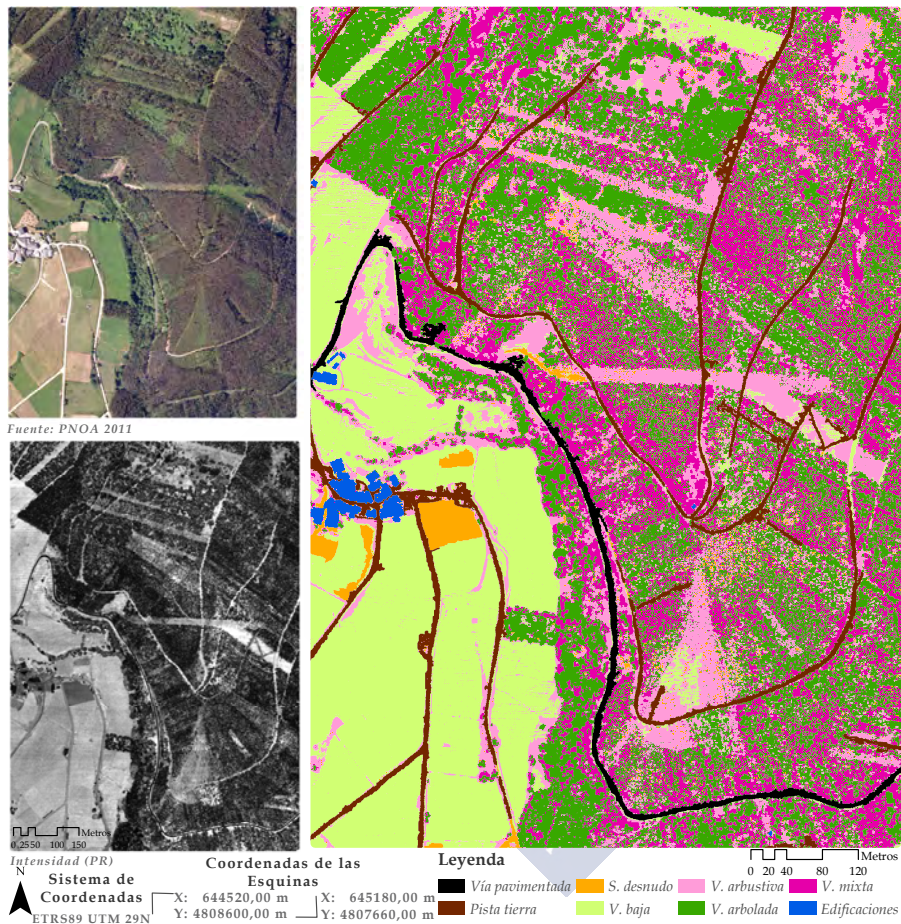


Figura 3.42: Resultado de la clasificación híbrida a partir de la nube de puntos original.

El método de clasificación híbrido *HyClass* fue probado en una zona rural de la que se disponían datos LiDAR de alta densidad (8 pto/m²). El resultado gráfico de dicha clasificación se muestra en la Figura 3.42. Junto al resultado de *HyClass* se incluye tanto la ortoimagen de la zona de estudio como la imagen de intensidad derivada de los datos LiDAR (I''_{PR} (23)). Se consideró relevante incluir esta última imagen

ya que la ortoimagen no permite comprobar visualmente la detección de la cobertura *suelo desnudo* debido al desfase temporal que existe entre dicha imagen (año 2011) y la captura de los datos LiDAR (año 2010). Para completar estos resultados, en la Tabla 3.9 se incluye la matriz de confusión y valores de precisión y desacuerdo obtenidos tras comprobar a qué clases habían sido asignadas las 800 observaciones de la muestra de validación.

Tabla 3.9: Matriz de confusión usando el método híbrido *HyClass*

<i>HyClass</i>									
Precisión (IC)= 96.88% (95.35% - 97.93%)									
Desacuerdo = 3.12% Q = 2.06% A = 1.06%									
Referencia → Clasificación ↓	Pv	Ps	Sd	Vb	Vr	Va	Vm	Ed	Usuario (%)
Pv	99	1	0	0	0	0	0	0	99.0
Ps	0	87	0	2	0	0	0	1	98.86
Sd	0	3	100	0	0	0	0	0	97.09
Vb	0	0	0	96	1	0	0	0	98.97
Vr	0	3	0	4	99	0	0	0	93.40
Va	1	4	0	0	0	99	4	0	91.67
Vm	0	2	0	0	0	1	96	0	96.97
Ed	0	0	0	0	0	0	0	99	100.0
<i>Productor (%)</i>	99.0	87.0	100.0	96.0	99.0	99.0	96.0	99.0	

Cobertura	Productor (%)	Usuario (%)
Pv	99.0	99.0
Ps	87.0	98.86
Sd	100.0	97.09
Vb	96.0	98.97
Vr	99.0	93.40
Va	99.0	91.67
Vm	96.0	96.97
Ed	99.0	100.0

Mediante el análisis visual del resultado de la clasificación incluido en la Figura 3.42 se observa como el método *HyClass* proporciona muy buenos resultados. Visualmente llama la atención la corrección en la detección de las construcciones y las zonas de *suelo desnudo*, así como la identificación del trazado completo de la mayoría de las *pistas de tierra* y la *vía pavimentada*. Esta primera evaluación se ve respaldada por un

elevado valor de precisión general. En este sentido, siguiendo una de las recomendaciones propuestas por Olofsson et al. (2014), se han calculado⁶ los intervalos de confianza de 95% para todos los valores de precisión y fiabilidad incluidos en este estudio. Se considera más apropiado emplear estos límites para evaluar la precisión de una clasificación y decidir si la precisión objetivo ha sido alcanzada, que el uso del porcentaje de aciertos (Foody, 2008). En este caso, la precisión general de la clasificación es de 96.88%, cuyos límites de confianza son 95.35% - 97.93%. (Tabla 3.9).

Existen muchas dificultades para comparar la efectividad de *HyClass* con otros métodos de clasificación. Una de las razones principales es la naturaleza de las coberturas identificadas en este estudio. Otra prueba de la dificultad de realizar evaluaciones comparativas con otros métodos es el reducido número de estudios similares que emplean datos LiDAR como única fuente de información. En la revisión realizada recientemente por Yan et al. (2015) sobre métodos de identificación de coberturas en entornos urbanos a partir de datos LiDAR, únicamente se incluye un estudio donde se han identificado más de 6 coberturas. Este estudio es el de Brennan y Webster (2006), donde se desarrolla una clasificación orientada a objetos usando un árbol de decisión y 4 variables LiDAR (no se especifica la densidad de la nube de puntos LiDAR) para identificar 7 coberturas (masas de coníferas, caducifolias, zona intermareal, cuerpos de agua, vegetación baja, carreteras y estructuras). La precisión de su clasificación alcanzó un valor de 98.14% (IC: 98.02% - 98.25%). Si no se tienen en cuenta las clases *zona intermareal* y *masas de agua*, coberturas que concentran el 50% de todas las observaciones de la muestra de validación, la precisión de su clasificación se reduce a 95.49% (IC: 95.20% - 95.76%). Resultado similar al que se presenta aquí.

Más recientemente, Zou et al. (2016) buscaron identificar 9 coberturas (*masas de agua, suelo desnudo, pasto, vegetación baja, media y alta, edificaciones y líneas eléctricas*) a partir de datos LiDAR *multi-wavelength* con una densidad de aproximadamente 20 pto/m². En su caso obtuvieron una precisión general de 91.63% (IC: 86.71% - 94.90%).

⁶Para el cálculo de los intervalos de confianza se empleó la función *prop.test* del paquete *stats* (V.3.5.0) del software R.

En la misma línea, Matikainen et al. (2017) empleó datos LiDAR multi-espectrales con una densidad de 25 ptos/m² para identificar 6 coberturas (*suelo desnudo/pistas de gravilla, vegetación baja, arbolado, edificaciones, zonas rocosas y asfalto*) a partir de una clasificación orientada a objetos y el método *random forest*. La precisión general de su clasificación empleando todos los datos fue de 95.9% (IC: 93.85% - 97.33%) y usando únicamente un canal (densidad de 8 ptos/m²) la precisión fue de 92.91% (IC: 90.38% - 94.82%). Estos últimos estudios han identificado un número similar de coberturas al estudio que aquí se presenta, empleando datos más modernos y con mayor resolución, obteniendo precisiones ligeramente inferiores a las obtenidas por el método *HyClass*. Este análisis comparativo puede tomarse como una prueba del potencial y la elevada efectividad del método híbrido propuesto.

Considerando las coberturas a nivel individual (Tabla 3.9), los resultados sugieren que el método híbrido *HyClass* muestra un gran potencial para identificar las 8 coberturas consideradas en este estudio. Destacan en este sentido los valores de fiabilidad, tanto del usuario como del productor, superiores al 96% que presentan las coberturas *vías pavimentadas, edificaciones, suelo desnudo, vegetación baja y vegetación mixta*. En el extremo opuesto se encuentra la cobertura *pistas de tierra*. Aunque esta clase presenta uno de los errores de comisión más bajos ($\approx 1\%$), muestra el error de omisión más elevado (13%). Se esperaban altos errores de omisión pues se contaba con que iba a ser complicado identificar algunos tramos de pista ocultos bajo arbolado. Posiblemente los errores citados se están dando en aquellas zonas donde la vegetación arbolada es muy densa o presenta varios estratos, impidiendo que el láser llegue hasta el terreno. A estas limitaciones se le unen los posibles errores del MDT en estas zonas. Estas suposiciones se confirman analizando la matriz de confusión que se incluye en la Tabla 3.9, donde se observa que casi el 70% de los errores de omisión de esta cobertura se deben a la confusión con las clases V_a , V_r y V_m .

Del mismo modo que se esperaban elevados errores de omisión, también se contaba con que los errores de comisión fueran bajos. Esto se debe a que no era muy probable que el proceso de segmentación creara objetos alargados que no se correspondieran con vías de comunicación.

Sin embargo, sí existía el riesgo de fallos en la segmentación por similitud *espectral* con las coberturas *suelo desnudo* o *vegetación baja*. Estos errores se producen debido a la presencia de zonas que presentan *Vb* o *Sd* próximas a las *pistas de tierra*, de manera que dichas zonas terminan por formar parte de los objetos alargados que representan a las vías. Algún ejemplo de estos errores se observa en la pista de tierra número 12 (el código de pistas se puede consultar en la primera imagen de la Figura 3.45) o en la *vía pavimentada* (en la Figura 3.42 se aprecian objetos redondeados clasificados como *Pv* que se encuentran junto a la carretera y se adentran en la zona arbolada). A pesar de estos errores, la cobertura *Pv* presenta valores de fiabilidad del 99%.

Aunque algunos estudios consideraron clave el empleo de la intensidad para diferenciar las coberturas *Pv* y *Vb* (Charaniya et al., 2004, MacFaden et al., 2012), aquí, aunque se empleó la intensidad, la variable clave para identificar la cobertura *Pv* ha sido la variable de forma *Density* implementada en *Definiens eCognition*[®]. Además, analizando la matriz de confusión no se observan indicios de posible confusión de esta cobertura con la clase *Vb*. Sin embargo, sí existe cierta confusión entre las coberturas *Vb* y *Vr*. La posibilidad de ocurrencia de este error ya se observó en la Figura 3.27, donde los valores de estas coberturas se solapaban en relación a las variables más relevantes y a partir de los resultados del *Escenario 2* (Figura 3.40). Estos últimos resultados mostraban la relevancia de las variables de rugosidad *P* (44) y *RMS_{Dn}* (47) y de las variables de altura *nM_{Vm}* (3) y *nMS_{PR}* (1). Si bien esta última variable ya demostró ser determinante en el estudio de Chen et al. (2009) para mejorar la identificación de estas clases, en el estudio que aquí se presenta la variable *P* (44) también desempeñó un papel muy importante en la diferenciación de estas dos coberturas.

Lo particular de la clase *Vr* también se observó en el análisis de la IV cuando la distribución de sus variables en la gráfica de importancia guardaba similitudes con otras coberturas pero no las suficientes para ser integrada en uno de los dos grupos (terreno ó objetos). Compartir características con clases de ambos grupos aumenta la dificultad para identificar esta clase. Sin embargo, la matriz de confusión únicamente muestra confusión con la clase *Vb* y *Ps*, alcanzando un error de comisión de 6.6%, mientras que el error de omisión es del 1%. Aunque estos valores

de error relativamente bajos no reflejan la complejidad que entraña la identificación de esta cobertura, una clara prueba de su dificultad es que su identificación se realizó en tres etapas tal y como se refleja en el árbol de decisión del método *HyClass* (Figura 3.26). Al mismo tiempo, esto también puede tomarse como prueba de la efectividad del método híbrido *HyClass*.

Otra de las coberturas que presentó altos valores de fiabilidad fue la clase *suelo desnudo*. Esta clase no presenta errores de omisión (fiabilidad de productor del 100%) y el error de comisión es del 3%. La totalidad de estos errores se debe a la confusión con la cobertura *Ps*. En la Figura 3.42 se observa como estos errores se localizan en la zona inferior de la escena en un cruce de pistas de tierra.

Una de las características generales del arbolado maduro es su densidad y baja penetrabilidad, dificultando que el láser atraviese la vegetación y llegue al terreno. Este comportamiento es similar al que presentan las cubiertas de las *edificaciones*, dificultando la diferenciación de estos dos tipos de coberturas. Sin embargo, en entornos rurales, las edificaciones no suelen tener más de dos plantas, lo que limita su altura a ≈ 12 m. Esta información fue tenida en cuenta a la hora de calcular el ratio *RE*. Dicha variable fue clave para identificar con éxito la cobertura *Ed* al disminuir el riesgo de confusión con la clase *Va*. Esta modificación en el cálculo de dicha variable puede ser la causa de su relevancia en este proceso de clasificación, pues en otros estudios donde sí se calculó, finalmente no fue empleada al no considerarse relevante (Kim y Sohn, 2010, 2013). En dichos estudios también se observó como gran parte de los errores en las coberturas *edificaciones* y *arbolado* se debían a la confusión entre ambas clases, que tal vez se podrían haber mitigado usando el *RE* calculado aquí. En el estudio que aquí se presenta, la fiabilidad de la cobertura *Ed* se encuentra entre las más elevadas, donde la referida al productor es de 99% y la del usuario de 100%. Aunque no se reflejen errores de comisión en la matriz de confusión, en el centro de la imagen con el resultado de la clasificación (Figura 3.42) sí es posible ver una pequeña zona clasificada como *Ed* cuando realmente se trata de *Vm*. Aunque se corrigieron parte de los errores por presencia de vegetación densa al considerar como únicos retornos sólo aquellos puntos entre un rango de altura de 2 a 12 m en el cálculo de *RE*, aquellas zonas

con vegetación muy densa cuya altura se encuentra en este rango sí presenta altos valores de RE y por ello en el proceso de clasificación se han considerado erróneamente como edificaciones.

Finalmente, en cuanto a las coberturas *vegetación arbolada* y *vegetación mixta*, estas clases presentan errores de omisión del 1% y 4% y de comisión del 8% y 3%, respectivamente. La totalidad de los errores de omisión de ambas clases se deben a la confusión entre Va y Vm . Sin embargo, en cuanto a los de comisión, fundamentalmente en el caso de Va , provienen en su mayoría de la confusión con las coberturas Ps y Pv . En relación a la confusión entre las coberturas Va y Vm , la magnitud de estos errores se encuentra estrechamente vinculada a la calidad del nM_{Vm} (3), pues junto con la altura resultó ser una variable clave para la diferenciación de estas coberturas. Esta variable es dependiente de la densidad de puntos, el ratio de penetrabilidad de la vegetación, la precisión del MDT, la orografía,... factores que provocan que la tarea de caracterizar la vegetación que se encuentra bajo arbolado sea todo un desafío (Fares et al., 2017). La dependencia que presenta la variable nM_{Vm} (3) con los factores citados y su importancia en el método *HyClass*, la señalan como una de las posibles flaquezas que presenta este método híbrido. Si bien estudios previos han empleado otras variables para caracterizar la estructura de la vegetación como pueden ser el coeficiente de curtosis o asimetría (Antonarakis et al., 2008), la penetrabilidad (Kim y Sohn, 2013), percentiles de altura (Chirici et al., 2013) o los intervalos de densidad (Martinuzzi et al., 2009, Alonso-Benito et al., 2016), en este caso no se mostraron relevantes en ninguno de los experimentos donde se analizó la importancia de las diferentes variables en relación a estas clases.

Con el propósito de evaluar la efectividad de *HyClass* en relación a otro método de clasificación, se realizó un experimento para comparar los resultados de *HyClass* con los obtenidos a partir de una clasificación basada en píxeles empleando el algoritmo *random forest*. En la Tabla 3.10 se incluyen las medidas de precisión y desacuerdo de esta clasificación así como la matriz de confusión correspondiente. Los resultados muestran que la precisión general y la fiabilidad tanto del usuario como del productor para todas las coberturas son mayores empleando el método híbrido *HyClass* que el algoritmo *random forest*.


La precisión general de la clasificación con *random forest* es de 89.12%, casi 8 puntos porcentuales menos que al usar el método *HyClass* (Tabla 3.9). Empleando este método de clasificación únicamente la cobertura *Ps* ofrece una fiabilidad del productor inferior al 90%, mientras que en el caso de *random forest* y de manera destacada, esa misma cobertura presenta altos errores de omisión ($\approx 30\%$) pero también las coberturas *Vb*, *Vr* y *Va* (errores de omisión de 13%, 12% y 11%, respectivamente). En relación a los errores de comisión y empleando el algoritmo *random forest*, nuevamente la cobertura *Ps* presenta el valor más elevado (21.3%) seguida de las clases *Va*, *Vr* y *Vb* con errores del 19.8%, 17.8% y 13%, respectivamente. En el caso de la clasificación híbrida, el mayor error de comisión lo presenta la cobertura *Va* con un valor de 8.3% seguida de la clase *Vr* con un 6.6%. El resto de coberturas presentan errores de comisión que no superan el 3%.

En base a los resultados anteriores, la cobertura *Ps* se afianza como la clase que presenta más dificultades para ser identificada. En el caso de la clasificación empleando *random forest*, al igual que con el método *HyClass*, la mayoría de los errores de omisión se deben a la confusión con las coberturas *Vr* y *Va*, debido al interés por identificar tramos de vías bajo arbolado. *Random forest* también presenta importantes errores de comisión en esta clase y también se encuentran relacionados con las coberturas *Vr* y *Va*, aunque en este caso resultan igual de relevantes las coberturas *Sd* y *Vb*. La confusión con estas dos últimas clases también se ha encontrado en otros estudios (Alonso y Malpica, 2010, Dinis et al., 2010). Se trata de una confusión habitual debido a que estas coberturas presentan valores similares en relación a la altura, pendiente, diferencia entre retornos y en algunos casos también en relación a la intensidad. La principal diferencia que presentan estas últimas coberturas de la clase *Ps* se relaciona con la forma, de ahí los diferentes valores de error de comisión de esta cobertura empleando el método híbrido o *random forest* (1.1% y 21.3%, respectivamente).

Si bien no estaría fuera de lugar esperar que la clase *Pv* presentara resultados similares, en este caso no ha sido así. Aunque estas coberturas presentan similitudes, también existen diferencias importantes entre ambas. En primer lugar, el material del que están formadas. Aunque las *Ps* generalmente son de tierra es habitual que presenten vegetación

Tabla 3.10: Matriz de confusión usando *random forest*

<i>random forest</i>									
Precisión (IC)= 89.12% (86.71% - 91.16%)									
Desacuerdo = 10.88% Q = 2.21% A = 8.67%									
Referencia → Clasificación ↓	Pv	Ps	Sd	Vb	Vr	Va	Vm	Ed	Usuario (%)
Pv	90	1	0	0	0	1	0	1	96.8
Ps	1	70	5	4	4	5	0	0	78.7
Sd	0	4	94	0	0	0	0	0	95.9
Vb	0	7	0	87	6	0	0	0	87.0
Vr	0	7	1	9	88	0	0	2	82.2
Va	9	10	0	0	1	89	0	2	80.2
Vm	0	1	0	0	0	3	100	0	96.2
Ed	0	0	0	0	1	2	0	95	96.9
Productor (%)	90.0	70.0	94.0	87.0	88.0	89.0	100.0	95.0	



baja, lo que produce un aumento del solape *espectral* entre estas clases. Sin embargo, las carreteras son vías pavimentadas mucho más homogéneas que las anteriores en relación a la reflectividad y sus valores de intensidad LiDAR son muy bajos. También presentan diferencias en cuanto al ancho, las primeras son mucho más estrechas que las segundas. A esta característica se le une el tipo de entorno por el que discurren. Las primeras generalmente se encuentran en zonas forestales, habitualmente franqueadas por vegetación (medio-alta) y presentan valores de pendiente dispares, vinculados a la orografía de la zona. Mientras tanto, las *Pv* presentan márgenes más marcados, la orografía se suele adaptarse a su trazado y aunque atraviesan zonas forestales y la vegetación de los márgenes puede invadir su espacio aéreo, no se encuentran en la zona de tránsito. Estas diferencias hacen que la

cobertura *Pv* presente valores de fiabilidad del 99% en el caso de emplear el método híbrido y no inferiores al 90% en el caso de *random forest*.

Tal y como dejaba ver el resultado del *Escenario 2* (Figura 3.40), donde se analizaba qué variables eran más relevantes para diferenciar las clase *Vb* y *Vr*, existía un alto riesgo de confusión entre estas dos coberturas. Este riesgo también se puso de manifiesto al describir la jerarquía de coberturas (Figura 3.25) y al elaborar el árbol de decisión del método *HyClass*. Y ahora también se observa en la matriz de confusión del método *random forest*, aproximadamente la mitad de los errores de comisión y dos tercios de los de omisión que presenta la clase *Vb* se deben a la confusión con la cobertura *Vr*, y esta cobertura a su vez presenta resultados similares en relación a la clase *Vb*. Esta misma relación se da aplicando el método *HyClass*, aunque la magnitud de los errores es mucho menor que los que se dan con *random forest*.

La detección de la vegetación intermedia también presentó dificultades en estudios previos. Por ejemplo, la vegetación media en el estudio presentado por Zou et al. (2016) muestra un error de omisión superior al 30% en favor de la clase vegetación alta, y un error de comisión de más del 20%, donde además de existir confusión con la cobertura vegetación alta también la presenta con las clases suelo desnudo y pastos/jardines. La confusión con la vegetación alta probablemente se debe al uso de la intensidad conjuntamente con la variable *diferencia entre retornos* para su diferenciación. Para tal fin, esta última variable probablemente funcione bien en caso de pretender diferenciar masas arboladas poco densas que presentan un único estrato (valores altos de la *diferencia entre retornos*) de vegetación media también poco densa que permita el paso del láser hasta el terreno. Así, la diferencia entre retornos será mayor que cero, valores característicos de las zonas que presentan edificaciones, y al mismo tiempo inferiores a los de las zonas arboladas. Estas condiciones pueden darse pero conjuntamente con otras: vegetación densa donde la diferencia entre retornos es próxima a cero; vegetación arbolada con un estrato arbustivo denso que reduce la magnitud de la diferencia entre retornos equiparándolo a los valores esperados de la vegetación media,... En base a lo expuesto, el uso de esta variable conjuntamente con valores de intensidad parece insuficiente para abordar muchas de las casuísticas que se pueden dar en relación a la vegetación media y alta. Tal y

como se mostró con el método *HyClass*, el empleo de modelos de altura normalizados haciendo uso de umbrales de altura (por ejemplo, la variable nM_{V_m} (3)) pueden contribuir a reducir la confusión entre este tipo de coberturas, sin olvidar que la calidad de estas variables depende en muchos casos de la precisión de los MDT.

Finalmente, se esperaba encontrar dificultades para diferenciar entre zonas V_a y V_m , pero a la vista de los resultados de ambos métodos, la confusión entre estas coberturas no es muy elevada. Sin embargo, si resulta evidente la confusión entre la clase V_a y las coberturas P_s y P_v , principalmente empleando *random forest*. De nuevo, este error se debe a la pretensión de identificar el trazado completo de las vías.

En la Figura 3.43 se comparan gráficamente los resultados de desacuerdo Q y A de los métodos *HyClass* (color malva) y *random forest* (color verde) empleando como datos de entrada las variables derivadas de la nube de puntos original. El desacuerdo general de *HyClass* es tres veces menor al producido por el algoritmo *random forest* a nivel píxel (3.12% y 10.6%, respectivamente). Mientras que en primer caso la mayoría de los errores se relacionan con la cantidad (Figura 3.43a), casi el 75% de los errores en el segundo caso son por localización (Figura 3.43b). Probablemente, una parte importante de estos desacuerdos se deba a las diferentes unidades de análisis que emplean los dos métodos de clasificación (píxeles/objetos vs. píxeles). El empleo de objetos permite usar variables adicionales a las *espectrales* como las que se encuentran relacionadas con el tamaño, la forma o el contexto. El uso de alguna de estas variables pueden contribuir a reducir los errores de localización. Un ejemplo de clases que se han podido ver favorecidas por su empleo son las coberturas P_v y P_s . Otra circunstancia que pudo influir en reducir el desacuerdo A en el caso de *HyClass* es que el orden de las operaciones de su árbol de decisión sigue la jerarquía de coberturas incluida en la Figura 3.25, lo que permitió acotar la localización de algunas coberturas favoreciendo su identificación.

En cuanto al desacuerdo por cantidad (Figura 3.43a), las coberturas P_s , V_a y V_r son las coberturas más afectadas. En estudios previos donde se emplearon datos LiDAR para diferenciar coberturas similares, por ejemplo *carreteras* y *vegetación arbolada*, la posibilidad de confusión

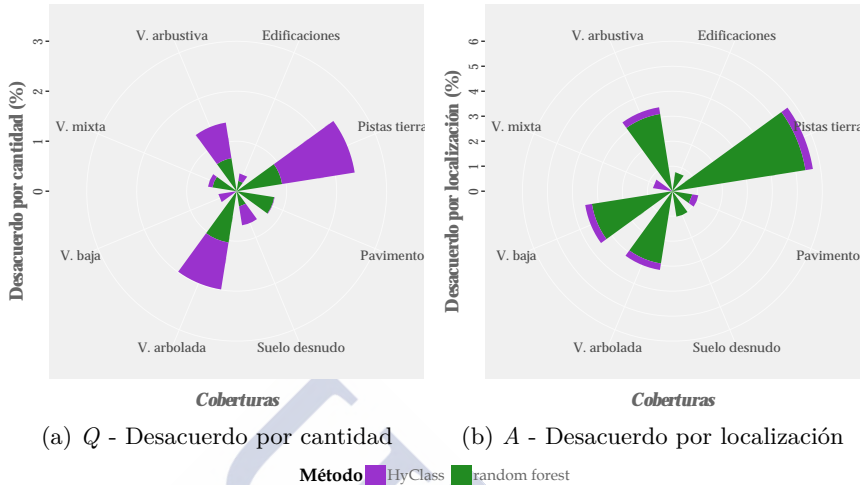


Figura 3.43: Desacuerdo por coberturas de los métodos *HyClass* y *random forest*.

entre estas coberturas era muy reducida (Buján et al., 2012, Teo y Wu, 2017). Sin embargo en este estudio, la probabilidad de confundir las coberturas V_a y V_r con la clase P_s y en menor medida con P_v , sí existe. Esto se debe al interés por identificar los tramos de vías que discurren bajo zonas que presentan vegetación. Así, analizando de forma conjunta los resultados de la Figura 3.43a y los incluidos en las matrices de confusión de los métodos *HyClass* y *random forest* (Tablas 3.9 y 3.10, respectivamente), se tiene que los errores Q de la clase P_s son mayoritariamente por defecto en favor de las clases V_a , V_m , V_r y V_b en el caso de *random forest*; y de V_a , V_m , V_r y S_d en el caso de *HyClass*. Adicionalmente, en el caso de la cobertura P_v y el método *random forest*, Q también es por defecto en favor de la clase V_a .

Las coberturas V_r , V_a y V_m guardan cierta similitud con alguno de los 7 tipos de combustible según el sistema de clasificación Prometheus, concretamente con el tipo 3 y 4 en el caso de V_r , el tipo 5 en relación a V_a y los tipos 6 y 7 con V_m . La definición de estos tipos de combustible se puede consultar en Chuvieco et al. (2003). Ninguno de los estudios consultados han empleado únicamente datos LiDAR para su identificación pero sí los han utilizado como fuente de datos auxiliar. En

este último caso se encuentra el estudio de [García et al. \(2011\)](#), donde se emplearon datos LiDAR conjuntamente con datos LiDAR para la identificación de tipos de combustible. La metodología que desarrollaron se basa en una clasificación anidada que consta de dos etapas: en primer lugar realizan una clasificación empleando SVM para obtener una serie de coberturas del suelo, que en la siguiente etapa serán los datos de entrada de un árbol de decisión que tiene como fin la identificación de los 7 tipos de combustible según el sistema de clasificación Prometheus. La precisión de la primera clasificación es de 92.8% mientras que el resultado de la identificación de tipos de combustible desciende a 88.24%. En concreto, los tipos de combustible que presentan los mayores errores de omisión son el 6 y 7 (20% y 13%, respectivamente), mientras que en relación a los errores de comisión son el 5 con un 25% y el 7 con un 7%. Todos estos errores están muy por encima de los obtenidos a partir de *HyClass* (Tabla 3.9) y son ligeramente superiores a los obtenidos a nivel píxel mediante *random forest* (Tabla 3.10).

Recientemente, [Alonso-Benito et al. \(2016\)](#) también desarrollaron un método para identificar los mismos tipos de combustible. En su caso probaron 3 métodos de asignación diferentes a nivel objeto y tomaron como datos de entrada una imagen con 8 bandas multi-espectrales (resolución de 2 m) y una pancromática (resolución de 0.5 m) junto con datos LiDAR de baja densidad. Los valores de desacuerdo general que obtuvieron toman valores muy por encima de los obtenidos con *HyClass* y el tipo de combustible que presenta los mayores errores es el 7. Estos valores se deben a que la densidad de los puntos LiDAR es insuficiente para caracterizar tanto la vegetación como el terreno que se encuentra bajo arbolado. Esta limitación también se observará más adelante en el momento en que se analice la influencia de la densidad de puntos en la precisión de la clasificación. En base a lo expuesto, se considera que los resultados de *HyClass* en relación a las coberturas V_a , V_m y V_r sugieren, en contra de lo manifestado en otros estudios ([Koetz et al., 2008](#)), que los datos LiDAR por sí solos permiten obtener precisiones similares y en algunos casos superiores a las obtenidas en estudios previos, particularmente aquellos orientados a la identificación de tipos de combustible según el sistema de clasificación Prometheus.

Para completar el análisis de la efectividad del método *HyClass*,

se comprobó su robustez ante variaciones de la densidad de puntos LiDAR y por tanto, variaciones de la resolución espacial de las variables. Los resultados cualitativos empleando la nube de puntos original (densidad ≈ 8 ptos/m²) y las tres nubes de puntos con densidad reducida (densidades de 4 ptos/m², 2 ptos/m² y 1 pto/m²) se incluyen en la Figura 3.44.

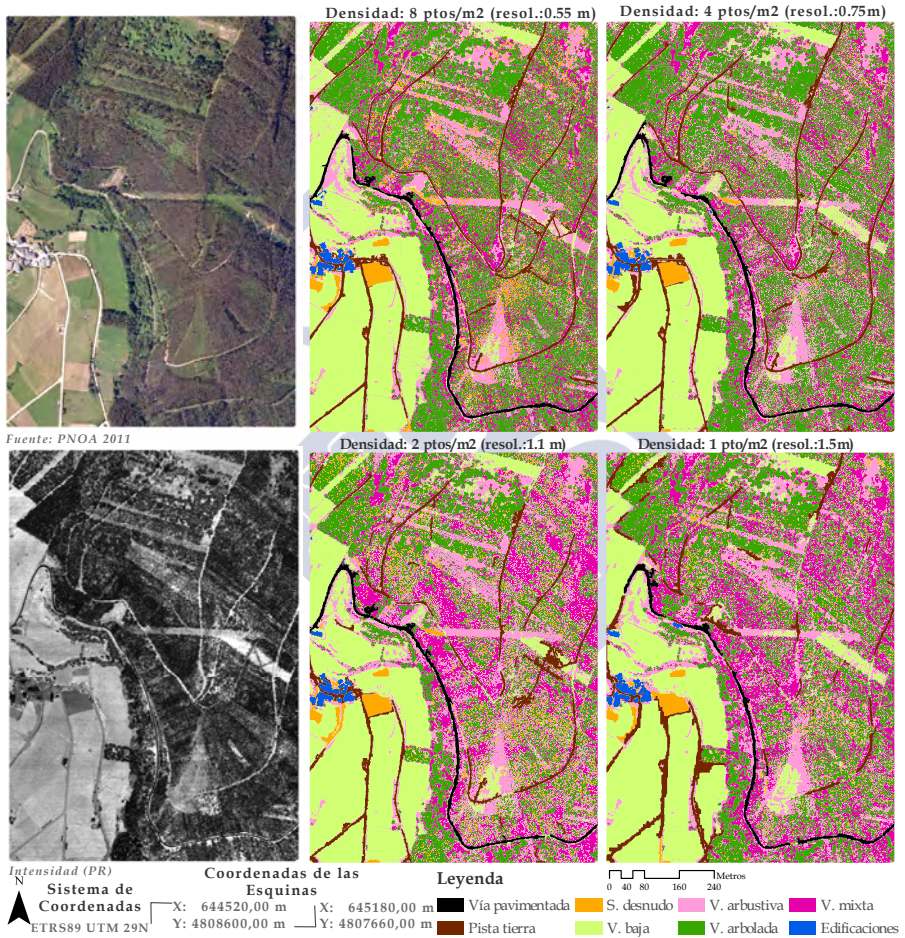


Figura 3.44: Resultado de la clasificación híbrida a partir de la nube de puntos original y las nubes reducidas.

Con independencia de la densidad de puntos, aparentemente las coberturas *Ed*, *Sd*, *Vb* y *Pv* presentan un alto nivel de acuerdo entre el

resultado de la clasificación y la realidad, representada en la Figura 3.44 por la ortoimagen y la imagen de intensidad. Sin embargo, no parece que suceda lo mismo con la clase Ps , cuya identificación se ve bastante comprometida al emplear la nube de puntos con menor densidad. Para completar este primer análisis visual, en la Figura 3.45 se incluyen los resultados de la detección de vías en función de la densidad de puntos. En dicha imagen se observa como al emplear la nube de puntos original la vía pavimentada se ha identificado perfectamente (objetos en color negro), al igual que la gran mayoría de las pistas de tierra (objetos en color marrón). Si bien la reducción de puntos no parece influir demasiado en el trazado de la vía pavimentada, sí afecta a la detección de pistas de tierra.

Los principales errores que se detectan en la identificación de la cobertura anterior tienen 2 orígenes: 1) similitud *espectral* en relación a la intensidad entre la clase Ps y las coberturas Vb y Sd que provocan errores de segmentación, donde tramos de pistas se unen a los objetos que incluyen dichas coberturas; 2) tramos ocultos por vegetación muy densa impiden el paso del láser hasta el terreno y por tanto la existencia de puntos, lo que da lugar a que el nM_{V_m} (3) no contenga datos en estas zonas. Así, a medida que la densidad de puntos baja y por tanto la resolución de las variables, el efecto de estos errores es mayor. Esto se traduce en que, tras la segmentación, el trazado de cada pista no se incluye en un objeto de gran longitud como sucede al emplear densidades de 4 ó 8 pto/m² sino que se compone de múltiples objetos cuya longitud es menor y al mismo tiempo se da con más frecuencia la incorporación de tramos de pistas a objetos que se identifican con otras coberturas. El resultado de la acumulación de estos errores se ve perfectamente a partir de los resultados incluidos en la Figura 3.45 empleando densidades de 2 y 1 pto/m², donde se observa que únicamente las pistas de tierra en zonas agrarias muestran casi todo su trazado.

Adicionalmente, se calculó el índice de compleción en la relación a la detección de vías. Dicho índice se emplea en estudios específicos de identificación de vías forestales para cuantificar la precisión de los resultados (Wiedemann, 2003, Azizi et al., 2014). Dicho índice se obtiene a partir del cociente entre el número de tramos reales correctamente detectados y el número total de tramos. De esta manera se obtiene

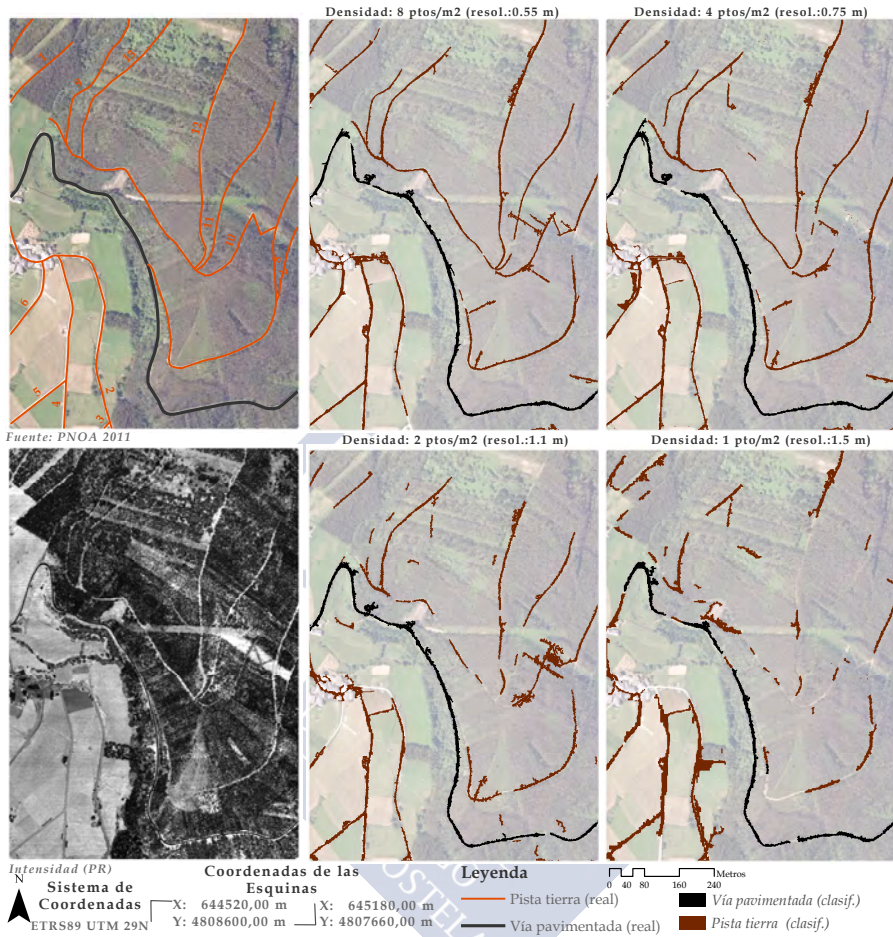


Figura 3.45: Resultado de la detección de vías a partir de la nube de puntos original y las nubes reducidas empleando *HyClass*.

el porcentaje de tramos reales de vía que han sido automáticamente identificados. Para realizar este cálculo, el trazado real de las vías se transformó en puntos considerando intervalos de 1 m. Así, el número de puntos correctamente identificados representará el número de metros de vía correctamente identificados. A continuación, se cruzó esta capa de puntos con la capa de vías detectadas y se obtuvieron los valores de compleción que se incluyen en la Tabla 3.11. Se sombrearon en color malva aquellos resultados que superaron un valor del 90%.

Tabla 3.11: Efectividad de la detección de vías de comunicación empleando *HyClass* en función de la densidad de puntos (clasificación *Nivel 2*).

Vía	Long. (m)	Densidad de puntos			
		8 ptos/m ²	4 ptos/m ²	2 ptos/m ²	1 ptos/m ²
0	95	100%	100%	64.2%	85.3%
1	199	99.5%	86.4%	58.8%	34.7%
2	638	90.9%	95.3%	83.1%	79.5%
3	21	0.0%	100%	100%	100%
4	402	100%	100%	100%	76.9%
5	162	100%	100%	100%	100%
6	194	90.7%	89.7%	40.7%	87.6%
7	860	76.9%	85.0%	72.3%	46.9%
8	180	10.0%	8.3%	5.0%	13.9%
9	339	60.2%	51.0%	37.2%	6.8%
10	310	96.8%	44.2%	82.6%	10.6%
11	438	91.3%	68.9%	62.3%	8.7%
12	1116	96.4%	97.5%	63.6%	40.8%
13	398	80.2%	77.1%	80.4%	60.8%
<i>Detección Ps</i>		85.8%	82.0%	68.9%	47.4%
<i>Detección Pv</i> (1267)		98.9%	97.2%	97.7%	83.9%

Los resultados anteriores muestran que el índice de compleción de las vías pavimentadas se encuentra por encima del 97% para densidades igual o superior a 2 ptos/m², mientras que la detección de pistas supera el 80% para densidades de 4 y 8 ptos/m². Estos resultados son similares y en algunos casos mejores a los obtenidos en estudios que tratan específicamente la detección de pistas forestales empleando datos LiDAR (Azizi et al., 2014, Ferraz et al., 2016). Recientemente, Beck et al. (2015) desarrollaron una metodología para la identificación de pistas forestales a partir de nubes de puntos LiDAR. Para ello emplearon únicamente dos variables: la intensidad y la densidad de puntos terreno. Consideró esta última variable ya que las zonas que contienen pistas presentan una mayor cantidad de puntos terreno que el resto de zonas. Mediante esta metodología detectó el 67% de las pistas, llegando al 84% si solo se consideran las pistas de gravilla. Esta metodología obtiene buenos resultados principalmente en zonas donde las pistas son de gravilla y se encuentran franqueadas por vegetación. En el caso de zonas sin vegetación y la presencia de pistas de tierra, la identificación de estas últimas se complica, en primer lugar porque ambas presentan

alta densidad de puntos terreno y en segundo lugar porque sus valores de intensidad son similares. Esta puede ser una de las causas por las que la precisión de la detección se reduce al considerar las *pistas nativas* junto con las de gravilla.

Al igual que en el estudio que aquí se presenta, [Sherba et al. \(2014\)](#) fue un paso más allá y analizó como la densidad de puntos afecta a la precisión de la detección de pistas forestales. En su caso empleó datos LiDAR con una densidad original de puntos de 12 ptos/m², que secuencial y aleatoriamente redujo a 6, 3, 1.5 y 0.8 ptos/m². Empleando una imagen de pendiente obtenida del MDT y el resultado de aplicar un filtro de detección de bordes en una *CoO* obtuvo unas precisiones de 86%, 78%, 67%, 64% y 49% a partir de las nubes LiDAR con densidad de 12, 6, 3, 1.5 y 0.8 ptos/m², respectivamente. Esta reducción de la precisión se debió fundamentalmente al aumento de los errores de omisión ya que los errores de comisión permanecieron constantes. Si bien los resultados de precisión obtenidos aquí son muy similares a los logrados por [Sherba et al. \(2014\)](#), no sucede lo mismo con los errores de omisión y comisión. En la Figura 3.46 se representa gráficamente la fiabilidad del usuario y productor para cada una de las coberturas y densidad de puntos. Ahí se observa como la reducción de la precisión en la detección de las pistas de tierra se debe tanto a un aumento de los errores de omisión (reducción de la fiabilidad del productor) como de los de comisión (reducción de la fiabilidad del usuario) al reducir la densidad de puntos. Los errores de omisión son causados mayoritariamente por falta de definición de las pistas en zonas arboladas y en consecuencia clasificadas erróneamente como *Va* o *Vr*, mientras que los de comisión son provocados mayoritariamente por un aumento de la similitud espectral entre coberturas, principalmente con las clases *Pv* y *Sd*.

En la Figura 3.46 además de la la fiabilidad del usuario y productor de cada clase, también se incluye de forma gráfica los valores de precisión general en función de la densidad de puntos (las matrices de confusión que dan origen a estas gráficas se incluyeron en las Tablas C.14 a C.17 del Anexo C). Para cada una de las medidas y densidades se marca el intervalo de confianza de 95% (barras superiores en color azul). La primera gráfica muestra la precisión general de la clasificación a medida




Figura 3.46: Resultados cuantitativos de *HyClass* en función de la densidad de puntos (clasificación de Nivel 2 - 8 coberturas).

que la densidad de puntos aumenta. Como se esperaba, existe una relación directa entre la densidad de puntos LiDAR y la precisión de la clasificación, de manera que cada vez que la densidad de puntos se duplica, la precisión de la clasificación aumenta aproximadamente un 4%. Esta diferencia llega al 12% si se tienen en cuenta los resultados de la clasificación al emplear la nube de puntos con menor densidad (84.0%) y los datos LiDAR originales (96.9%).

La misma relación entre la densidad de puntos y la precisión de la clasificación la obtuvieron *Buján et al. (2013b)*. En dicho estudio se usó el algoritmo J48 a nivel píxel para identificar 8 coberturas del suelo en la misma zona de estudio a partir de datos LiDAR con características similares. Teniendo en cuenta que ni el método de clasificación ni las coberturas identificadas en ese estudio eran las mismas, una de las principales diferencias se encontró en la magnitud de las diferencias entre los resultados de las 4 densidades de puntos. Si bien existe una diferencia de 4 puntos porcentuales entre usar datos con una densidad de 8 y 4 pto/m², únicamente hay una diferencia de 1.5% entre usar 4 y 1 pto/m². Sin embargo las precisiones para densidades igual o inferior a 4 pto/m² no superan el 86%, valor similar al obtenido aquí con una

densidad de 1 pto/m² (84%). Buján et al. (2013b) demostraron que la causa de la reducción drástica de precisión para densidades inferiores a 8 ptos/m² se debía a la cobertura pistas forestales pues al no considerar esta clase la precisión subió una media del 6%.

En la Tabla 3.12 se incluyen los valores de desacuerdo total y de sus dos componentes (Q y A). En base a estos resultados se observa como únicamente al emplear la mayor densidad de puntos el desacuerdo por cantidad es mayor que el debido a la localización. A medida que la densidad decrece, ambos errores aumentan aunque a ritmos diferentes. En el caso de los errores por cantidad, éstos aumentan ligeramente a medida que disminuye la densidad hasta 2 ptos/m² y se duplican al emplear la nube de puntos con menor densidad. La variación máxima de estos errores es de 3.43%, diferencia entre el desacuerdo Q empleando la nube de puntos con menor densidad y el correspondiente a la nube de puntos original. Por otro lado, los errores debidos a la localización aumentan rápidamente a medida que la densidad decrece, llegando casi a una diferencia del 10% entre emplear la nube de puntos original y la de menor densidad.

Tabla 3.12: Desacuerdo en función de la densidad empleando *HyClass* (clasificación Nivel 2).

	Densidad de puntos			
	8 ptos/m ²	4 ptos/m ²	2 ptos/m ²	1 ptos/m ²
<i>Desacuerdo total</i>	3.12%	7.63%	11.88%	16.00%
<i>D. por cantidad - Q</i>	2.06%	3.42%	2.90%	5.49%
<i>D. por localización - A</i>	1.06%	4.21%	8.97%	10.51%

Para intentar explicar las tendencias que siguen los errores al disminuir la densidad de puntos, en la Figura 3.47 se representa gráficamente el desacuerdo por cantidad y localización para cada una de las coberturas empleando las diferentes densidades de puntos.

De acuerdo a los valores de desacuerdo por cantidad incluidos en la Figura 3.47a, la principal contribución al error por cantidad a medida que la densidad se reduce procede de la clase *Va*. Al disminuir la densidad de puntos, el número de retornos bajo el arbolado también se reduce, lo que dificulta la detección de matorral en estas zonas. Así, estos

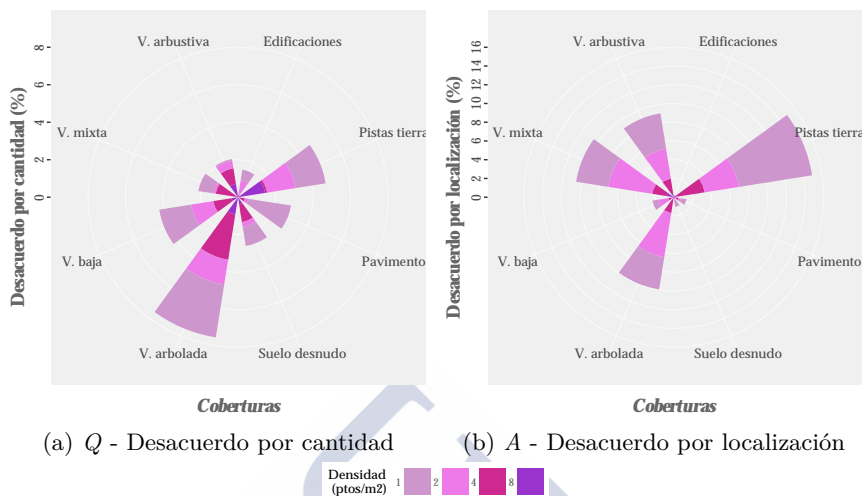


Figura 3.47: Desacuerdo por coberturas en función de la densidad empleando *HyClass* (clasificación Nivel 2 - 8 coberturas).

errores contribuyen a aumentar la confusión entre las coberturas V_a y V_m en favor de las primeras, de manera que esta cadena de sucesos puede ser la causa del aumento del desacuerdo por cantidad en la cobertura V_a cuando la densidad de puntos se reduce. Aunque en menor magnitud, algo similar sucede con las coberturas V_b y V_r . Como se observaba en los resultados de la importancia de variables para discriminar ambas coberturas (Figura 3.40 - *Escenario 2*), las variables más relevantes se encontraban vinculadas con la altura y algunas relacionadas con la rugosidad, como la pendiente. Al disminuir la densidad de puntos, la reducción del detalle con el que se representan los objetos y la superficie del terreno hace que las zonas con V_r se encuentren peor caracterizadas, aumentando las similitudes con las zonas de V_b . Esta circunstancia provoca que zonas con V_r sean clasificadas como V_b , aumentando el desacuerdo por cantidad de estas últimas.

Por otro lado, la relación inversa entre la densidad de puntos y el desacuerdo Q de la cobertura P_s se encuentra estrechamente vinculada a las características de dicha cobertura, es decir, la identificación del trazado completo, incluidos aquellos tramos que discurren bajo arbolado.

Este último punto es el origen de la mayoría de los errores que presenta esta cobertura, de manera que tramos de pistas ocultos por vegetación terminan clasificándose erróneamente como Va , Vr o Vm . En esta línea, Čekada et al. (2010) mostró en su estudio que el ratio de penetrabilidad de las masas mediterráneas y caducifolias es del 20% y 6%, respectivamente. Esto indica que en zonas donde esta vegetación se encuentra presente será necesaria una densidad mínima de 5 ptos/m² y 16 ptos/m², respectivamente para obtener 1 punto por debajo del primer estrato de vegetación.

Por otro lado, en relación a los errores por localización (A), las coberturas que se ven más afectadas a medida que la densidad se reduce son Ps , Va , Vm y Vr . El caso de la cobertura Ps ya se analizó en detalle previamente y se pudo comprobar gráficamente la ocurrencia tanto de los errores por cantidad como por localización. En relación a estos últimos, en la Figura 3.45 se observa como algunos de estos errores se deben a fallos en la segmentación, bien porque los objetos que representan *pistas de tierra* incorporan zonas próximas con valores de intensidad similares (*objetos mixtos*) bien porque tramos de pistas ocultos por vegetación no son detectados debido a la reducción de la resolución de las capas de información LiDAR. Otros errores se deben a fallos en la asignación, de forma que algunos tramos de carretera o zonas de suelo desnudo son clasificados erróneamente como Ps . En cuanto a los tramos de Ps no detectados y que se encuentran ocultos por la vegetación, éstos se identifican erróneamente como Va , Vm y Vr , aumentando el desacuerdo A de estas coberturas.

Cuando la densidad de puntos es baja, el empleo de información auxiliar como imágenes satélite o aéreas puede contribuir a mejorar la precisión de la clasificación (Buján et al., 2013b, Zahidi et al., 2015). Esta afirmación es cierta cuando la información espectral permite aumentar la separabilidad entre las clases que están siendo confundidas. Por ejemplo, para mitigar la confusión entre las clases arbolado y edificaciones cuando se emplean los atributos altura e intensidad de los datos LiDAR (Chen et al., 2009, Guan et al., 2013). Sin embargo, en el caso de la clasificación de nivel 2 (8 coberturas), los resultados de la identificación de las coberturas que presentan mayor nivel de degradación a medida que la densidad de

puntos disminuye, no parece que pueda mejorar demasiado empleando información espectral. En este caso se encuentran las pistas de tierra que discurren bajo arbolado o la vegetación mixta y la vegetación arbolada ambas vinculadas a la existencia o no de vegetación arbustiva. Mejorar la identificación de estas coberturas pasa por aumentar el nivel de detalle del terreno/objetos que se encuentra bajo la vegetación arbolada, cosa que las imágenes por lo general no permiten.

Adicionalmente, tal y como se mostró en el Capítulo 2, la pendiente del terreno es uno de los factores que más influye en la precisión con la que se representa el terreno. Zahidi et al. (2015) empleando datos LiDAR de baja densidad, citaba como posible origen de los buenos resultados obtenidos en la identificación de matorral, a que la pendiente era suave en su zona de estudio. Si bien una pendiente suave en su caso pudo repercutir positivamente en los resultados de la clasificación, en el caso que aquí se presenta la reducción de la densidad de puntos en combinación con una pendiente elevada del terreno pueden contribuir a aumentar los errores en la identificación de las coberturas P_s , V_a y V_m (coberturas que en el área de estudio se localizan en zonas donde la orografía es más compleja).

Probablemente el punto donde está fallando el método *HyClass* sea en que el nivel de detalle de las capas de entrada no es suficiente para caracterizar las coberturas que se pretenden identificar, incumpliendo la regla de que la resolución espacial de los datos debe ser similar a la *escala de acción* (Wu y Li, 2009). En este caso concreto se encuentran las coberturas P_s , V_a y V_m , las cuáles presentan ciertas particularidades que hacen que su correcta identificación se encuentra condicionada por la disponibilidad de datos que permitan la obtención de información concreta y detallada. Información que probablemente no se pueda extraer a partir de nubes de puntos con baja densidad. Por ejemplo, en el caso de las *pistas de tierra* cuyo ancho en algunos casos no llega a los 3 m y además se encuentran ocultas bajo el arbolado, detectarlas correctamente resulta muy complicado a partir de capas de información con una resolución de ≈ 1.5 m (caso de las variables obtenidas a partir de la nube de puntos con una densidad de 1 pto/m²).

Llegado este punto, se ha realizado un último experimento para

evaluar el funcionamiento del método *HyClass*. Teniendo en cuenta la jerarquía de coberturas de la Figura 3.25 y los resultados de la clasificación de *Nivel 2* (8 coberturas), se ha pasado a una clasificación de *Nivel 1* de 5 clases: *carreteras pavimentadas (PV)*, *vegetación no arbolada (VnA)* (integra las coberturas *Vr* y *Vb*), *vegetación arbolada (VA)* (integra las coberturas *Va* y *Vm*), *suelo desnudo (SD)* (integra las coberturas *Sd* y *Ps*) y edificaciones (*ED*). Los resultados de precisión y desacuerdo para esta clasificación de *Nivel 1* se incluyen en las Figuras 3.48 y 3.49, respectivamente (las matrices de confusión y valores de desacuerdo que dan origen a estas gráficas se incluyeron en las Tablas C.14 a C.18 del Anexo C). Las muestras de validación empleadas para comprobar la precisión de la clasificación de *Nivel 1* fueron las mismas que las usadas en la clasificación de *Nivel 2* en el caso de las coberturas *Pv* y *Ed*. Para la cobertura *VA (Nivel 1)* se seleccionaron aleatoriamente 100 observaciones de las muestras de validación de las clases *Va* y *Vm* empleadas en la clasificación de *Nivel 2*. Para la cobertura *VnA (Nivel 1)* se procedió igual que en el caso anterior pero considerando las muestras de las clases *Vb* y *Vr* de la clasificación de *Nivel 2*. Finalmente, para la cobertura *SD (Nivel 1)*, se seleccionaron aleatoriamente 100 observaciones a partir de las muestras de las clases *Sd* y *Ps* de la clasificación de *Nivel 2*, pero en este caso se comprobó que dichas observaciones no se encontraran en tramos de pistas ocultos por la vegetación.

Nuevamente se observa una relación directa entre la densidad y la precisión general de la clasificación, sin embargo en este caso las diferencias de precisión entre emplear las nubes con densidades de 2, 4 y 8 pts/m² son muy inferiores al 4% que se observaba en la clasificación de *Nivel 2* (Figura 3.46). Al emplear la nube de puntos original, el método *HyClass* proporciona una precisión del 99.4% (IC: 98.10% - 99.84%), que se reduce hasta el 96.40% (IC: 94.26% - 97.79%) en caso de usar la nube con una densidad de 2 pts/m². Estos resultados mejoran los obtenidos en estudios similares donde se emplean datos LiDAR de retorno discreto (Im et al., 2008a, Zhou, 2013), LiDAR *full-waveform* con densidades similares a las empleadas aquí (Chehata et al., 2009) o más recientemente *dual-wavelength* (Wang et al., 2014) y *multi-wavelength* con densidades superiores a los 25 pts/m² (Zou et al., 2016, Matikainen et al., 2017). Por ejemplo, Teo y Wu (2017) empleó datos




Figura 3.48: Resultados cuantitativos de *HyClass* en función de la densidad de puntos (clasificación de Nivel 1 - 5 coberturas).

LiDAR *multi-wavelength* con una densidad media de 70 ptos/m² para identificar en una zona urbana 5 coberturas del suelo (árboles, edificios, suelo desnudo, carreteras y jardines). Para ello desarrollaron una *CoO* empleando como algoritmo de segmentación el ASM y como método de asignación *supervised Support Vector Machine* (SVM). Empleando únicamente los datos con una longitud de onda de 1064nm (análogos a los usados en este estudio) obtuvieron una precisión del 92%, llegando al 96% si se usan de manera conjunta los datos de todas las longitudes de onda. Adicionalmente, calcularon índices de vegetación a partir de los datos de los canales verde e infrarrojo. El empleo de esta variable mejoró los resultados de la clasificación, llegando a una precisión del 98%. Sin intención de cuestionar el gran potencial que poseen los datos LiDAR empleados en su estudio, para la identificación de coberturas como las consideradas en el *Nivel 1*, datos LiDAR monocromáticos de menor densidad permiten obtener resultados tanto o más precisos tal y como muestra la gráfica de precisiones generales de la Figura 3.48.

Finalmente, en la Tabla 3.13 se incluyen los valores de desacuerdo

total y los relacionados con la cantidad (Q) y la localización (A). Adicionalmente, en la Figura 3.49 se representa gráficamente el desacuerdo Q y A de las diferentes coberturas (clasificación *Nivel 1*) para cada una de las densidades de puntos.

Tabla 3.13: Desacuerdo en función de la densidad empleando *HyClass* (clasificación *Nivel 1*).

	Densidad de puntos			
	8 ptos/m ²	4 ptos/m ²	2 ptos/m ²	1 ptos/m ²
<i>Desacuerdo total</i>	0.60%	3.00%	3.60%	8.80%
<i>D. por cantidad - Q</i>	0.40%	0.98%	1.59%	4.58%
<i>D. por localización - A</i>	0.20%	2.02%	2.01%	4.22%

Nuevamente se observa una relación inversa entre el desacuerdo y la densidad de puntos. Sin embargo, el aumento del desacuerdo no es homogéneo como se observó en la clasificación de *Nivel 2* (Tabla 3.12). En el caso de la clasificación de *Nivel 1*, se observa como el desacuerdo al emplear la nube de puntos original es muy bajo ($D=0.60\%$) y que aumenta aproximadamente un 3% para densidades de 4 y 2 ptos/m², donde los valores de desacuerdo son muy similares, 3% y 3.6% respectivamente, para aumentar más del 5% al emplear los datos con menor densidad. Tampoco se observan grandes diferencias entre el desacuerdo por cantidad y localización como se observó en la clasificación de *Nivel 2*. Estos resultados seguramente se deban a que en esta clasificación no se tiene en cuenta la cobertura *Ps*, clase que resultó ser la más conflictiva en la clasificación de *Nivel 2*.

No solo se observan diferencias en relación a las tendencias de los valores de desacuerdo a nivel general, sino que también se aprecian a nivel cobertura. La Figura 3.49a muestra como las coberturas *VA* y *PV* son las que presentan un mayor incremento de los errores Q a medida que la densidad se reduce. En el caso de las *vías pavimentadas*, se debe al aumento de la confusión con la clase *SD*, producto de la incorporación de las *pistas de tierra* (*Nivel 2*) a esta última cobertura.

Por otro lado, el aumento del desacuerdo por cantidad de la clase *VA* proviene del aumento de los errores de comisión en favor de la cobertura *ED*. La mayoría de estos errores son herencia de la cobertura

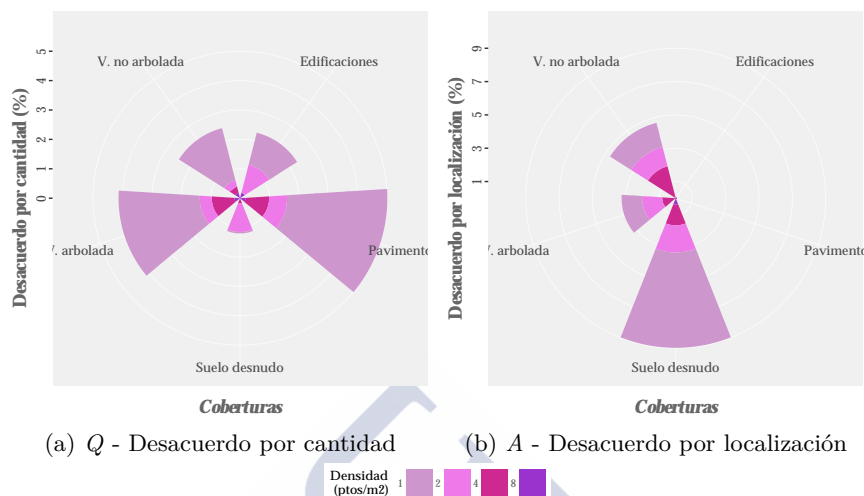


Figura 3.49: Desacuerdo por coberturas en función de la densidad empleando *HyClass* (clasificación Nivel 1 - 5 coberturas).

V_m , integrada junto con V_a en la clase VA de *Nivel 1*. La matriz de confusión de la clasificación de *Nivel 2* para la densidad de 1 pto/m² muestra un incremento de los errores de comisión de la cobertura V_m debido a la confusión con la clase Ed . Los bordes de las edificaciones se caracterizan por presentar características similares a las que presenta la vegetación arbolada puesto que alguno de los impactos del láser puede darse en los muros de las edificaciones. Errores motivados por esta causa también fueron identificados en el estudio de [Guo et al. \(2015\)](#). A esto se suma la baja resolución de la variable P (44) empleada en la segmentación para aislar las edificaciones. De forma resumida, el borde de la edificación es más ancho y dicho borde presenta similitudes con la cobertura V_m , y en consecuencia la superficie interna del contorno que se identifica con las edificaciones se reduce. Esta cadena de circunstancias no hace más que aumentar la confusión entre las coberturas V_m y Ed (*Nivel 2*), y en consecuencia entre VA y ED (*Nivel 1*). A pesar de estos errores, la fiabilidad del productor en el caso de la cobertura ED varía entre 99% (densidad de 8 pto/m²) y 94% (densidad de 1 pto/m²), mientras que los errores de comisión son del 0% para todas las densidades (Figura 3.48).

Existen muy pocos estudios que aborden el análisis de cómo la densidad de puntos influye en la precisión de las clasificaciones. Uno de estos estudios es el realizado por Tomljenovic y Rousell (2014). En su caso evalúan como la reducción de la densidad de puntos afecta a la detección de construcciones en un entorno urbano. Para ello emplean una *CoO*, donde la segmentación se realiza en base a la imagen de pendiente extraída del MDS y al nMDS, y la identificación de construcciones empleando reglas de decisión en base a la intensidad, ratio perímetro-área, índice de forma, ajuste rectangular y altura. La densidad de la nube de puntos original (18 ptos/m²) se reduce secuencialmente a 16, 9, 7, 5, 2, 1 y 0.5 ptos/m². Sus resultados muestran como la precisión de la detección de edificaciones se reduce del 90% (nube de puntos original y resolución de 0.25 m) al 6.4% (densidad de 1 pto/m² y resolución de 1.5 m). Claramente, la metodología propuesta por estos autores es muy sensible a variaciones de la densidad de puntos y únicamente se aconseja el uso de este método para densidades superiores a 5 ptos/m² y resolución superior a 0.5 m. Los resultados de *HyClass* mejoran los presentados en dicho estudio ya que una densidad de 4 ptos/m² y resolución de 0.75 m proporciona un 100% de acierto en la identificación de edificaciones.

3.4 Conclusiones

A lo largo de la última década se incrementó el desarrollo de métodos híbridos de clasificación como respuesta a la demanda de productos cartográficos con mayor nivel de detalle. Estos métodos se caracterizan por aprovechar las ventajas de los métodos basados en píxeles y los orientados a objetos. La gran mayoría de estos clasificadores se han probado en zonas urbanas empleando imágenes de resolución media. En casos muy puntuales, la tecnología LiDAR se empleó como fuente de datos auxiliar. Tomando como base estos antecedentes, en esta investigación se propone un nuevo método de clasificación donde se integran en un árbol de decisión procesos basados en píxeles con otros orientados a objetos (*HyClass*). Este método se usará para identificar 8 tipos de coberturas del suelo en un entorno rural empleado únicamente

datos LiDAR. Para su desarrollo se prestó especial atención a la corrección de la intensidad LiDAR, a la creación de capas de información (variables) y al posterior análisis de su importancia para discriminar las diferentes coberturas. Finalmente se evalúa el potencial de este método frente a un método basado en píxeles empleando el algoritmo *random forest*. Adicionalmente, se analizó la robustez del método de clasificación propuesto ante variaciones de la densidad de puntos.

Las principales conclusiones que se extraen de este estudio son:

En cuanto a la normalización de la intensidad ...

La intensidad se ha considerado por mucho tiempo un *extra* de los datos LiDAR. Si bien esa condición de *extra* inicialmente la relegó a un segundo plano, tanto en relación a su uso como a las atenciones recibidas durante el registro y pre-procesado, actualmente su papel en la mayoría de los procesos de clasificación se considera clave. Adicionalmente, el número de aplicaciones de esta información se ha multiplicado, planteando renovados retos tanto para la tecnología en sí como para la componente radiométrica de los datos LiDAR.

Teniendo en cuenta la importancia de este atributo y las experiencias y recomendaciones hechas en trabajos previos, se llevó a cabo la normalización de los datos LiDAR. El proceso de normalización adoptado consta de 4 niveles: 1) corrección por el rango; 2) corrección por el ángulo de escaneo; 3) aplicación de filtro de paso bajo a nivel punto y 4) expansión del histograma. El análisis visual de los resultados de la normalización mostraron que el efecto debido al patrón de escaneo y al consecuente aumento de la densidad de puntos en el borde de pasada y zona de solape entre pasadas contiguas fue mitigado pero no totalmente corregido. Tal vez el empleo de un cilindro con mayor radio en estas zonas pudiera contribuir a mejorar los resultados. Por otro lado, el efecto bandeado debido al patrón de escaneo únicamente pudo ser mitigado en algunas zonas mientras que en otras dicho efecto persistió. Sin embargo, el bandeado debido al efecto del relieve y el ángulo de escaneo fue totalmente corregido.

A continuación se analizó la magnitud del efecto de la excesiva corrección de la intensidad y a partir de dicho análisis se puso de

manifiesto la necesidad de determinar para cada estudio y conjunto de datos el valor del umbral de pendiente más apropiado. Finalmente, se comprobó si el proceso de normalización había contribuido a reducir la heterogeneidad interna de las coberturas en relación a los valores de intensidad. Los análisis realizados indican que dicho proceso permitió mejorar la información referente a la intensidad, disminuyendo la variabilidad en todas las coberturas analizadas. Este proceso también permitió comprender el origen de algunos de los errores que presenta la intensidad mostrando la necesidad de mejorar y *personalizar* los procesos destinados a corregir esta información.

En cuanto a la importancia de las variables ...

El análisis de la importancia de las variables disponibles para llevar a cabo una clasificación no sólo es de utilidad para aumentar la eficiencia y precisión del proceso de clasificación, sino que también facilita la comprensión de los datos y la interpretación de resultados. En este estudio se generaron 72 variables a partir de una nube de puntos LiDAR. Dichas variables se encuentran relacionadas con la altura, la intensidad, los retornos, la rugosidad y la textura. El algoritmo *random forest* permitió analizar la importancia general de las variables para identificar las diferentes coberturas del suelo, su importancia para cada cobertura individualmente así como las variables más útiles para diferenciar coberturas con características similares.

En relación al primer punto, en un contexto global el análisis de la importancia de las variables (IV) LiDAR fue de gran utilidad, pues permitió identificar tanto las variables más útiles como aquellas que aportan menos información para la identificación de las coberturas. Las variables más relevantes se encuentran relacionadas con la altura (nM_{V_m} (3) y nMS_{PR} (1)); y con la textura de la altura ($GLCM T\Delta z_{\sigma^2}$ (66) y $GLCM T\Delta z_{\mu}$ (65)). Se esperaba un papel destacado de las dos primeras puesto que nM_{V_m} (3) en teoría podrían facilitar la identificación de las zonas que presentan o no matorral, fundamentalmente bajo arbolado, mientras que nMS_{PR} (1) se considera fundamental para diferenciar las coberturas vinculadas al *terreno* de las que se relacionan con los *objetos*. A continuación, las variables que se presentan más relevantes se encuentran relacionadas con los retornos, caso de RE (41), con la intensidad de los datos LiDAR (I''_{PR} (23), I''_{UR} (24) y I''_{V_m} (25)),

la rugosidad por medio de la pendiente (P (44)) y la textura de la intensidad ($GLCM I''_{\mu}$ (49)). En el extremo opuesto se encuentran gran parte de las variables de altura y textura de la intensidad, y la totalidad de las variables de textura de la elevación. Todas ellas muestran niveles de importancia muy bajos.

En un contexto por categoría, se analizó la importancia de las variables para cada cobertura individualmente. Las variables relacionadas con la intensidad presentan una importancia mucho mayor para las coberturas *terreno* que para las vinculadas a los *objetos*. En relación al primer grupo de coberturas, llama la atención la importancia de la variable N_z (46) con respecto a la clase Ps y no para la clase Pv , donde I''_{V_m} (25) es la variable más relevante. Estos resultados se vieron respaldados por su uso decisivo en la primera segmentación incluida en **HyClass**, lo que facilitó la identificación de estas dos coberturas.

Adicionalmente, las variables más relevantes en relación a los *objetos* son un grupo muy reducido. Las variables RE (41) y nM_{V_m} (3) son claramente las más destacadas para las clases Ed y V_m , respectivamente. En el caso de la cobertura *vegetación arbolada*, nMS_{PR} (1), $GLCM T\Delta z_{\mu}$ (65), nM_{V_m} (3) y $GLCM T\Delta z_{\sigma^2}$ (66) son por este orden las variables más importantes. Además de ser un grupo muy reducido, en el caso de las clases Ed y V_m también son muy específicas. El *ratio retorno edificación* (RE (41)) en el caso de las edificaciones es un caso muy claro. Como se comprobaría posteriormente con los resultados de la clasificación, la modificación en el cálculo de esta variable permitió mitigar los errores de comisión entre las coberturas Ed y V_a y V_m . Por otro lado, se esperaba que el nM_{V_m} (3) se mostrase como una de las variables más relevantes para la *vegetación mixta*, pero también se esperaba de otras variables puesto que no era la única que podía revelar la presencia de vegetación bajo arbolado. Sin embargo, ni el coeficiente de curtosis o asimetría, ni la penetrabilidad, ni los percentiles de altura, ni los intervalos de densidad mostraron tener importancia en relación a esta cobertura. También se observó una ligera importancia de las variables de rugosidad (P (44), $Std_{\Delta z > 0.7}$ (43) y $Std Z$ (42)), debido probablemente a la presencia de mayor cantidad de retornos múltiples que en la mayoría de coberturas.

A medio camino entre ambos grupos se encuentra la cobertura V_r , cuyas características se solapan con ambos. Dicha cobertura presenta similitudes con las clases S_d y V_b en relación a la relevancia de las variables de altura nMS_{PR} (1) y nM_{V_m} (3). También presenta similitudes con la cobertura V_a con respecto a la importancia de la textura de la altura y por otro lado, también a la pérdida de importancia de las variables de intensidad como en el caso de las pistas de tierra.

Finalmente, se analizó la importancia de las variables para separar grupos de coberturas considerando tres escenarios. Los resultados de este análisis fueron de gran utilidad tanto en la fase de desarrollo del método **HyClass** como en la fase de análisis de los resultados. En el primer escenario se consideraron las coberturas *terreno*: V_b , S_d , P_s y P_v . A pesar de la gran cantidad de variables calculadas, la imagen de intensidad (I'_{PR} (23)) se mantiene como la información por excelencia para diferenciar estas coberturas. Estos resultados vuelven a poner de manifiesto la importancia de esta variable y por tanto la necesidad de seguir investigando para mejorar la calidad de esta información, no solo en la fase de procesado sino también en la fase de captura. En el segundo escenario se analizó qué variables son más relevantes para la diferenciación de las coberturas V_r y V_b . En contra de lo esperado y de resultados obtenidos en estudios previos, las variables relacionadas con la intensidad presentan poca importancia en el caso de identificar estas dos coberturas. Por el contrario, las variables más relevantes se relacionan con la altura: nM_{V_m} (3) y nMS_{PR} (1). En el último escenario se consideraron las coberturas Ed , V_a y V_m . La variable por excelencia de este escenario fue nM_{V_m} (3). Llama la atención que esta variable, tal y como está planteada, no se ha encontrado en ningún estudio previo y sin embargo aquí se ha mostrado determinante, no solo para identificar la cobertura V_m , o para reconocer parte de la cobertura V_r sino que también ha tenido un papel relevante en la identificación de los tramos ocultos por la vegetación en relación a las clases P_s y P_v .

Ha sido muy complicado realizar un análisis comparativo de los resultados obtenidos con los conseguidos por otros investigadores pues no se ha encontrado ningún estudio con características similares (empleo de datos LiDAR a nivel pixel y/o objeto que tuvieran en cuenta tantas variables). Por ello, gran parte de la discusión se ha centrado en

casuísticas particulares de un pequeño grupo de variables relacionadas con alguna cobertura.

Como reflexión final, no se debe olvidar que estos resultados son específicos de los datos que aquí se emplearon y de las coberturas del suelo consideradas, de tal forma que su aplicación a otros contextos debe hacerse con cautela. Sin embargo, las casuísticas analizadas y las reflexiones que las acompañan pueden ser de gran utilidad para interpretar otros escenarios y mejorar los procesos de clasificación.

En cuanto a la precisión del método híbrido *HyClass* ...

La identificación de 8 coberturas del suelo en un entorno rural (*pistas de tierra, vías pavimentadas, suelo desnudo, vegetación baja, vegetación arbustiva, vegetación arbolada, vegetación mixta y edificaciones*) aplicando el método ***HyClass*** logró una precisión de 96.88% (IC: 95.35% - 97.93%), llegando a una precisión de 99.4% (IC: 98.10% - 99.84%) al considerar 5 de las coberturas más habituales en los procesos de clasificación (*vías pavimentadas, suelo desnudo, vegetación no arbolada, vegetación arbolada y edificaciones*). Para ello se utilizaron únicamente 6 variables derivadas de una nube de puntos LiDAR monocromática de retorno discreto con una densidad de 8 pto/m². El análisis comparativo con otros métodos de clasificación donde se emplearon datos LiDAR multi-espectrales con densidades superiores a 20 pto/m² o mediante la aplicación de algoritmos como *random forest* a nivel píxel, vino a confirmar el elevado potencial y efectividad del método ***HyClass***. Dichos resultados también se pueden considerar como una prueba de que los datos LiDAR como fuente de información única son suficientes para llevar a cabo con éxito una clasificación de coberturas del suelo en un entorno rural. Esta última afirmación es cierta para las clases que se han tenido en cuenta en este estudio siempre y cuando la densidad de puntos sea suficiente para caracterizar las coberturas objetivo. Sin lugar a dudas, gran parte del éxito del método ***HyClass*** se debe al árbol de decisión híbrido. En este árbol se integran procesos de asignación a nivel píxel con segmentaciones a nivel local que además de permitir el uso de variables *espectrales* también posibilitan el empleo de variables de forma, tamaño y contexto.

Teniendo en cuenta las coberturas a nivel individual, el método híbrido propuesto presenta una fiabilidad del productor y del usuario

superior al 96% en la identificación de la mayoría de las coberturas (*vías pavimentadas, edificaciones, suelo desnudo, vegetación baja y vegetación mixta*). Tal y como se esperaba, la identificación de la clase *pistas de tierra* fue la que presentó las mayores dificultades y también un desafío de futuro. Si bien esta clase muestra uno de los errores de comisión más bajos ($\approx 1\%$), también alcanza el error de omisión más alto (13%). Estos errores de omisión se deben a la pretensión de identificar los tramos de pistas que se encuentran ocultos bajo la vegetación. Estos errores se localizan en zonas con presencia de vegetación densa o con varios estratos que dificultan la llegada del láser al terreno, prueba de ello es que el 70% de los errores de omisión son debidos a la confusión con las clases *Va*, *Vr* y *Vm*. A pesar de estos errores el porcentaje de detección de las pistas de tierra, 85%, es similar al alcanzado en estudios específicos de detección de este tipo de vías.

Por otro lado, se observó cierta confusión entre las coberturas *Vb* y *Vr*. La posibilidad de ocurrencia de este error ya se observara a partir de los resultados del *Escenario 2*. Estos últimos resultados mostraron la relevancia de las variables de rugosidad P (44) y RMS_{Dn} (47) y de las variables de altura nM_{Vm} (3) y nMS_{PR} (1). Lo particular de la clase *Vr* también se observó en el análisis de la IV cuando la distribución de sus variables en la gráfica de importancia guardaba similitudes con otras coberturas pero no las suficientes para ser integrada en uno de los dos grupos (*terreno ó objetos*). Compartir características con clases de ambos grupos aumentó la dificultad para su identificación. Prueba de tal dificultad es que dicha identificación se realizó en tres etapas, tal y como se refleja en el árbol de decisión del método *HyClass*.

En relación a la confusión entre las coberturas *Va* y *Vm*, la magnitud de estos errores se encuentra estrechamente vinculada a la calidad del nM_{Vm} (3), pues junto con la altura resultó ser una variable clave para la diferenciación de estas coberturas. Esta variable es dependiente de la densidad de puntos, el ratio de penetrabilidad de la vegetación, la precisión del MDT, la orografía,... factores que provocan que la tarea de caracterizar la vegetación que se encuentra bajo arbolado sea todo un desafío. Esta dependencia que presenta la variable nM_{Vm} (3) con los factores citados y su importancia en el método *HyClass*, la señalan como una de las posibles flaquezas que presenta este método híbrido.

Este límite pone de manifiesto la necesidad de explorar el empleo de nuevas o renovadas variables que refuercen la identificación de estas coberturas

En cuanto a los valores de desacuerdo ...

El empleo de valores de desacuerdo, tanto en relación a la cantidad como a la localización, no es una práctica muy extendida en el análisis de los resultados de una clasificación, sin embargo han mostrado que proporcionan información relevante que no es posible extraer de la matriz de confusión o de los valores de precisión o fiabilidad. En relación con esto, se compararon los resultados del método **HyClass** y los obtenidos a nivel píxel empleando *random forest*. Se observó que el desacuerdo general del método híbrido es tres veces menor que el obtenido por *random forest* (3.12% y 10.6%, respectivamente). Dicha comparación también permitió comprobar la ventaja del primero frente al segundo en relación a los errores de localización. Mientras que el desacuerdo por localización de **HyClass** es de poco más del 1%, en el caso de *random forest* supera el 8.5%, mientras que el desacuerdo por cantidad de ambos métodos es $\approx 2\%$.

En cuanto a la influencia de la densidad de puntos ...

Para comprobar la robustez del método **HyClass** ante variaciones de la densidad de puntos LiDAR, se redujo secuencialmente y de manera artificial la densidad de puntos de la nube LiDAR original, obteniéndose tres nubes con densidades de 4, 2 y 1 pto/m². Como se esperaba, existe una relación directa entre la densidad de puntos y la precisión de la clasificación, de manera que cada vez que la densidad de puntos se duplica, la precisión de la clasificación aumenta aproximadamente un 4%. Esta diferencia llega al 12% si se tienen en cuenta los resultados de la clasificación al emplear la nube de puntos con menor densidad (84.0%) y los datos LiDAR originales (96.9%).

En cuanto a los valores de desacuerdo, la reducción de la densidad de puntos provoca que los valores de desacuerdo por localización se disparen (pasan de 1.06% con una densidad de 8 pto/m² a 10.51% empleando la mínima densidad), debido principalmente a fallos en la detección de las pistas de tierra y a la confusión entre V_a y V_m por la pérdida de detalle de la variable nM_{V_m} (3). Probablemente el punto donde está fallando el

método **HyClass** sea en que el nivel de detalle de las capas de entrada no es suficiente para caracterizar las coberturas que se pretenden identificar, incumpliendo la regla de que la resolución espacial de los datos debe ser similar a la escala de acción. En este caso concreto se encuentran las coberturas *Ps*, *Va* y *Vm*, pues presentan ciertas particularidades que hacen que su correcta identificación se encuentra condicionada por la disponibilidad de datos que permita la obtención de información concreta y detallada. Información que probablemente no se pueda extraer a partir de nubes de puntos con baja densidad.

De manera particular, también se analizó como la densidad de puntos influye en la detección de las pistas de tierra. Los resultados muestran como el porcentaje de detección de estas estructuras pasa del 85.8% empleando una densidad de 8 ptos/m² al 47.4% al emplear la menor densidad. Esta reducción de la precisión se debe tanto a un aumento de los errores de omisión como de los de comisión al reducir la densidad de puntos. Los errores de omisión son causados mayoritariamente por falta de definición de las pistas en zonas arboladas y en consecuencia clasificadas erróneamente como *Va* o *Vr*, mientras que los de comisión son provocados mayoritariamente por un aumento de la similitud espectral entre coberturas, principalmente con las clases *Pv* y *Sd*.

Futuras investigaciones ...

Las diferentes actuaciones que se han ejecutado en este capítulo han arrojado luz a muchas de las inquietudes iniciales, como por ejemplo si un método híbrido como **HyClass** permitiría mejorar la identificación de coberturas del suelo en comparación con los métodos desarrollados hasta el momento; si los datos LiDAR serían suficientes para lograrlo, o donde se encuentra el límite de precisión aceptable en relación a la densidad de puntos,... Sin embargo, también ha provocado la necesidad de buscar nuevas fuentes de luz para iluminar nuevas inquietudes...

... si es posible formular nuevas variables o re-formular algunas de las existentes para simular la interpretación humana y reforzar la identificación de coberturas como vegetación arbolada y vegetación mixta.

... si introducir *random forest* en cada nivel para establecer las

variables y umbrales más adecuados permitiría mejorar la precisión de los resultados y aumentar el nivel de automatización de los procesos.

... si se puede aumentar el número de coberturas a identificar, por ejemplo, especies forestales, cultivos,... empleando datos LiDAR multi-espectrales.

... si **HyClass** tiene potencial como método de detección de pistas y si es posible mejorar la identificación y delimitación de éstas.

... después de pasar por el píxel y el objeto, si *lo híbrido* puede llegar a nivel punto.

... si los resultados de la clasificación pueden emplearse en estudios de interfaces urbano forestales en el marco de los incendios forestales; la obtención de mapas de tipos de combustible; seguimiento y monitoreo de planes de ordenación o detección de irregularidades, caso concreto de la PAC (Política Agrícola Común).

Agradecimientos

Este trabajo fue realizado en el Grupo de Investigación Laboratorio del Territorio (GI.-1934-Te-Bio) de la Universidad de Santiago de Compostela (Galicia, España).

A mis compañer@s en el [LaboraTe](#), muchas gracias por vuestro esfuerzo y ayuda, sin vosotr@s no hubiera sido posible. De manera muy especial le agradezco a Laura Barreiro y a Eduardo M. González su valiosa e irremplazable ayuda.





Referencias bibliográficas

- Aguilar, F.J., Agüera, F., Aguilar, M.A., Carvajal, F., 2005. Effects of terrain morphology, sampling density, and interpolation methods on grid DEM accuracy. *Photogrammetric Engineering & Remote Sensing* 71, 805 – 816.
- Aguilar, F.J., Nemmaoui, A., Aguilar, M.A., Chourak, M., Zarhloule, Y., García Lorca, A.M., 2016. A quantitative assessment of forest cover change in the moulouya river watershed (Morocco) by the integration of a subpixel-based and object-based analysis of landsat data. *Forests* 7, 1 – 19.
- Aguirre-Gutiérrez, J., Seijmonsbergen, A.C., Duivenvoorden, J.F., 2012. Optimizing land cover classification accuracy for change detection, a combined pixel-based and object-based approach in a mountainous area in Mexico. *Applied Geography* 34, 29 – 37.
- Ai, T., Li, J., 2010. A DEM generalization by minor valley branch detection and grid filling. *ISPRS Journal of Photogrammetry and Remote Sensing* 65, 198 – 207.
- Alonso, M., Malpica, J., 2010. Satellite imagery classification with lidar data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Science* XXXVIII, 730 – 741.
- Alonso-Benito, A., Arroyo, L.A., Arbelo, M., Hernández-Leal, P., 2016. Fusion of WorldView-2 and LiDAR data to map fuel types in the Canary Islands. *Remote Sensing* 8, 1 – 18.
- Anderson, E., Thompson, J., Crouse, D., Austin, R., 2006. Horizontal resolution and data density effects on remotely sensed LIDAR-based DEM. *Geoderma* 132, 406 – 415.
- Antonarakis, A., Richards, K., Brasington, J., 2008. Object-based land cover classification using airborne LiDAR. *Remote Sensing of Environment* 112, 2988 – 2998.

- Arefi, H., Hahn, M., 2005. A morphological reconstruction algorithm for separating off-terrain points from terrain points in laser scanning data, in: *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 120 – 125.
- Arefi, H., Hahn, M., Lindenberger, J., 2003. LIDAR data classification with remote sensing tools, in: *Proceedings of the ISPRS Commission IV Joint Workshop: Challenges in Geospatial Analysis, Integration and Visualization II*, Stuttgart, Germany. pp. 131 – 136.
- Aryal, R.R., Latifi, H., Heurich, M., Hahn, M., 2017. Impact of slope, aspect, and habitat-type on LiDAR-derived digital terrain models in a near natural, heterogeneous temperate forest. *PFG – Journal of Photogrammetry, Remote Sensing and Geoinformation Science* 85, 243 – 255.
- Asal, F.F., 2016. Evaluating the effects of reductions in LiDAR data on the visual and statistical characteristics of the created digital elevation models, in: *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 91 – 98.
- Axelsson, P., 1999. Processing of laser scanner data: algorithms and applications. *ISPRS Journal of Photogrammetry and Remote Sensing* 54, 138 – 147.
- Axelsson, P., 2000. DEM generation from laser scanner data using adaptive TIN models. *International Archives of Photogrammetry and Remote Sensing* 33, 111 – 118.
- Azizi, Z., Najafi, A., Sadeghian, S., 2014. Forest road detection using LiDAR data. *Journal of Forestry Research* 25, 975 – 980.
- Baatz, M., Schäpe, A., 2000. Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation, in: Strobl, J., Blaschke, T., Griesbner, G. (Eds.), *Angewandte Geographische Informations-Verarbeitung*, pp. 1 – 12.
- Barreiro-Fernández, L., Buján, S., Miranda, D., Diéguez-Aranda, U., González-Ferreiro, E., 2016. Accuracy assessment of LiDAR-derived digital elevation models in a rural landscape with complex terrain. *Journal of Applied Remote Sensing* 10, 016014.
- Bartels, M., Wei, H., 2006. Segmentation of LiDAR data using measures of distribution. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36, 426 – 31.

- Bartels, M., Wei, H., 2010. Threshold-free object and ground point separation in LIDAR data. *Pattern Recognition Letters* 31, 1089 – 1099.
- Bater, C.W., Coops, N.C., 2009. Evaluating error associated with lidar-derived DEM interpolation. *Computers & Geosciences* 35, 289 – 300.
- Beck, S.J., Olsen, M.J., Sessions, J., Wing, M.G., 2015. Automated extraction of forest road network geometry from aerial LiDAR. *European Journal of Forest Engineering* 1, 21 – 33.
- Belgiu, M., Drăguț, L., 2016. Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing* 114, 24 – 31.
- Belgiu, M., Tomljenovic, I., Lampoltshammer, T.J., Blaschke, T., Höfle, B., 2014. Ontology-based classification of building types detected from airborne laser scanning data. *Remote Sensing* 6, 1347 – 1366.
- Bernardini, A., Frontoni, E., Malinverni, E., Mancini, A., Tassetti, A., Zingaretti, P., 2010. Pixel, object and hybrid classification comparisons. *Journal of Spatial Science* 55, 43–54.
- Bhaskaran, S., Paramananda, S., Ramnarayan, M., 2010. Per-pixel and object-oriented classification methods for mapping urban features using Ikonos satellite data. *Applied Geography* 30, 650 – 665.
- Blaschke, T., Hay, G.J., Kelly, M., Lang, S., Hofmann, P., Addink, E., Feitosa, R.Q., van der Meer, F., van der Werff, H., van Coillie, F., Tiede, D., 2014. Geographic object-based image analysis: Towards a new paradigm. *ISPRS Journal of Photogrammetry and Remote Sensing* 87, 180 – 191.
- Bolón-Canedo, V., Sánchez-Marroño, N., Alonso-Betanzos, A., 2015. Recent advances and emerging challenges of feature selection in the context of big data. *Knowledge-Based Systems* 86, 33 – 45.
- Boyaci, D., Erdoğan, M., Yildiz, F., 2017. Pixel- versus object-based classification of forest and agricultural areas from multiresolution satellite images. *Turkish Journal of Electrical Engineering & Computer Sciences* 25, 365 – 375.
- Breiman, L., 1984. *Classification and regression trees*. Routledge.
- Breiman, L., 1996. Bagging predictors. *Machine Learning* 24, 123 – 140.
- Breiman, L., 2001. Random forests. *Machine Learning* 45, 5 – 32.

- Brennan, R., Webster, T., 2006. Object-oriented land cover classification of LiDAR-derived surfaces. *Canadian Journal of Remote Sensing* 32, 162 – 172.
- Bretar, F., Chehata, N., 2010. Terrain modeling from lidar range data in natural landscapes: A predictive and bayesian framework. *IEEE Transactions on Geoscience and Remote Sensing* 48, 1568 – 1578.
- Briese, C., Pfeifer, N., Dorninger, P., 2001. Applications of the robust interpolation for DTM determination. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34 (Part 3/A), 55 – 61.
- Brovelli, M.A., Cannata, M., Longoni, U.M., 2002. Managing and processing LIDAR data within GRASS, in: *GRASS Users Conference*, pp. 1 – 29.
- Buján, S., Corbelle, E., Miranda, D., 2013a. Clasificación de los usos del suelo en una zona rural con datos LiDAR multitemporales. *Universidade de Santiago de Compostela, Servicio de Publicaciones e Intercambio Científico*. chapter 3. pp. 61 – 84.
- Buján, S., González-Ferreiro, E., Barreiro-Fernández, L., Santé, I., Corbelle, E., Miranda, D., 2013b. Classification of rural landscapes from low-density lidar data: is it theoretically possible? *International Journal of Remote Sensing* 34, 5666 – 5689.
- Buján, S., González-Ferreiro, E., Reyes-Bueno, F., Barreiro-Fernández, L., Crecente, R., Miranda, D., 2012. Land use classification from lidar data and ortho-images in a rural area. *The Photogrammetric Record* 27, 401 – 422.
- Cai, J., Luo, J., Wang, S., Yang, S., 2018. Feature selection in machine learning: A new perspective. *Neurocomputing* 300, 70 – 79.
- Cánovas-García, F., Alonso-Sarría, F., 2015. A local approach to optimize the scale parameter in multiresolution segmentation for multispectral imagery. *Geocarto International* 30, 937 – 961.
- Chan, J.C.W., Paelinckx, D., 2008. Evaluation of random forest and adaboost tree-based ensemble classification and spectral band selection for ecotope mapping using airborne hyperspectral imagery. *Remote Sensing of Environment* 112, 2999 – 3011.
- Chang, L.D., 2010. Bare-earth extraction and vehicle detection in forested terrain from airborne lidar point clouds. *Doctoral dissertation*. University of Florida. Gainesville, FL, USA.

- Charaniya, A., Manduchi, R., Lodha, S., 2004. Supervised parametric classification of aerial LiDAR data, in: IEEE 2004 Conference on Computer Vision and Pattern Recognition Workshop, pp. 1–8.
- Chenhata, N., Guo, L., Mallet, C., 2009. Airborne lidar feature selection for urban classification using random forests. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 38, 207 – 212.
- Chen, C., Li, Y., 2012. A robust method of thin plate spline and its application to DEM construction. *Computers & Geosciences* 48, 9 – 16.
- Chen, C., Li, Y., Li, W., Dai, H., 2013. A multiresolution hierarchical classification algorithm for filtering airborne LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing* 82, 1 – 9.
- Chen, C., Li, Y., Yan, C., Dai, H., Liu, G., 2015a. A Thin Plate Spline-based feature-preserving method for reducing elevation points derived from LiDAR. *Remote Sensing* 7, 11344 – 11371.
- Chen, C., Yan, C., Cao, X., Guo, J., Dai, H., 2015b. A greedy-based multiquadric method for LiDAR-derived ground data reduction. *ISPRS Journal of Photogrammetry and Remote Sensing* 102, 110 – 121.
- Chen, H., Cheng, M., Li, J., Liu, Y., 2012a. An iterative terrain recovery approach to automated DTM generation from airborne LIDAR point clouds. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 39, 363 – 368.
- Chen, Q., 2010. Assessment of terrain elevation derived from satellite laser altimetry over mountainous forest areas using airborne lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing* 65, 111 – 122.
- Chen, Q., Gong, P., Baldocchi, D., Xie, G., 2007. Filtering airborne laser scanning data with morphological methods. *Photogrammetric Engineering & Remote Sensing* 73, 175 – 185.
- Chen, Q., Wang, H., Zhang, H., Sun, M., Liu, X., 2016a. A point cloud filtering approach to generating DTM for steep mountainous areas and adjacent residential areas. *Remote Sensing* 8, 71.
- Chen, Y., Ge, Y., Jia, Y., 2017. Integrating object boundary in super-resolution land-cover mapping. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 10, 219 – 230.

- Chen, Y., Su, W., Li, J., Sun, Z., 2009. Hierarchical object oriented classification using very high resolution imagery and LIDAR data over urban areas. *Advances in Space Research* 43, 1101 – 1110.
- Chen, Y., Zhou, Y., Ge, Y., An, R., Chen, Y., 2018. Enhancing land cover mapping through integration of pixel-based and object-based classifications from remotely sensed imagery. *Remote Sensing* 10, 77.
- Chen, Z., Devereux, B., Gao, B., Amable, G., 2012b. Upward-fusion urban DTM generating method using airborne lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing* 72, 121 – 130.
- Chen, Z., Xu, B., Gao, B., 2016b. An image-segmentation-based urban dtm generation method using airborne lidar data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 9, 496 – 506.
- Chirici, G., Scotti, R., Montagni, A., Barbati, A., Cartisano, R., Lopez, G., Marchetti, M., McRoberts, R., Olsson, H., Corona, P., 2013. Stochastic gradient boosting classification trees for forest fuel types mapping through airborne laser scanning and IRS LISS-III imagery. *International Journal of Applied Earth Observation and Geoinformation* 25, 87 – 97.
- Chuvieco, E., Riaño, D., Wagtendok, J.V., Morsdorf, F., 2003. Wildland Fire Danger Estimation and Mapping. World Scientific. volume 4 of *Series in Remote Sensing*. chapter Chapter 5. Fuel Loads and Fuel Type Mapping. pp. 119 – 142.
- Ciriza, R., González-Audícana, M., Albizua, L., 2012. Procedimiento simplificado para la caracterización de la textura del cultivo del frutal a nivel de parcela mediante los parámetros de Haralick. *Revista de Teledetección* 37, 57 – 66.
- Clark, M.L., Clark, D.B., Roberts, D.A., 2004. Small-footprint lidar estimation of sub-canopy elevation and tree height in a tropical rain forest landscape. *Remote Sensing of Environment* 91, 68 – 89.
- Cleve, C., Kelly, M., Kearns, F., Moritz, M., 2008. Classification of the wildland-urban interface: A comparison of pixel-and object-based classifications using high-resolution aerial photography. *Computers, Environment and Urban Systems* 32, 317 – 326.
- Cohen, J., 1960. A coefficient of agreement for nominal scales. *Educational and Psychological Measurement* 20, 37 – 46.
- Congalton, R.G., Green, K., 2009. *Assessing the Accuracy of Remotely Sensed Data. Principles and Practices*. Boca Raton, FL: CRC Press.

- Coren, F., Sterzai, P., 2006. Radiometric correction in laser scanning. *International Journal of Remote Sensing* 27, 3097 – 3104.
- Costa, H., Carrão, H., Bação, F., Caetano, M., 2014. Combining per-pixel and object-based classifications for mapping land cover over large areas. *International Journal of Remote Sensing* 35, 738 – 753.
- Croneborg, L., Saito, K., Matera, M., McKeown, D., van Aardt, J., 2015. Digital Elevation Models. A guidance note on how Digital Elevation Models are created and used. The Africa Water sector, the Latin America and Caribbean Disaster Risk Management unit and the Global Facility for Disaster Reduction and Recovery (GFDRR) at the World Bank.
- Definiens, 2007. Definiens Developer 7. Reference Book. Document version 7.0.2.936 ed., Definiens AG.
- Deng, S.S., Shi, W.Z., 2013. Integration of different filter algorithms for improving the ground surface extraction from airborne LiDAR data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XL-2/W1*, 105 – 110.
- Dengsheng, L., Hetrick, S., Moran, E., 2010. Land coverclassification in a complex urban-rural landscape with QuickBird imagery. *Photogrammetric Engineering & Remote Sensing* 76, 1159 – 1168.
- Ding, Q., Chen, W., King, B., Liu, Y., Liu, G., 2013. Combination of overlap-driven adjustment and Phong model for LiDAR intensity correction. *ISPRS Journal of Photogrammetry and Remote Sensing* 75, 40 – 47.
- Dinis, J., Navarro, A., Soares, F., Santos, T., Freire, S., Fonseca, A., Afonso, N., Tenedório, J., 2010. Hierarchical object-based classification of dense urban areas by integrating high spatial resolution satellite images and LiDAR elevation data, in: Addink, E., Coillie, F.V. (Eds.), *GEOBIA 2010: Geographic Object-Based Image Analysis*, Ghent, Belgium. pp. 1 – 6.
- Donoghue, D.N., Watt, P.J., Cox, N.J., Wilson, J., 2007. Remote sensing of species mixtures in conifer plantations using LiDAR height and intensity data. *Remote Sensing of Environment* 110, 509 – 522.
- Elmqvist, M., Jungert, E., Lantz, F., Persson, Å., Söderman, U., 2001. Terrain modelling and analysis using laser scanner data. *International Archives of Photogrammetry and Remote Sensing* 34, 219 – 226.
- Erdogan, S., 2009. A comparison of interpolation methods for producing digital elevation models at the field scale. *Earth Surface Processes and Landforms* 34, 366 – 376.

- Espendola, G.M., Camara, G., Reis, I.A., Bins, L.S., Monteiro, A.M., 2006. Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation. *International Journal of Remote Sensing* 27, 3035 – 3040.
- Estornell, J., Ruiz, L., Velázquez-Martí, B., Hermosilla, T., 2011. Analysis of the factors affecting LiDAR DTM accuracy in a steep shrub area. *International Journal of Digital Earth* 4, 521 – 538.
- Evans, J.S., Hudak, A.T., 2007. A multiscale curvature algorithm for classifying discrete return LiDAR in forested environments. *IEEE Transactions on Geoscience and Remote Sensing* 45, 1029 – 1038.
- Fares, S., Bajocco, S., Salvati, L., Camarretta, N., Dupuy, J.L., Xanthopoulos, G., Guijarro, M., Madrigal, J., Hernando, C., Corona, P., 2017. Characterizing potential wildland fire fuel in live vegetation in the Mediterranean region. *Annals of Forest Science* 74, 1 – 14.
- Feng, Y., Ji-xian, Z., Li, Z., Jing-xiang, G., 2009. Urban DEM generation from airborne lidar data, in: 2009 Urban Remote Sensing Joint Event, IEEE, Shanghai. pp. 1 – 5.
- Ferraz, A., Mallet, C., Chehata, N., 2016. Large-scale road detection in forested mountainous areas using airborne topographic lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing* 112, 23 – 36.
- Fields Development Team, 2006. *fields: Tools for Spatial*. v.8.2-1 ed. National Center for Atmospheric Research. Boulder, CO.
- Filin, S., 2002. Surface clustering from airborne laser scanning data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34 (Part 3/A), 119 – 124.
- Fisher, P.F., Tate, N.J., 2006. Causes and consequences of error in digital elevation models. *Progress in Physical Geography: Earth and Environment* 30, 467 – 489.
- Flood, M., 2001. LiDAR activities and research priorities in the commercial sector. *International Archives of Photogrammetry and Remote Sensing* 34 (3/W4), 3 – 8.
- Foody, G., 2002. Status of land cover classification accuracy assessment. *Remote sensing of environment* 80, 185 – 201.
- Foody, G.M., 2008. Harshness in image classification accuracy assessment. *International Journal of Remote Sensing* 29, 3137 – 3158.

- Forlani, G., Nardinocchi, C., 2007. Adaptive filtering of aerial laser scanning data. *International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences* 36, 130 – 135.
- Gallopín, G.C., 1997. Sustainability indicators. A report on the project on Indicators of sustainable development. Wiley, Chichester. chapter Indicators and their use: Information for decision-making. Part one-introduction. pp. 13 – 27.
- García, M., Riaño, D., Chuvieco, E., Danson, F., 2010. Estimating biomass carbon stocks for a Mediterranean forest in central Spain using LiDAR height and intensity data. *Remote Sensing of Environment* 114, 816 – 830.
- García, M., Riaño, D., Chuvieco, E., Salas, J., Danson, F.M., 2011. Multispectral and LiDAR data fusion for fuel type mapping using Support Vector Machine and decision rules. *Remote Sensing of Environment* 115, 1369 – 1379.
- Gastellu-Etchegorry, J.P., Yin, T., Lauret, N., Cajgfinger, T., Gregoire, T., Grau, E., Feret, J.B., Lopes, M., Guilleux, J., Dedieu, G., Malenovsky, Z., Cook, B.D., Morton, D., Rubio, J., Durrieu, S., Cazanave, G., Martin, E., Ristorcelli, T., 2015. Discrete Anisotropic Radiative Transfer (DART 5) for modeling airborne and satellite spectroradiometer and LIDAR acquisitions of natural and urban landscapes. *Remote Sensing* 7, 1667 – 1701.
- Genuer, R., Poggi, J.M., Tuleau-Malot, C., 2010. Variable selection using random forests. *Pattern Recognition Letters* 31, 2225 – 2236.
- Ghosh, A., Fassnacht, F.E., Joshi, P., Koch, B., 2014. A framework for mapping tree species combining hyperspectral and LiDAR data: Role of selected classifiers and sensor across three spatial scales. *International Journal of Applied Earth Observation and Geoinformation* 26, 49 – 63.
- Gislason, P.O., Benediktsson, J.A., Sveinsson, J.R., 2006. Random forests for land cover classification. *Pattern Recognition Letters* 27, 294 – 300. *Pattern Recognition in Remote Sensing (PRRS 2004)*.
- Gobakken, T., Næsset, E., 2008. Assessing effects of laser point density, ground sampling intensity, and field sample plot size on biophysical stand properties derived from airborne laser scanner data. *Canadian Journal of Forest Research* 38, 1095 – 1109.
- Godone, D., Garnero, G., 2013. The role of morphometric parameters in Digital Terrain Models interpolation accuracy: a case study. *European Journal of Remote Sensing* 46, 198 – 214.

- Gonçalves, L.M., Fonte, C.C., Júlio, E.N., Caetano, M., 2009. A method to incorporate uncertainty in the classification of remote sensing images. *International Journal of Remote Sensing* 30, 5489 – 5503.
- González-Ferreiro, E., Arellano-Pérez, S., Castedo-Dorado, F., Hevia, A., Vega, J.A., Vega-Nieva, D., Álvarez-González, J.G., Ruiz-González, A.D., 2017. Modelling the vertical distribution of canopy fuel load using national forest inventory and low-density airborne laser scanning data. *PLoS ONE* 12, e0176114.
- González-Ferreiro, E., Diéguez-Aranda, U., , Miranda, D., 2012. Estimation of stand variables in *Pinus radiata* D. Don plantations using different LiDAR pulse densities. *Forestry* 85, 281 – 292.
- González-Ferreiro, E., Diéguez-Aranda, U., Barreiro-Fernández, L., Barbosa, S.B.B., Suárez, J., Bye, I.J., Miranda, D., 2013a. A mixed pixel-and region-based approach for using airborne laser scanning data for individual tree crown delineation in *Pinus radiata* D. Don plantations. *International Journal of Remote Sensing* 34, 7671 – 7690.
- González-Ferreiro, E., Miranda, D., Barreiro-Fernández, L., Buján, S., García-Gutierrez, J., Diéguez-Aranda, U., 2013b. Modelling stand biomass fractions in Galician *Eucalyptus globulus* plantations by use of different LiDAR pulse densities. *Forest Systems* 22, 510 – 525.
- Goodwin, N.R., Coops, N.C., Culvenor, D.S., 2006. Assessment of forest structure with airborne LiDAR and the effects of platform altitude. *Remote Sensing of Environment* 103, 140 – 152.
- Gould, S.B., Glenn, N.F., Sankey, T.T., McNamara, J.P., 2013. Influence of a dense, low-height shrub species on the accuracy of a lidar-derived DEM. *Photogrammetric Engineering & Remote Sensing* 79, 421 – 431.
- Gross, H., Jutzi, B., Thoennessen, U., 2008. Intensity normalization by incidence angle and range of full-waveform lidar data. *Proc. Commission IV. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37, 405 – 412.
- Guan, H., Li, J., Chapman, M., Deng, F., Ji, Z., Yang, X., 2013. Integration of orthoimagery and lidar data for object-based urban thematic mapping using random forests. *International Journal of Remote Sensing* 34, 5166 – 5186.
- Guan, H., Li, J., Yu, Y., Zhong, L., Ji, Z., 2014. DEM generation from lidar data in wooded mountain areas by cross-section-plane analysis. *International Journal of Remote Sensing* 35, 927 – 948.

- Gueudet, P., 2004. The influence of post-spacing density of DEMs derived from LiDAR on flood modeling. Thesis. Center for Research in Water Resources, University of Texas at Austin.
- Guo, B., Huang, X., Zhang, F., Sohn, G., 2015. Classification of airborne laser scanning data using JointBoost. *ISPRS Journal of Photogrammetry and Remote Sensing* 100, 71 – 83. High-Resolution Earth Imaging for Geospatial Information.
- Guo, L., Chehata, N., Mallet, C., Boukir, S., 2011. Relevance of airborne lidar and multispectral image data for urban scene classification using random forests. *ISPRS Journal of Photogrammetry and Remote Sensing* 66, 56 – 66.
- Guo, Q., Li, W., Yu, H., Alvarez, O., 2010. Effects of topographic variability and lidar sampling density on several DEM interpolation methods. *Photogrammetric Engineering & Remote Sensing* 76, 1 – 12.
- Habib, A.F., Kersting, A.P., Shaker, A., Yan, W.Y., 2011. Geometric calibration and radiometric correction of LiDAR data and their impact on the quality of derived products. *Sensors* 11, 9069 – 9097.
- Han, J., 2012. Data mining: Concepts and techniques. 3rd ed., Elsevier.
- Hansen, E., Gobakken, T., Næsset, E., 2015. Effects of pulse density on digital terrain models and canopy metrics using airborne laser scanning in a tropical rainforest. *Remote Sensing* 7, 8453 – 8468.
- Hasegawa, H., 2006. Evaluations of LiDAR reflectance amplitude sensitivity towards land cover conditions. *Bulletin of the Geographical Survey Institute* 53, 44.
- Hassan, Y., Fernández, F.J.M., Iazza, G., 2004. Diseño web centrado en el usuario: Usabilidad y arquitectura de la información. *Hipertext.net*, online.
- Haugerud, R.A., Harding, D.J., 2001. Some algorithms for virtual deforestation (VDF) of lidar topographic survey data. *International Archives of Photogrammetry and Remote Sensing* .
- Hay, G.J., Castilla, G., 2006. Object-based image analysis : Strengths , weaknesses , opportunities and threats (swot), in: *OBIA2006: The international Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*.

- Hecht, R., Meinel, G., Buchroithner, M.F., 2008. Estimation of urban green volume based on single-pulse LiDAR data. *IEEE Transactions on Geoscience and Remote Sensing* 46, 3832 – 3840.
- Hladik, C., Alber, M., 2012. Accuracy assessment and correction of a LIDAR-derived salt marsh digital elevation model. *Remote Sensing of Environment* 121, 224 – 235.
- Hodgson, M.E., Bresnahan, P., 2004. Accuracy of airborne lidar-derived elevation: empirical assessment and error budget. *Photogrammetric engineering and remote sensing* 70.
- Hodgson, M.E., Jensen, J., Raber, G., Tullis, J., Davis, B.A., Thompson, G., Schuckman, K., 2005. An evaluation of lidar-derived elevation and terrain slope in leaf-off conditions. *Photogrammetric Engineering & Remote Sensing* 71, 817 – 823.
- Höfle, B., Hollaus, M., Hagenauer, J., 2012. Urban vegetation detection using radiometrically calibrated small-footprint full-waveform airborne lidar data. *ISPRS Journal of Photogrammetry and Remote Sensing* 67, 134 – 147.
- Höfle, B., Pfeifer, N., 2007. Correction of laser scanning intensity data: Data and model-driven approaches. *ISPRS Journal of Photogrammetry and Remote Sensing* 62, 415 – 433.
- Höhle, J., Höhle, M., 2009. Accuracy assessment of digital elevation models by means of robust statistical methods. *ISPRS Journal of Photogrammetry and Remote Sensing* 64, 398 – 406.
- Hollaus, M., Wagner, W., Eberhöfer, C., Karel, W., 2006. Accuracy of large-scale canopy heights derived from LiDAR data under operational constraints in a complex alpine environment. *ISPRS Journal of Photogrammetry & Remote Sensing* 60, 323 – 338.
- Holmgren, J., Persson, Å., 2004. Identifying species of individual trees using airborne laser scanner. *Remote Sensing of Environment* 90, 415 – 423.
- Hopkinson, C., Chasmer, L., 2009. Testing LiDAR models of fractional cover across multiple forest ecozones. *Remote Sensing of Environment* 113, 275 – 288.
- Horn, B.K.P., 1981. Hill shading and the reflectance map. *Proceedings of the IEEE* 69, 14 – 47.

- Hu, H., Ding, Y., Zhu, Q., Wu, B., Lin, H., Du, Z., Zhang, Y., Zhang, Y., 2014. An adaptive surface filter for airborne laser scanning point clouds by means of regularization and bending energy. *ISPRS Journal of Photogrammetry and Remote Sensing* 92, 98 – 111.
- Hu, X., Li, X., Zhang, Y., 2013. Fast filtering of LiDAR point cloud in urban areas based on scan line segmentation and GPU acceleration. *IEEE Geoscience and Remote Sensing Letters* 10, 308 – 312.
- Hu, X., Ye, L., Pang, S., Shan, J., 2015. Semi-global filtering of airborne lidar data for fast extraction of digital terrain models. *Remote Sensing* 7, 10996 – 11015.
- Huang, M.J., Shyue, S.W., Lee, L.H., Kao, C.C., 2008. A knowledge-based approach to urban feature classification using aerial imagery with lidar data. *Photogrammetric Engineering & Remote Sensing* 74, 1473 – 1485.
- Huang, X., Zhang, L., Gong, W., 2011. Information fusion of aerial images and LIDAR data in urban areas: vector-stacking, re-classification and post-processing approaches. *International Journal of Remote Sensing* 32, 69 – 84.
- Huang, Y., Zhao, C., Yang, H., Song, X., Chen, J., Li, Z., 2017. Feature selection solution with high dimensionality and low-sample size for land cover classification in object-based image analysis. *Remote Sensing* 9, 1 – 16.
- Hui, Z., Hu, Y., Yevenyo, Y.Z., Yu, X., 2016. An improved morphological algorithm for filtering airborne LiDAR point cloud based on multi-level kriging interpolation. *Remote Sensing* 8, 35.
- Hyypä, H., Yu, X., Hyypä, J., Kaartinen, H., Kaasalainen, S., Honkavaara, E., Rönnholm, P., 2005. Factors affecting the quality of DTM generation in forested areas, in: Workshop "Laser scanning 2005", Enschede, the Netherlands. pp. 85 – 90.
- Hyypä, J., Hyypä, H., Leckie, D., Gougeon, F., Yu, X., Maltamo, M., 2008. Methods of small-footprint airborne laser scanning for extracting forest inventory data in boreal forests. *International Journal of Remote Sensing* 29, 1339 – 1366.
- Im, J., Jensen, J., Hodgson, M., 2008a. Object-based land cover classification using high-posting-density lidar data. *GIScience & Remote Sensing* 45, 209 – 228.

- Im, J., Jensen, J., Tullis, J., 2008b. Object-based change detection using correlation image analysis and image segmentation. *International Journal of Remote Sensing* 29, 399 – 423.
- Immelman, J., Scheepers, L.G.C., 2011. The effects of data reduction on LiDAR-based digital elevation models, in: *Image and Signal Processing (CISP)*, 2011 4th International Congress on, pp. 1694 – 1698.
- Ismail, Z., Khanan, M.F.A., Omar, F.Z., Rahman, M.Z.A., Mohd Salleh, M.R., 2016. Evaluating Error of LIDAR Derived dem Interpolation for Vegetation Area. *ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* , 141 – 150.
- ISO 9241-11, 1998. Ergonomic requirements for office work with visual display terminals (VDT)s - Part 11 Guidance on usability.
- Jahromi, A.B., Zoej, M.J.V., Mohammadzadeh, A., Sadeghian, S., 2011. A novel filtering algorithm for bare-earth extraction from airborne laser scanning data using an artificial neural network. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 4, 836 – 843.
- Jakubowski, M.K., Guo, Q., Kelly, M., 2013. Tradeoffs between lidar pulse density and forest measurement accuracy. *Remote Sensing of Environment* 130, 245 – 253.
- Janitza, S., Tutz, G., Boulesteix, A.L., 2016. Random forest for ordinal responses: Prediction and variable selection. *Computational Statistics & Data Analysis* 96, 57 – 73.
- Jensen, J.L., Humes, K.S., Vierling, L.A., Hudak, A.T., 2008. Discrete return lidar-based prediction of leaf area index in two conifer forests. *Remote Sensing of Environment* 112, 3947 – 3957.
- Johnston, A.N., Moskal, L.M., 2017. High-resolution habitat modeling with airborne lidar for red tree voles. *The Journal of Wildlife Management* 81, 58 – 72.
- Jović, A., Brkić, K., Bogunović, N., 2015. A review of feature selection methods with applications, in: *38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO)*, pp. 1200 – 1205.
- Julesz, B., 1962. Visual pattern discrimination. *IRE Transactions on Information Theory* 8, 84 – 92.

- Jutzi, B., Gross, H., 2010. Investigations on surface reflection models for intensity normalization in Airborne Laser Scanning (ALS) data. *Photogrammetric Engineering & Remote Sensing* 76, 1051–1060.
- Kaasalainen, S., Hyyppä, H., Kukko, A., Litkey, P., Ahokas, E., Hyyppä, J., Lehner, H., Jaakkola, A., Suomalainen, J., Akujarvi, A., 2009. Radiometric calibration of LiDAR intensity with commercially available reference targets. *Geoscience and Remote Sensing, IEEE Transactions on* 47, 588–598.
- Kampa, K., Slatton, K.C., 2004. An adaptive multiscale filter for segmenting vegetation in ALSM data, in: *Geoscience and Remote Sensing Symposium, 2004. IGARSS '04. Proceedings. 2004 IEEE International*, pp. 3837 – 3840.
- Kampouraki, M., Wood, G.A., Brewer, T.R., 2008. Opportunities and limitations of object based image analysis for detecting urban impervious and vegetated surfaces using true-colour aerial photography. Springer Berlin Heidelberg, Berlin, Heidelberg. chapter 6.2. pp. 555 – 569.
- Kandare, K., Ørka, H.O., Chan, J.C.W., Dalponte, M., 2016. Effects of forest structure and airborne laser scanning point cloud density on 3D delineation of individual tree crowns. *European Journal of Remote Sensing* 49, 337 – 359.
- Kashani, A.G., Olsen, M.J., Parrish, C.E., Wilson, N., 2015. A review of lidar radiometric processing: from Ad Hoc intensity correction to rigorous radiometric calibration. *Sensors* 15, 28099 – 28128.
- Khosravipour, A., Skidmore, A.K., Isenburg, M., Wang, T., Hussin, Y.A., 2014. Generating pit-free canopy height models from airborne lidar. *Photogrammetric Engineering & Remote Sensing* 80, 863 – 872.
- Khosravipour, A., Skidmore, A.K., Wang, T., Isenburg, M., Khoshelham, K., 2015. Effect of slope on treetop detection using a LiDAR canopy height model. *ISPRS Journal of Photogrammetry and Remote Sensing* 104, 44 – 52.
- Kilian, J., Haala, N., English, M., 1996. Capture and evaluation of airborne laser scanner data. *International Archives of Photogrammetry and Remote Sensing* 31, 383 – 388.
- Kim, H., 2015. 3D Classification of power line scene using airborne LiDAR data. Phdthesis. York University. Toronto, Ontario.
- Kim, H.B., Sohn, G., 2010. 3D classification of power-line scene from airborne laser scanning data using random forests, in: *Paparoditis, N.,*

- Pierrot-Deseilligny, M., Mallet, C., Tournaire, O. (Eds.), ISPRS Technical Commission III Symposium PCV 2010 - Photogrammetric Computer Vision and Image Analysis, Saint-Mandé, France. pp. 126 – 132.
- Kim, H.B., Sohn, G., 2013. Point-based classification of power line corridor scene using random forests. *Photogrammetric Engineering & Remote Sensing* 79, 821 – 833.
- Kobler, A., Pfeifer, N., Ogrinc, P., Todorovski, L., Oštir, K., Džeroski, S., 2007. Repetitive interpolation: a robust algorithm for DTM generation from aerial laser scanner data in forested terrain. *Remote Sensing of Environment* 108, 9 – 23.
- Koetz, B., Morsdorf, F., van der Linden, S., Curt, T., Allgöwer, B., 2008. Multi-source land cover classification for forest fire management based on imaging spectrometry and LiDAR data. *Forest Ecology and Management* 256, 263 – 271. Impacts of forest ecosystem management on greenhouse gas budgets.
- Korzeniowska, K., Lacka, M., 2011. Generating DEM from LIDAR data - comparison of available software tools. *Archives of Photogrammetry, Cartography and Remote Sensing* 22, 271 – 284.
- Kramer, H.A., Collins, B.M., Lake, F.K., Jakubowski, M.K., Stephens, S.L., Kelly, M., 2016. Estimating ladder fuels: A new approach combining field photography with LiDAR. *Remote Sensing* 8, 1 – 23.
- Kraus, K., Pfeifer, N., 1998. Determination of terrain models in wooded areas with airborne laser scanner data. *ISPRS Journal of Photogrammetry and Remote Sensing* 53, 193–203.
- Krzystek, P., 2003. Filtering of laser scanning data in forest areas using finite elements, in: *Workshop Proceedings: 3-D Reconstruction from Airborne Laser Scanner and InSAR Data*.
- Kukko, A., Kaasalainen, S., Litkey, P., 2008. Effect of incidence angle on laser scanner intensity and surface data. *Applied optics* 47, 986 – 992.
- Lee, H., Younan, N., 2003. DTM extraction of lidar returns via adaptive processing. *Geoscience and Remote Sensing, IEEE Transactions on* 41, 2063 – 2069.
- Lee, J., 1991. Comparison of existing methods for building triangular irregular network, models of terrain from grid digital elevation models. *International Journal of Geographical Information Systems* 5, 267 – 285.

- Leitold, V., Keller, M., Morton, D.C., Cook, B.D., Shimabukuro, Y.E., 2015. Airborne lidar-based estimates of tropical forest structure in complex terrain: opportunities and trade-offs for REDD+. *Carbon Balance and Management* 10, 1 – 12.
- Li, N., Liu, C., Pfeifer, N., J.F., Y., Liao, Z., Zhou, Y., 2016. Tensor modeling based for airborne LiDAR data classification, in: *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 283 – 287.
- Li, N., Pfeifer, N., Liu, C., 2017. Tensor-based sparse representation classification for urban airborne LiDAR points. *Remote Sensing* 9, 1 – 22.
- Li, X., Meng, Q., Gu, X., Jancso, T., Yu, T., Wang, K., Mavromatis, S., 2013. A hybrid method combining pixel-based and object-oriented methods and its application in hungary using chinese hj-1 satellite images. *International Journal of Remote Sensing* 34, 4655 – 4668.
- Li, Y., 2013. Filtering airborne LiDAR data by an improved morphological method based on multi-gradient analysis, in: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 191 – 194.
- Li, Y., Yong, B., Wu, H., An, R., Xu, H., 2014. An improved Top-Hat filter with sloped brim for extracting ground points from airborne lidar point clouds. *Remote Sensing* 6, 12885.
- Li, Z., Zhu, C., Gold, C., 2005. *Digital Terrain Modeling: Principles and Methodology*. CRC Press.
- Liaw, A., Wiener, M., 2002. Classification and regression by randomforest. *R News* 2/3, 18 – 22.
- Lim, K., Hopkinson, C., Treitz, P., 2008. Examining the effects of sampling point densities on laser canopy height and density metrics. *The forestry chronicle* 84, 876 – 885.
- Lin, X., Zhang, J., 2014. Segmentation-based filtering of airborne LiDAR point clouds by progressive densification of terrain segments. *Remote Sensing* 6, 1294.
- Liu, C., Frazier, P., Kumar, L., 2007. Comparative assessment of the measures of thematic classification accuracy. *Remote Sensing of Environment* 107, 606 – 616.

- Liu, D., Xia, F., 2010. Assessing object-based classification: advantages and limitations. *Remote Sensing Letters* 1, 187–194.
- Liu, X., 2008. Airborne LiDAR for DEM generation: some critical issues. *Progress in Physical Geography* 32, 31 – 49.
- Liu, X., Hu, H., Hu, P., 2015. The "M" in digital elevation models. *Cartography and Geographic Information Science* 42, 235 – 243.
- Liu, X., Zhang, Z., 2008. Lidar data reduction for efficient and high quality DEM generation. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 37, 173–178.
- Lodha, S.K., Kreps, E.J., Helmbold, D.P., Fitzpatrick, D., 2006. Aerial LiDAR data classification using support vector machines (SVM), in: *Third International Symposium on 3D Data Processing, Visualization and Transmission*, pp. 567 – 574.
- Lohmann, P., Koch, A., Schaeffer, M., 2000. Approaches to the filtering of laser scanner data. *International Archives of Photogrammetry and Remote Sensing* 33, 540 – 547.
- Lovell, J., Jupp, D., Newnham, G., Coops, N., Culvenor, D., 2005. Simulation study for finding optimal lidar acquisition parameters for forest height retrieval. *Forest Ecology and Management* 214, 398 – 412.
- Lu, D., Weng, Q., 2007. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing* 28, 823–870.
- Lu, W.L., Little, J.J., Sheffer, A., Fu, H., 2008. Deforestation: Extracting 3d bare-earth surface from airborne LiDAR data, in: *Canadian Conference on Computer and Robot Vision, 2008. CRV '08, IEEE*. pp. 203 – 210.
- Lu, W.L., Murphy, K.P., Little, J.J., Sheffer, A., Fu, H., 2009. A hybrid conditional random field for estimating the underlying ground surface from airborne LiDAR data. *IEEE Transactions on Geoscience and Remote Sensing* 47, 2913 – 2922.
- Luzum, B., Starek, M., Slatton, K., 2004. Normalizing ALSM intensities. *Technical Report. Geosensing Engineering and Mapping, University of Florida, USA*.
- MacFaden, S.W., O'Neil-Dunne, J.P., Royar, A.R., Lu, J.W., Rundle, A.G., 2012. High-resolution tree canopy mapping for new york city using LIDAR

- and object-based image analysis. *Journal of Applied Remote Sensing* 6, 063567/1–063567/23.
- Magnussen, S., Næsset, E., Gobakken, T., 2010. Reliability of LiDAR derived predictors of forest inventory attributes: A case study with Norway spruce. *Remote Sensing of Environment* 114, 700 – 712.
- Magnusson, M., Fransson, J., Holmgren, J., 2007. Effects on estimation accuracy of forest variables using different pulse density of laser data. *Forest science* 53, 619 – 626.
- Maguya, A.S., Junttila, V., Kauranne, T., 2013. Adaptive algorithm for large scale dtm interpolation from lidar data for forestry applications in steep forested terrain. *ISPRS Journal of Photogrammetry and Remote Sensing* 85, 74 – 83.
- Malinverni, E.S., Tassetti, A.N., Mancini, A., Zingaretti, P., Frontoni, E., Bernardini, A., 2011. Hybrid object-based approach for land use/land cover mapping using high spatial resolution imagery. *International Journal of Geographical Information Science* 25, 1025 – 1043.
- Man, Q., Dong, P., Guo, H., 2015. Pixel- and feature-level fusion of hyperspectral and lidar data for urban land-use classification. *International Journal of Remote Sensing* 36, 1618 – 1644.
- Manuri, S., Andersen, H.E., McGaughey, R.J., Brack, C., 2017. Assessing the influence of return density on estimation of lidar-based aboveground biomass in tropical peat swamp forests of kalimantan, indonesia. *International Journal of Applied Earth Observation and Geoinformation* 56, 24 – 35.
- Martinuzzi, S., Vierling, L.A., Gould, W.A., Falkowski, M.J., Evans, J.S., Hudak, A.T., Vierling, K.T., 2009. Mapping snags and understory shrubs for a lidar-based assessment of wildlife habitat suitability. *Remote Sensing of Environment* 113, 2533 – 2546.
- Matikainen, L., Karila, K., Hyyppä, J., Litkey, P., Puttonen, E., Ahokas, E., 2017. Object-based analysis of multispectral airborne laser scanner data for land cover classification and map updating. *ISPRS Journal of Photogrammetry and Remote Sensing* 128, 298 – 313.
- Matinfar, H., Sarmadian, F., Panah, S.A., Heck, R., 2007. Comparisons of object-oriented and pixel-based classification of land use/land cover types based on Landsat7, Etm+ spectral bands (case study: arid region of Iran). *American-Eurasian Journal of Agricultural & Environmental Sciences* 2, 448 – 456.

- Maune, D.F., 2011. Digital Elevation Model (DEM) Whitepaper NRCS High Resolution Elevation Data. dewberry ed. USDA Natural Resources Conservation Service. 501 West Felix Street, FWFC Building 23, Fort Worth, Texas 76115.
- Maxwell, A., Warner, T., Strager, M., Conley, J., Sharp, A., 2015. Assessing machine-learning algorithms and image- and lidar-derived variables for GEOBIA classification of mining and mine reclamation. *International Journal of Remote Sensing* 36, 954 – 978.
- Mazzarini, F., Pareschi, M., Favalli, M., Isola, I., Tarquini, S., Boschi, E., 2007. Lava flow identification and ageing by means of LiDAR intensity: Mount etna case. *Journal of Geophysical Research-Solid Earth* 112, 1 – 43.
- McGaughey, R.J., 2010. Fusion/ldv: Software for lidar data analysis and visualization.
- McGaughey, R.J., 2018. Fusion/ldv: Software for lidar data analysis and visualization. version 3.70.
- McRoberts, R., Tomppo, E., 2007. Remote sensing support for national forest inventories. *Remote Sensing of Environment* 110, 412 – 419.
- Meng, X., Currit, N., Zhao, K., 2010. Ground filtering algorithms for airborne LiDAR data: A review of critical issues. *Remote Sensing* 2, 833 – 860.
- Meng, X., Wang, L., Silván-Cárdenas, J.L., Currit, N., 2009. A multi-directional ground filtering algorithm for airborne LIDAR. *ISPRS Journal of Photogrammetry and Remote Sensing* 64, 117 – 124.
- Mesas-Carrascosa, F.J., Castillejo-González, I.L., de la Orden, M.S., Porras, A.G.F., 2012. Combining lidar intensity with aerial camera data to discriminate agricultural land uses. *Computers and Electronics in Agriculture* 84, 36 – 46.
- Miller, C., Laflamme, R., 1958. The digital tappings: theory and applications. *Photogrammetric Engineering* 24, 433 – 442.
- Ming, Y., Chen, C.J., 2013. A robust filtering algorithm of LiDAR data for DTM extraction, in: *Advanced Materials Research, Trans Tech Publ.* pp. 639 – 642.
- Möller, M., Lymburner, L., Volk, M., 2007. The comparison index: A tool for assessing the accuracy of image segmentation. *International journal of applied earth observation and geoinformation* 9, 311–321.

- Mongus, D., Žalik, B., 2012. Parameter-free ground filtering of LiDAR data for automatic DTM generation. *ISPRS Journal of Photogrammetry and Remote Sensing* 67, 1 – 12.
- Mongus, D., Žalik, B., 2014. Computationally efficient method for the generation of a digital terrain model from airborne LiDAR data using connected operators. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 7, 340 – 351.
- Montealegre, A., Lamelas, M., Riva, J.D.L., 2015a. A comparison of Open-Source LiDAR filtering algorithms in a Mediterranean forest environment. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 8, 4072 – 4085.
- Montealegre, A.L., Lamelas, M.T., Riva, J.d.l., 2015b. Interpolation routines assessment in ALS-Derived digital elevation models for forestry applications. *Remote Sensing* 7, 8631 – 8654.
- Moreira, J., 2001. La cartografía hoy: evolución o revolución?. las nuevas tecnologías y los cambios en la representación del territorio, in: *Actas del Congreso Año mil, año dos mil. Dos milenios en la historia de España*, Sociedad estatal España nuevo milenio. pp. 433 – 451.
- Myint, S.W., Gober, P., Brazel, A., Grossman-Clarke, S., Weng, Q., 2011. Per-pixel vs. object-based classification of urban land cover extraction using high spatial resolution imagery. *Remote Sensing of Environment* 115, 1145 – 1161.
- Næsset, E., 2009. Effects of different sensors, flying altitudes, and pulse repetition frequencies on forest canopy metrics and biophysical stand properties derived from small-footprint airborne laser data. *Remote Sensing of Environment* 113, 148 – 159.
- Nardinocchi, C., Forlani, G., Zingaretti, P., 2003. Classification and filtering of laser data. *International Archives of Photogrammetry and Remote Sensing* 34, 9 – 36.
- Navulur, K. (Ed.), 2006. *Multispectral image analysis using the object-oriented paradigm*. CRC Press.
- Niemeyer, J., Rottensteiner, F., Soergel, U., 2014. Contextual classification of lidar data and building object detection in urban areas. *ISPRS Journal of Photogrammetry and Remote Sensing* 87, 152 – 165.

- Nychka, D., Haaland, P., O'Connell, M., Ellner, S.P., 1998. Case studies in environmental statistics. Springer-Verlag New York, Inc.. volume 132. chapter FUNFITS: data analysis and statistical tools for estimating functions. pp. 159 – 179.
- O'Connell, J., Bradter, U., Benton, T.G., 2015. Wide-area mapping of small-scale features in agricultural landscapes using airborne remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 109, 165 – 177.
- Olofsson, P., Foody, G.M., Herold, M., Stehman, S.V., Woodcock, C.E., Wulder, M.A., 2014. Good practices for estimating area and assessing accuracy of land change. *Remote Sensing of Environment* 148, 42 – 57.
- Pacifici, F., Del Frate, F., Solimini, C., Emery, W., 2007. An innovative neural-net method to detect temporal changes in high-resolution optical satellite imagery. *IEEE Transactions on Geoscience and Remote Sensing* 45, 2940 – 2952.
- Persson, A., Holmgren, J., Soderman, U., 2002. Detecting and measuring individual trees using an airborne laser scanner. *Photogrammetric Engineering and Remote Sensing* 68, 925 – 932.
- Pfeifer, N., Kostli, A., Kraus, K., 1998. Interpolation and filtering of laser scanner data - implementation and first results, in: *International Archives of Photogrammetry and Remote Sensing*, pp. 31 – 36.
- Pfeifer, N., Mandlbürger, G., 2008. LiDAR data filtering and DTM generation. CRC press. chapter 11. pp. 307 – 333.
- Pfeifer, N., Stadler, P., Briese, C., 2001. Derivation of digital terrain models in the SCOP++ environment, in: *OEEPE Workshop on Airborne Laserscanning and Interferometric SAR for Digital Elevation Model*, p. (on CDROM).
- Pingel, T.J., Clarke, K.C., McBride, W.A., 2013. An improved simple morphological filter for the terrain classification of airborne LIDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing* 77, 21 – 30.
- Pirotti, F., Tarolli, P., 2010. Suitability of LiDAR point density and derived landform curvature maps for channel network extraction. *Hydrological Processes* 24, 1187 – 1197.
- Polat, N., Uysal, M., Toprak, A., 2015. An investigation of DEM generation process based on lidar data filtering, decimation, and interpolation methods for an urban area. *Measurement* 75, 50 – 56.

- Pontius, R.G., Millones, M., 2011. Death to kappa: birth of quantity disagreement and allocation disagreement for accuracy assessment. *International Journal of Remote Sensing* 32, 4407 – 4429.
- Pu, R., Landry, S., Yu, Q., 2011. Object-based urban detailed land cover classification with high spatial resolution IKONOS imagery. *International Journal of Remote Sensing* 32, 3285 – 3308.
- Puetz, A., Olsen, R., Anderson, B., 2009. Effects of LiDAR point density on bare earth extraction and DEM creation, in: Turner, M.D., Kamerman, G.W. (Eds.), *Proc. SPIE 7323, Laser Radar Technology and Applications XIV*, Orlando, Florida, USA.
- Qin, H., Wang, C., Xi, X., Tian, J., Zhou, G., 2017. Simulating the effects of the airborne lidar scanning angle, flying altitude and pulse density for forest foliage profile retrieval. *Applied Sciences* 7, 1 – 18.
- Quinlan, J.R., 1993. *C4.5: programs for machine learning*. Morgan Kaufmann Publishers Inc.
- R Core Team, 2015. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing. Vienna, Austria.
- R Development Core Team, 2004. *The R Reference Manual Base Package. volume 2*. Network Theory Limited.
- R Development Core Team, 2010. *R: A Language and Environment for Statistical Computing*.
- Raber, G., Jensen, J., Hodgson, M., Tullis, J., Davis, B., Berglund, J., 2007. Impact of LiDAR nominal post-spacing on DEM accuracy and flood zone delineation. *Photogrammetric Engineering and Remote Sensing* 73, 793 – 804.
- Rayburg, S., Thoms, M., Neave, M., 2009. A comparison of digital elevation models generated from different data sources. *Geomorphology* 106, 261 – 270.
- Renslow, M., 2012. *Manual of Airborne Topographic Lidar*. American Society for Photogrammetry and Remote Sensing.
- Reutebuch, S.E., McGaughey, R.J., Andersen, H.E., Carson, W.W., 2003. Accuracy of a high-resolution lidar terrain model under a conifer forest canopy. *Canadian Journal Remote Sensing* 29, 527 – 535.

- Riaño, D., Meier, E., Allgöwer, B., Chuvieco, E., Ustin, S.L., 2003. Modeling airborne laser scanning data for the spatial generation of critical forest parameters in fire behavior modeling. *Remote Sensing of Environment* , 177 – 186.
- Roberts, R., 1957. Using new methods in high location. *Photogrammetric Engineering* 23, 563 – 569.
- Robinson, A.H., Morrison, J.L., Muehrcke, P.C., Kimerling, A.J., Guptill, S.C., 1995. *Elements of Cartography*. 6 edition ed., John Wiley & Sons, Inc.
- Rodriguez-Galiano, V., Ghimire, B., Rogan, J., Chica-Olmo, M., Rigol-Sanchez, J., 2012. An assessment of the effectiveness of a random forest classifier for land-cover classification. *ISPRS Journal of Photogrammetry and Remote Sensing* 67, 93 – 104.
- Roggero, M., 2001. Airborne laser scanning: clustering in raw data, in: *International Archives of Photogrammetry and Remote Sensing*, pp. 227 – 232.
- Ruiz, L.A., Hermosilla, T., Mauro, F., Godino, M., 2014. Analysis of the influence of plot size and LiDAR density on forest structure attribute estimates. *Forests* 5, 936 – 951.
- Ruiz, L.Á., Recio, J.A., Crespo-Peremarch, P., Sapena, M., 2018. An object-based approach for mapping forest structural types based on low-density LiDAR and multispectral imagery. *Geocarto International* 33, 443 – 457.
- Rutzinger, M., Höfle, B., Hollaus, M., Pfeifer, N., 2008. Object-based point cloud analysis of full-waveform airborne laser scanning data for urban vegetation classification. *sensors* 8, 4505 – 4528.
- Rwanga, S.S., Ndambuki, J.M., 2017. Accuracy assessment of land use/land cover classification using remote sensing and GIS. *International Journal of Geosciences* 8, 611 – 622.
- Sailer, R., Rutzinger, M., Rieg, L., Wichmann, V., 2014. Digital elevation models derived from airborne laser scanning point clouds: appropriate spatial resolutions for multi-temporal characterization and quantification of geomorphological processes. *Earth Surface Processes and Landforms* 39, 272 – 284.
- Salah, M., 2014. Combining pixel-based and object-oriented support vector machines using Bayesian probability theory. *ISPRS Annals of Photogrammetry, Remote Sensing & Spatial Information Sciences* II-7, 67 – 74.

- Salk, C., Fritz, S., See, L., Dresel, C., McCallum, I., 2018. An exploration of some pitfalls of thematic map assessment using the new map tools resource. *Remote Sensing* 10, 1 – 14.
- Salleh, M.R.M., Ismail, Z., Rahman, M.Z.A., 2015. Accuracy assessment of lidar-derived digital terrain model (dtm) with different slope and canopy cover in tropical forest region. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 2, 183 – 189.
- Samadzadegan, F., Bigdeli, B., Ramzi, P., 2010. A multiple classifier system for classification of LIDAR remote sensing data using multi-class SVM, in: El Gayar, N., Kittler, J., Roli, F. (Eds.), *Multiple Classifier Systems*, Springer Berlin Heidelberg, Berlin, Heidelberg. pp. 254 – 263.
- Sanii, S., 2008. Assessing the effect of point density and terrain complexity on the quality of LiDAR-derived DEMs in multiple resolutions. Master's thesis. Department of Geography, University of Calgary.
- Sasaki, T., Imanishi, J., Ioki, K., Morimoto, Y., Kitada, K., 2012. Object-based classification of land cover and tree species by integrating airborne LiDAR and high spatial resolution imagery data. *Landscape and Ecological Engineering* 8, 157 – 171.
- Schickler, W., Thorpe, A., 2001. Surface estimation based on LIDAR, in: *Proceedings of the ASPRS Annual Conference*. St. Louis, Missouri.
- Schiewe, X., 2001. Ein regionen-basiertes Verfahren zur Extraktion der Gelandoberfläche aus Digitalen Oberflächen-Modellen. *Photogrammetrie, Fernerkundung, Geoinformation* 2, 81 – 90.
- Seo, S., O'Hara, C.G., 2008. Parametric investigation of the performance of lidar filters using different surface contexts. *Photogrammetric Engineering & Remote Sensing* 74, 343 – 362.
- Shan, J., Aparajithan, S., 2005. Urban DEM generation from raw LiDAR data. *Photogrammetric Engineering & Remote Sensing* 71, 217 – 226.
- Shao, Y.C., Chen, L.C., 2008. Automated searching of ground points from airborne lidar data using a climbing and sliding method. *Photogrammetric Engineering & Remote Sensing* 74, 625 – 635.
- Sheeren, D., Bastin, G.N., Ouin, A., Ladet, S., Balent, G., Lacombe, J.P., 2009. Discriminating small wooded elements in rural landscape from aerial photography: a hybrid pixel/object-based analysis approach. *International Journal of Remote Sensing* 30, 4979–4990.

- Sherba, J., Blesius, L., Davis, J., 2014. Object-based classification of abandoned logging roads under heavy canopy using LiDAR. *remote sensing* 6, 4043 – 4060.
- Sibona, E., Vitali, A., Meloni, F., Caffo, L., Dotta, A., Lingua, E., Motta, R., Garbarino, M., 2017. Direct measurement of tree height provides different results on the assessment of lidar accuracy. *Forest* 8, 1 – 12.
- Silvan-Cardenas, J., Wang, L., 2006. A multi-resolution approach for filtering LiDAR altimetry data. *ISPRS Journal of Photogrammetry and Remote Sensing* 61, 11 – 22.
- Singh, K.K., Chen, G., McCarter, J.B., Meentemeyer, R.K., 2015. Effects of LiDAR point density and landscape context on estimates of urban forest biomass. *ISPRS Journal of Photogrammetry and Remote Sensing* 101, 310 – 322.
- Singh, K.K., Vogler, J.B., Meentemeyer, R.K., 2010. Estimation of land-use in an urbanized landscape using lidar intensity data: a regional scale approach, in: *Geospatial Data and Geovisualization: Environment, Security, and Society*. Orlando, Florida.
- Sithole, G., 2001. Filtering of laser altimetry data using a slope adaptive filter. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34, 203 – 210.
- Sithole, G., 2002. Filtering strategy: Working towards reliability, in: *ISPRS Commission III, Symposium 2002 September 9 - 13, 2002*, pp. 330 – 335.
- Sithole, G., 2005. Segmentation and Classification of Airborne Laser Scanner data. Phdthesis. Technische Universiteit Delft.
- Sithole, G., Vosselman, G., 2004. Experimental comparison of filter algorithms for bare-earth extraction from airborne laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing* 59, 85 – 101.
- Smith, S.L., Holland, D.A., Longley, P.A., 2005. Quantifying interpolation errors in urban airborne laser scanning models. *Geographical Analysis* 37, 200 – 224.
- Sohn, G., Dowman, I., 2002. Terrain surface reconstruction by the use of tetrahedron model with the MDL criterion, in: *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, pp. 336 – 344.

- Sohn, G., Dowman, I., 2008. A model-based approach for reconstructing a terrain surface from airborne LiDAR data. *The Photogrammetric Record* 23, 170 – 193.
- Solberg, S., Hill, R., Rosette, J., Suárez, J., 2008. Comparing discrete echoes counts and intensity sums from als for estimating forest LAI and gap fraction., in: *Proceedings of SilviLaser 2008, 8th international conference on LiDAR applications in forest assessment and inventory*, Heriot-Watt University, Edinburgh, UK, 17-19 September, 2008., SilviLaser 2008 Organizing Committee. pp. 247 – 256.
- Song, J., Han, S., Yuand, K., Kim, Y., 2002. Assessing the possibility of land-cover classification using LiDAR intensity data. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34, 259 – 262.
- Spaete, L.P., Glenn, N.F., Derryberry, D.R., Sankey, T.T., Mitchell, J.J., Hardegree, S.P., 2011. Vegetation and slope effects on accuracy of a LiDAR-derived DEM in the sagebrush steppe. *Remote Sensing Letters* 2, 317 – 326.
- Stereńczak, K., Zasada, M., Brach, M., 2013. The accuracy assessment of dtm generated from lidar data for forest area - a case study for scots pine stands in poland. *Baltic Forestry* 19, 252 – 262.
- Strobl, C., Boulesteix, A.L., Zeileis, A., Hothorn, T., 2007. Bias in random forest variable importance measures: Illustrations, sources and a solution. *BMC Bioinformatics* 8, 25.
- Strunk, J., Temesgen, H., Andersen, H.E., Flewelling, J.P., Madsen, L., 2012. Effects of lidar pulse density and sample size on a model-assisted approach to estimate forest inventory variables. *Canadian Journal of Remote Sensing* 38, 644 – 654.
- Sturari, M., Frontoni, E., Pierdicca, R., Mancini, A., Malinverni, E.S., Tasseti, A.N., Zingaretti, P., 2017. Integrating elevation data and multispectral high-resolution images for an improved hybrid land use/land cover mapping. *European Journal of Remote Sensing* 50, 1 – 17.
- Su, J., Bork, E., 2006. Influence of vegetation, slope, and lidar sampling angle on DEM accuracy. *Photogrammetric Engineering & Remote Sensing* 72, 1265 – 1274.
- Su, W., Sun, Z., Zhong, R., Huang, J., Li, M., Zhu, J., Zhang, K., Wu, H., Zhu, D., 2015. A new hierarchical moving curve-fitting algorithm for filtering

- lidar data for automatic DTM generation. *International Journal of Remote Sensing* 36, 3616 – 3635.
- Su, Y., Guo, Q., Fry, D.L., Collins, B.M., Kelly, M., Flanagan, J.P., Battles, J.J., 2016. A vegetation mapping strategy for conifer forests by combining airborne lidar data and aerial imagery. *Canadian Journal of Remote Sensing* 42, 1 – 15.
- Sun, W., Wang, H., Zhao, X., 2017. A simplification method for grid-based DEM using topological hierarchies. *Survey Review* , 1 – 14.
- Susaki, J., 2012. Adaptive slope filtering of airborne LiDAR data in urban areas for digital terrain model (DTM) generation. *Remote Sensing* 4, 1804 – 1819.
- Takahashi, T., Awaya, Y., Hirata, Y. and Furuya, N., Sakai, T., Sakai, A., 2008. Effects of flight altitude on LiDAR-derived tree heights in mountainous forests with poor laser penetration rates. *Photogrammetric Journal of Finland* 21, 86 – 96.
- Takahashi, T., Awaya, Y., Hirata, Y., Furuya, N., Sakai, T., Sakai, A., 2010. Stand volume estimation by combining low laser-sampling density LiDAR data with QuickBird panchromatic imagery in closed-canopy Japanese cedar (*Cryptomeria japonica*) plantations. *International Journal of Remote Sensing* 31, 1281 – 1301.
- Tang, J., Alelyani, S., Liu, H., 2014. *Data Classification: Algorithms and Applications*. CRC Press. chapter 2. *Feature Selection for Classification: A Review*. pp. 37 – 86.
- Tatem, A., Lewis, H., Atkinson, P., Nixon, M., 2001. Super-resolution mapping of urban scenes from IKONOS imagery using a Hopfield neural network, in: *Geoscience and Remote Sensing Symposium, 2001. IGARSS'01. IEEE 2001 International*, IEEE. pp. 3203 – 3205.
- Teo, T.A., Huang, C.H., 2016. Object-based land cover classification using airborne LiDAR and different spectral images. *Terrestrial, Atmospheric and Oceanic Sciences* 27, 491 – 504.
- Teo, T.A., Wu, H.M., 2017. Analysis of land cover classification using multi-wavelength LiDAR system. *Applied Sciences* 7, 1 – 20.
- Therneau, T., Atkinson, B., Ripley, B., 2017. *rpart: Recursive Partitioning and Regression Trees*. R package version 4.1-11.

- Tian, J., Chen, D., 2007. Optimization in multi-scale segmentation of high-resolution satellite images for artificial feature recognition. *International Journal of Remote Sensing* 28, 4625 – 4644.
- Tobler, W.R., 1970. A computer movie simulating urban growth in the detroit region. *Economic Geography* 46, 234 – 240.
- Tomljenovic, I., Rousell, A., 2014. Influence of point cloud density on the results of automated object-based building extraction from ALS data, in: Huerta, J., Schade, S., Granell, C. (Eds.), *Connecting a Digital Europe through Location and Place*, Springer International Publishing.
- Tóvári, D., Pfeifer, N., 2005. Segmentation based robust interpolation - a new approach to laser data filtering, in: *ISPRS WG III/3, III/4, V/3 Workshop "Laser scanning 2005"*, Enschede, the Netherlands. pp. 79 – 84.
- Treitz, P., Lim, K., Woods, M., Pitt, D., Nesbitt, D., Etheridge, D., 2012. LiDAR sampling density for forest resource inventories in Ontario, Canada. *Remote Sensing* 4, 830 – 848.
- Triglav-Čekada, M., Crosilla, F., Kosmatin-Fras, M., 2009. A simplified analytical model for a-priori lidar point-positioning error estimation and a review of lidar error sources. *Photogrammetric Engineering & Remote Sensing* 75, 1425 – 1439.
- Ullrich, A., Hollaus, M., Briese, C., Doneus, W.W., Mücke, W., 2007. Improvements in DTM generation by using full-waveform airborne laser scanning data, in: Moscow, R. (Ed.), *7th International Conference on "Laser Scanning and Digital Aerial Photography. Today and Tomorrow"*, pp. 1 – 9.
- Van de Woestyne, I., Jordan, M., Moons, T., Cord, M., 2004. A software system for efficient DEM segmentation and DTM estimation in complex urban areas, in: *Proceedings of International Spatial of Photogrametry and Remote Sensing, Istanbul*. pp. 134 – 139.
- Varghese, N., Verghese, V., Gayathri, P., Jaisankar, N., 2012. A survey of dimensionality reduction and classification methods. *International Journal of Computer Science & Engineering Survey* 3, 45 – 54.
- Čekada, M.T., Crosilla, F., Fras, M.K., 2010. Theoretical LiDAR point density for topographic mapping in the largest scales. *Geodetski Vestnik* 54, 403 – 416.
- Véga, C., Durrieu, S., Morel, J., Allouis, T., 2012. A sequential iterative dual-filter for lidar terrain modeling optimized for complex forested environments. *Computers & Geosciences* 44, 31 – 41.

- Vogels, M., de Jong, S., Sterk, G., Addink, E., 2017. Agricultural cropland mapping using black-and-white aerial photography, object-based image analysis and Random Forests. *International Journal of Applied Earth Observation and Geoinformation* 54, 114 – 123.
- Von Hansen, W., Vögtle, T., 1999. Extraktion der Geländeoberfläche aus flugzeuggetragenen Laserscanner-Aufnahmen. *Photogrammetrie, Fernerkundung, Geoinformation* 4, 229 – 236.
- Vosselman, G., 2000. Slope based filtering of laser altimetry data. *International Archives of Photogrammetry and Remote Sensing* 33, 935 – 942.
- Vosselman, G., 2003. ISPRS test on extracting DEMs from point clouds: A comparison of existing automatic filters. Technical Report. ISPRS, Commission III, Working Group 3.
- Wack, R., Wimmer, A., 2002. Digital terrain models from airborne laserscanner data-a grid based approach, in: *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences*, pp. 293 – 296.
- Wang, C.K., Tseng, Y.H., 2010. DEM generation from airborne lidar data by an adaptive dual directional slope filter, in: Wagner, W., Székely, B. (Eds.), *ISPRS TC VII Symposium - 100 Years ISPR*, *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*. pp. 628 – 632.
- Wang, C.K., Tseng, Y.H., Chu, H.J., 2014. Airborne dual-wavelength LiDAR data for classifying land cover. *Remote Sensing* 6, 700 – 715.
- Wang, M., Tseng, Y.H., 2004. LiDAR data segmentation and classification based on octree structure. *International Archives of Photogrammetry and Remote Sensing* 35 (Part B3), 5.
- Watt, M.S., Adams, T., Aracil, S.G., Marshall, H., Watt, P., 2013. The influence of LiDAR pulse density and plot size on the accuracy of new zealand plantation stand volume equations. *New Zealand Journal of Forestry Science* 43, 1 – 10.
- Watt, M.S., Meredith, A., Watt, P., Gunn, A., 2014. The influence of LiDAR pulse density on the precision of inventory metrics in young unthinned douglas-fir stands during initial and subsequent LiDAR acquisitions. *New Zealand Journal of Forestry Science* 44, 18.
- Weng, Q., 2010. *Remote sensing and GIS integration: theories, methods and applications*. The McGraw-Hill Companies, Inc.

- Weng, Q., 2011. Advances in environmental remote sensing: sensors, algorithms, and applications. CRC Press.
- Wiedemann, C., 2003. External evaluation of road networks. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 34, 93 – 98.
- Wilkes, P., 2016. Assessment of forest canopy vertical structure with multi-scale remote sensing: from the plot to the large area. Ph.D. thesis. Faculty of geo-information science and earth observation, University of Twente.
- Wu, H., Li, Z.L., 2009. Scale issues in remote sensing: A review on analysis, processing and modeling. *sensors* 9, 1768 – 1793.
- Wu, S.S., Qiu, X., Utery, E.L., Wang, L., 2009. Using geometrical, textural, and contextual information of land parcels for classification of detailed urban land use. *Annals of the Association of American Geographers* 99, 76 – 98.
- Wu, W., Fan, Y., Wang, Z., Liu, H., 2008. Assessing effects of digital elevation model resolutions on soil-landscape correlations in a hilly area. *Agriculture, Ecosystems & Environment* 126, 209 – 216.
- Wu, Z., Dye, D., Stoker, J., Vogel, J., Velasco, M., Middleton, B., 2016. Evaluating lidar point densities for effective estimation of aboveground biomass. *International Journal of Advanced Remote Sensing and GIS* 5, 1483 – 1499.
- Wurm, M., Taubenböck, H., Schardt, M., Esch, T., Dech, S., 2011. Object-based image information fusion using multisensor earth observation data over urban areas. *International Journal of Image and Data Fusion* 2, 121 – 147.
- Xiong, J., Fang, Y., Jin, B., Zhao, Z., 2012. Automated dtm generation in urban areas with airborne lidar data, in: 2012 4th International Conference on Intelligent Human-Machine Systems and Cybernetics, pp. 181 – 184.
- Yan, M., Blaschke, T., Liu, Y., Wu, L., 2012. An object-based analysis filtering algorithm for airborne laser scanning. *International Journal of Remote Sensing* 33, 7099 – 7116.
- Yan, W.Y., 2012. Radiometric correction and normalization of airborne lidar intensity data for land cover classification. Phd thesis. Ryerson University.
- Yan, W.Y., Shaker, A., 2014. Radiometric correction and normalization of airborne LiDAR intensity data for improving land-cover classification. *IEEE Transactions on Geoscience and Remote Sensing* 52, 7658 – 7673.

- Yan, W.Y., Shaker, A., El-Ashmawy, N., 2015. Urban land cover classification using airborne LiDAR data: A review. *Remote Sensing of Environment* 158, 295 – 310.
- Yao, W., Wei, Y., 2013. Detection of 3D individual trees in urban areas by combining airborne lidar data and imagery. *IEEE Geoscience and Remote Sensing Letters* 10, 1355 – 1359.
- Yilmaz, H.M., 2007. The effect of interpolation methods in surface definition: an experimental study. *Earth Surface Processes and Landforms* 32, 1346 – 1361.
- Yilmaz, M., Uysal, M., 2016. Comparison of data reduction algorithms for LiDAR-derived digital terrain model generalisation. *Area* 48, 521 – 532.
- Yoon, J., Shin, J., Lee, K., 2008. Land cover characteristics of airborne LiDAR intensity data: A case study. *Geoscience and Remote Sensing Letters, IEEE* 5, 801 – 805.
- Yu, X., Hyypä, J., Hyypä, H., Maltamo, M., 2004. Effects of flight altitude on tree height estimation using airborne laser scanning. *International Archives of Photogrammetry Remote Sensing and Spatial Information Sciences* 36, 96 – 101.
- Yuan, F., Zhang, J., Zhang, L., Gao, J., 2009. DEM generation from airborne LIDAR data. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* 38 (7/C4), 308 – 312.
- Yunfei, B., Guoping, L., Chunxiang, C., Xiaowen, L., Hao, Z., Qisheng, H., Linyan, B., Chaoyi, C., 2008. Classification of LIDAR point cloud and generation of DTM from LIDAR height and intensity data in forested area. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences* , 313 – 318.
- Zahidi, I., Yusuf, B., Hamedianfar, A., Shafri, H.Z.M., Mohamed, T.A., 2015. Object-based classification of QuickBird image and low point density lidar for tropical trees and shrubs mapping. *European Journal of Remote Sensing* 48, 423 – 446.
- Zehtabian, A., Ghassemian, H., 2017. An adaptive framework for spectral-spatial classification based on a combination of pixel-based and object-based scenarios. *Earth Science Informatics* 10, 357 – 368.
- Zhang, J., Lin, X., 2013. Filtering airborne LiDAR data by embedding smoothness-constrained segmentation in progressive TIN densification. *ISPRS Journal of Photogrammetry and Remote Sensing* 81, 44 – 59.

- Zhang, K., Chen, S.C., Whitman, D., Shyu, M.L., Yan, J., Zhang, C., 2003. A progressive morphological filter for removing nonground measurements from airborne LIDAR data. *IEEE Transactions on Geoscience and Remote Sensing* 41, 872 – 882.
- Zhang, K., Whitman, D., 2005. Comparison of three algorithms for filtering airborne lidar data. *Photogrammetric Engineering & Remote Sensing* 71, 313 – 324.
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., Yan, G., 2016. An easy-to-use airborne LiDAR data filtering method based on cloth simulation. *Remote Sensing* 8, 501.
- Zhang, Y., Guindon, B., 2009. Multi-resolution integration of land cover for sub-pixel estimation of urban impervious surface and forest cover. *International Journal of Digital Earth* 2, 89 – 108.
- Zhao, X., Guo, Q., Su, Y., Xue, B., 2016. Improved progressive TIN densification filtering algorithm for airborne LiDAR data in forested areas. *ISPRS Journal of Photogrammetry and Remote Sensing* 117, 79 – 91.
- Zhao, Z., Benoy, G., Chow, T.L., Rees, H.W., Daigle, J.L., Meng, F.R., 2010. Impacts of accuracy and resolution of conventional and lidar based DEMs on parameters used in hydrologic modeling. *Water Resources Management* 24, 1363 – 1380.
- Zhou, Q., Chen, Y., 2011. Generalization of DEM for terrain analysis using a compound method. *ISPRS Journal of Photogrammetry and Remote Sensing* 66, 38 – 45.
- Zhou, W., 2013. An object-based approach for urban land cover classification: Integrating LiDAR height and intensity data. *IEEE Geoscience and Remote Sensing Letters* 10, 928 – 931.
- Zou, X., Zhao, G., Li, J., Yang, Y., Fang, Y., 2016. 3d land cover classification based on multispectral LiDAR point clouds. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XLI-B1*, 741 – 747.

Índice de figuras

1.1	Capítulo 1. Resumen gráfico	2
1.2	Evolución y tipología de los filtros desarrollados de 1996 a 2016.	5
1.3	Esquema de funcionamiento de la función OWM.	37
1.4	Pseudo-código de OWM.	38
1.5	Pseudo-código de PNT.	38
1.6	Pseudo-código de DebCloud.	39
1.7	Esquema de funcionamiento de la función DebCloud	41
1.8	Esquema de funcionamiento de DTMOFLabTe.	44
1.9	Valores de los parámetros automáticos y variables para la evaluación de DTMOFLabTe.	51
1.10	Efectividad del proceso de depurado.	53
1.11	Ejemplo efectividad del proceso de depurado (parte 1)	55
1.12	Ejemplo efectividad del proceso de depurado (parte 2)	56
1.13	Datos cuantitativos de la efectividad del proceso de selección de puntos semilla.	58
1.14	Ejemplo efectividad del proceso de selección de puntos semilla.	59
1.15	Ejemplo de puntuaciones de los puntos semilla.	61
1.16	Influencia de los parámetros variables en la precisión del filtrado.	62
1.17	Influencia de los parámetros C y C _S en los T _{Ie} , T _{IIe} y T _e	66
1.18	Resultados cualitativos del proceso de filtrado (parte 1).	71
1.19	Resultados cualitativos del proceso de filtrado (parte 2).	72
1.20	Comparativa de los errores T _{Ie} , T _{IIe} y T _e obtenidos en este estudio y en 23 trabajos previos.	77
1.21	Comparativa de resultados derivados de la combinación de parámetros únicos.	79
1.22	Distribución de los T _e en relación a su ocurrencia.	80
2.1	Capítulo 2. Resumen gráfico.	92
2.2	Esquema de factores que influyen en la precisión de los MDT.	94
2.3	Enfoques de análisis de la influencia de la densidad sobre la calidad de los MDT.	96
2.4	Esquema de funcionamiento de DecimaTe.	109

2.5	Esquema de la evaluación a nivel modelo.	119
2.6	Resultado indicadores a nivel método.	125
2.7	II. Resultados cualitativos y cuantitativos de la muestra 31. . .	126
2.8	II. Resultados cualitativos y cuantitativos de la muestra 42. . .	127
2.9	Relación densidad-resolución-precisión de los MDT	134
2.10	Diferencias de precisión entre modelos (Q68.3 _{\Delta h} -m) generados con nubes reducidas por diferentes métodos	137
2.11	Precisión de los MDT (Q68.3 _{\Delta h} -metros) en función de la densidad y método de reducción.	138
2.12	Precisión de los MDT (Q68.3 _{\Delta h} - m) para cada muestra en función de la densidad de puntos, el método de reducción y la pendiente.	143
2.13	Precisión de los MDT (Q68.3 _{\Delta h} - m) en función de la cobertura, la densidad, la pendiente y la resolución.	148
2.14	Resultados del análisis de sensibilidad.	156
2.15	Análisis CART. Árboles predictivos del error de los MDT. . .	162
3.1	Capítulo 3. Resumen gráfico.	176
3.2	Localización de la zona de estudio.	189
3.3	Distribución espacial y caracterización de los PC _R	191
3.4	Esquema del proceso de corrección de la intensidad.	196
3.5	Esquema de funcionamiento del método de reducción PpC. . .	201
3.6	Precisión de los MDT en función de la densidad y la cobertura.	204
3.7	Unidades de análisis para el cálculo de variables y elementos de asignación.	206
3.8	Variables en base a la elevación/altura: nMS _{FR} , nMS _{UR} , nM _{Vm} y Rg _z	209
3.9	Variables en base a la elevación/altura: Intervalos de densidad.	211
3.10	Variables en base a la elevación/altura: Cuantiles de altura. . .	212
3.11	Características e histograma de elevaciones de las zonas arboladas sin vegetación arbustiva.	213
3.12	Características e histograma de elevación de las zonas arboladas con vegetación arbustiva.	214
3.13	Variables en base a la elevación/altura: Coeficiente de asimetría y curtosis.	215
3.14	variables en base a la intensidad: I'' _{PR} , I'' _{UR} , I'' _{Vm} , I'' _D , Std _{I''} y CV _{I''}	217
3.15	Variables en base a la intensidad: Cuantiles de intensidad. . .	218
3.16	Variables en base a los retornos: MS _D , nD _{\Delta z} , PNT y RR.. . .	221
3.17	Variables en base a los retornos: RR, RT, RV y RE.	224
3.18	Variables en base a la rugosidad: Std _Z , Std _{\Delta Z} , P y CV _Z	228
3.19	Esquema del análisis de puntos a partir de un cilindro.	229

3.20	Variables en base a la rugosidad: N_z , RMS y D_N máxima y mínima.	230
3.21	Variables en base a la textura de la intensidad.	234
3.22	Variables en base a la textura de la elevación.	235
3.23	Variables en base a la textura de la altura.	236
3.24	Aplicaciones y coberturas del suelo.	237
3.25	Jerarquía de las coberturas del suelo.	243
3.26	Árbol de decisión que constituye <i>HyClass</i>	244
3.27	Características de las muestras de entrenamiento en relación a las 10 variables más importantes.	245
3.28	Muestras de entrenamiento P_v y P_s en tramos ocultos por vegetación.	247
3.29	Zonas susceptibles de contener P_v o P_s	248
3.30	Definición y relación entre los parámetros del ASM.	249
3.31	Ejemplo de delineación de contornos de edificaciones en las variables Std_z y P	253
3.33	Resultados de la corrección de la intensidad.	261
3.34	Comparación de la intensidad original con el resultado de las correcciones.	264
3.35	Comparación del coeficiente de variación de intensidad antes y después de su normalización.	265
3.36	<i>Random Forest</i> : Importancia de las variables a escala global.	268
3.37	<i>Random Forest</i> : Importancia de las variables en función de la cobertura (parte 1).	271
3.38	<i>Random Forest</i> : Importancia de las variables en función de la cobertura (parte 2).	273
3.39	Escenario 1. V_b , S_d , P_s y P_v	275
3.40	Escenario 2. V_b y V_r	276
3.41	Escenario 3. E_d , V_a y V_m	277
3.42	Resultado de la clasificación híbrida (nube de puntos original).	278
3.43	Desacuerdo por coberturas de los métodos <i>HyClass</i> y <i>random forest</i>	289
3.44	Resultado de la clasificación híbrida (nube de puntos original y las nubes reducidas).	291
3.45	Resultado de la detección de vías (nube de puntos original y las nubes reducidas).	293
3.46	Resultados cuantitativos de <i>HyClass</i>	296
3.47	Desacuerdo por coberturas en función de la densidad empleando <i>HyClass</i> (clasificación Nivel 2 - 8 coberturas).	298
3.48	Resultados cuantitativos de <i>HyClass</i> en función de la densidad de puntos (clasificación de Nivel 1 - 5 coberturas).	302

3.49	Desacuerdo por coberturas en función de la densidad empleando <i>HyClass</i> (clasificación Nivel 1 - 5 coberturas).	304
A.1	PFG-DebCloud code.	373
A.2	PFG-Hybrid method flowchart.	375
A.3	PFG-Data analysis: internal and external assessment.	376
A.4	PFG-Filtering optimal parameters.	377
A.5	PFG-Quantitative results of internal evaluation.	379
A.6	PFG-Qualitative results of internal evaluation.	380
A.7	Efectividad del proceso de depurado (parte 1)	395
A.8	Efectividad del proceso de depurado (parte 2)	396
A.9	Efectividad del proceso de depurado (parte 3)	397
A.10	Efectividad del proceso de depurado (parte 4)	398
A.11	Efectividad del proceso de depurado (parte 5)	399
A.12	Muestra 11: Efectividad del proceso de depurado.	403
A.13	Muestra 12: Efectividad del proceso de depurado.	404
A.14	Muestra 21: Efectividad del proceso de depurado	405
A.15	Muestra 22: Efectividad del proceso de depurado	406
A.16	Muestra 23: Efectividad del proceso de depurado	407
A.17	Muestra 24: Efectividad del proceso de depurado	408
A.18	Muestra 31: Efectividad del proceso de depurado	409
A.19	Muestra 41: Efectividad del proceso de depurado	410
A.20	Muestra 42: Efectividad del proceso de depurado	411
A.21	Muestra 51: Efectividad del proceso de depurado	412
A.22	Muestra 52: Efectividad del proceso de depurado	413
A.23	Muestra 53: Efectividad del proceso de depurado	414
A.24	Muestra 54: Efectividad del proceso de depurado	415
A.25	Muestra 61: Efectividad del proceso de depurado	416
A.26	Muestra 71: Efectividad del proceso de depurado	417
A.27	Muestra 11: Influencia parámetros variables.	420
A.28	Muestra 12: Influencia parámetros variables.	421
A.29	Muestra 21: Influencia parámetros variables.	422
A.30	Muestra 22: Influencia parámetros variables.	423
A.31	Muestra 23: Influencia parámetros variables.	424
A.32	Muestra 24: Influencia parámetros variables.	425
A.33	Muestra 31: Influencia parámetros variables.	426
A.34	Muestra 41: Influencia parámetros variables.	427
A.35	Muestra 42: Influencia parámetros variables.	428
A.36	Muestra 51: Influencia parámetros variables.	429
A.37	Muestra 52: Influencia parámetros variables.	430
A.38	Muestra 53: Influencia parámetros variables.	431
A.39	Muestra 54: Influencia parámetros variables.	432

A.40	Muestra 61: Influencia parámetros variables.	433
A.41	Muestra 71: Influencia parámetros variables.	434
A.42	Muestra 11: Resultados cualitativos filtrado.	435
A.43	Muestra 12: Resultados cualitativos filtrado.	436
A.44	Muestra 21: Resultados cualitativos filtrado.	437
A.45	Muestra 22: Resultados cualitativos filtrado.	438
A.46	Muestra 23: Resultados cualitativos filtrado.	439
A.47	Muestra 24: Resultados cualitativos filtrado.	440
A.48	Muestra 31: Resultados cualitativos filtrado.	441
A.49	Muestra 41: Resultados cualitativos filtrado.	442
A.50	Muestra 42: Resultados cualitativos filtrado.	443
A.51	Muestra 51: Resultados cualitativos filtrado.	444
A.52	Muestra 52: Resultados cualitativos filtrado.	445
A.53	Muestra 53: Resultados cualitativos filtrado.	446
A.54	Muestra 54: Resultados cualitativos filtrado.	447
A.55	Muestra 61: Resultados cualitativos filtrado.	448
A.56	Muestra 71: Resultados cualitativos filtrado.	449
B.1	Características de la muestra 11.	459
B.2	Características de la muestra 12.	460
B.3	Características de la muestra 21.	461
B.4	Características de la muestra 22.	462
B.5	Características de la muestra 23.	463
B.6	Características de la muestra 24.	464
B.7	Características de la muestra 31.	465
B.8	Características de la muestra 41.	466
B.9	Características de la muestra 42.	467
B.10	Pseudo-código de DecimaTe	468
B.11	Muestra 11. Resultado cualitativo del Indicador 1	470
B.12	Muestra 12. Resultado cualitativo del Indicador 1	471
B.13	Muestra 21. Resultado cualitativo del Indicador 1	472
B.14	Muestra 22. Resultado cualitativo del Indicador 1	473
B.15	Muestra 23. Resultado cualitativo del Indicador 1	474
B.16	Muestra 24. Resultado cualitativo del Indicador 1	475
B.17	Muestra 31. Resultado cualitativo del Indicador 1	476
B.18	Muestra 41. Resultado cualitativo del Indicador 1	477
B.19	Muestra 42. Resultado cualitativo del Indicador 1	478
B.20	Muestra 11-Indicador 1. Distribución de frecuencias.	480
B.21	Muestra 11-Indicador 1. Ajuste lineal.	481
B.22	Muestra 12-Indicador 1. Distribución de frecuencias.	482
B.23	Muestra 12-Indicador 1. Ajuste lineal.	483
B.24	Muestra 21-Indicador 1. Distribución de frecuencias.	484

B.25	Muestra 21-Indicador 1. Ajuste lineal.	485
B.26	Muestra 22-Indicador 1. Distribución de frecuencias.	486
B.27	Muestra 22-Indicador 1. Ajuste lineal.	487
B.28	Muestra 23-Indicador 1. Distribución de frecuencias.	488
B.29	Muestra 23-Indicador 1. Ajuste lineal.	489
B.30	Muestra 24-Indicador 1. Distribución de frecuencias.	490
B.31	Muestra 24-Indicador 1. Ajuste lineal.	491
B.32	Muestra 31-Indicador 1. Distribución de frecuencias.	492
B.33	Muestra 31-Indicador 1. Ajuste lineal.	493
B.34	Muestra 41-Indicador 1. Distribución de frecuencias.	494
B.35	Muestra 41-Indicador 1. Ajuste lineal.	495
B.36	Muestra 42-Indicador 1. Distribución de frecuencias.	496
B.37	Muestra 42-Indicador 1. Ajuste lineal.	497
B.38	Diferencias de precisión entre modelos ($Q95_{ \Delta h }$ -m) generados con nubes reducidas por diferentes métodos	503
B.39	Precisión de los MDT ($Q95_{ \Delta h }$ -metros) en función de la densidad y método de reducción.	503
B.40	Precisión de los MDT ($Q95_{ \Delta h }$ - m) para cada muestra en función de la densidad de puntos, el método de reducción y la pendiente.	504
B.41	Precisión de los MDT ($Q95_{ \Delta h }$ - m) en función de la cobertura, la densidad, la pendiente y la resolución.	507
C.1	Muestras de entrenamiento para las clases Pv y Ps.	521
C.2	Muestras de entrenamiento para las clases Ed, Sd, Vb y Vr.	521
C.3	Muestras de entrenamiento para las clases Va y Vm.	523
C.4	Árbol de decisión de <i>HyClass</i> . Densidad de 4 ptos/m ²	524
C.5	Árbol de decisión de <i>HyClass</i> . Densidad de 2 ptos/m ²	525
C.6	Árbol de decisión de <i>HyClass</i> . Densidad de 1 ptos/m ²	526

Índice de tablas

1.1	Características de los filtros de densificación.	25
1.2	Características de las zonas de análisis y los datos LiDAR . . .	32
1.3	Descripción de los parámetros de DTMofLabTe	36
1.4	<i>Cross-matrix</i> teórica y ecuaciones	48
1.5	Resultados de la evaluación de DTMofLabTe	68
1.6	Comparación del coeficiente Kappa para cada muestra de referencia con 23 trabajos previos.	74
1.7	Comparativa y resumen de los resultados del DTMofLabTe con 23 trabajos previos.	75
2.1	Características de las muestras y datos LiDAR.	107
2.2	Indicadores de la evaluación a nivel método.	115
2.3	Indicadores de la evaluación a nivel modelo.	120
2.4	Resultados de los <i>I2</i> e <i>I3</i> considerando zonas con y sin solape.	130
2.5	Precisión ($Q68.3_{ \Delta h } - m$) de los modelos en función de la cobertura, la pendiente y el CV para las posibles combinaciones densidad-método.	139
2.6	Caracterización de las muestras de referencia: cobertura, pendiente y CV.	145
3.1	Características técnicas de la captura de datos LiDAR.	190
3.2	Precisión de los MDT en función de la densidad de puntos. . .	203
3.3	Variables en base a la elevación/altura.	207
3.4	Variables en base a la intensidad.	215
3.5	Variables en base a los retornos.	220
3.6	Variables en base a la rugosidad.	226
3.7	Variables en base a la textura.	233
3.8	Descripción de las clases de coberturas del suelo.	238
3.9	Matriz de confusión usando el método híbrido <i>HyClass</i> . . .	279
3.10	Matriz de confusión usando <i>random forest</i>	286
3.11	Efectividad de la detección de vías de comunicación empleando <i>HyClass</i>	294

3.12	Desacuerdo en función de la densidad empleando <i>HyClass</i> (clasificación <i>Nivel 2</i>).	297
3.13	Desacuerdo en función de la densidad empleando <i>HyClass</i> (clasificación <i>Nivel 1</i>).	303
A.1	Listado algoritmos de filtrado desarrollados (1996 - 2016).	365
A.2	PFG-Characteristics of the ISPRS urban samples.	370
A.3	PFG-Comparison of error values (%) for each urban reference sample produced by the hybrid method and by the IRI filter and FUSION method.	381
A.4	PFG-Comparison of errors and K for all samples with 14 previous works from 2008 to 2016.	382
A.5	Sample11: Resultado del ajuste de parámetros.	386
A.6	Sample12: Resultado del ajuste de parámetros.	386
A.7	Sample21: Resultado del ajuste de parámetros.	387
A.8	Sample22: Resultado del ajuste de parámetros.	387
A.9	Sample23: Resultado del ajuste de parámetros.	388
A.10	Sample24: Resultado del ajuste de parámetros.	388
A.11	Sample31: Resultado del ajuste de parámetros.	389
A.12	Sample41: Resultado del ajuste de parámetros.	390
A.13	Sample42: Resultado del ajuste de parámetros.	390
A.14	Sample51: Resultado del ajuste de parámetros.	391
A.15	Sample52: Resultado del ajuste de parámetros.	391
A.16	Sample53: Resultado del ajuste de parámetros.	392
A.17	Sample54: Resultado del ajuste de parámetros.	392
A.18	Sample61: Resultado del ajuste de parámetros.	393
A.19	Sample71: Resultado del ajuste de parámetros.	393
A.20	Efectividad del proceso de depurado.	401
A.21	Comparación de resultados para cada muestra de referencia con 23 trabajos previos desde 1998 hasta 2016 (Parte 1).	451
A.22	Comparación de resultados para cada muestra de referencia con 23 trabajos previos desde 1998 hasta 2016 (Parte 2).	452
A.23	Comparación de resultados para cada muestra de referencia con 23 trabajos previos desde 1998 hasta 2016. Parámetros únicos	453
A.24	Muestras urbanas: Resultados cualitativos y cuantitativos (<i>online</i>).	455
A.25	Muestras rurales: Resultados cualitativos y cuantitativos (<i>online</i>).	455
B.1	Resultados cuantitativos del Indicador 1.	498
B.2	Resultados cuantitativos del Indicador 2.	498
B.3	Resultados cuantitativos del Indicador 3.	499
B.4	Resultados cuantitativos del Indicador 4	499

B.5	Datos cuantitativos de la precisión de los modelos (Q68.3 _{Δh} - m) en función de todos los factores considerados menos la resolución.	501
B.6	Datos cuantitativos de la precisión de los modelos (Q95 _{Δh} - m) en función de todos los factores considerados menos la resolución.	502
B.7	Precisión (Q68.3 _{Δh} - m) de los modelos en función de los métodos de reducción, la densidad, la pendiente y la muestra de referencia.	505
B.8	Precisión (Q95 _{Δh} - m) de los modelos en función de los métodos de reducción, la densidad, la pendiente y la muestra de referencia.	506
C.1	Coordenadas puntos control terreno (año 2004) (parte 1).	511
C.2	Coordenadas puntos control terreno (año 2004) (parte 2).	512
C.3	Coordenadas puntos control terreno (año 2004) (parte 3).	513
C.4	Coordenadas puntos control terreno (año 2004) (parte 4).	514
C.5	Coordenadas puntos control terreno (año 2004) (parte 5).	515
C.6	Coordenadas puntos control terreno (año 2004) (parte 6).	516
C.7	Coordenadas puntos control terreno (año 2004) (parte 7).	517
C.8	Coordenadas puntos control terreno (año 2010) (parte 1).	518
C.9	Coordenadas puntos control terreno (año 2010) (parte 2).	519
C.10	Matriz de confusión usando el método híbrido <i>HyClass</i> a partir de una nube de puntos con densidad de 4 pts/m ²	527
C.11	Matriz de confusión usando el método híbrido <i>HyClass</i> a partir de una nube de puntos con densidad de 2 pts/m ²	528
C.12	Matriz de confusión usando el método híbrido <i>HyClass</i> a partir de una nube de puntos con densidad de 1 pto/m ²	529
C.13	Medidas de desacuerdo (%) usando el método híbrido <i>HyClass</i> en función de la densidad de puntos (clasificación de nivel 2 - 8 coberturas)	530
C.14	Matriz de confusión usando el método híbrido <i>HyClass</i> a partir de una nube de puntos con densidad de 8 pto/m ² (clasificación nivel 1 - 5 coberturas)	531
C.15	Matriz de confusión usando el método híbrido <i>HyClass</i> a partir de una nube de puntos con densidad de 4 pto/m ² (clasificación nivel 1 - 5 coberturas)	531
C.16	Matriz de confusión usando el método híbrido <i>HyClass</i> a partir de una nube de puntos con densidad de 2 pto/m ² (clasificación nivel 1 - 5 coberturas)	532
C.17	Matriz de confusión usando el método híbrido <i>HyClass</i> a partir de una nube de puntos con densidad de 1 pto/m ² (clasificación nivel 1 - 5 coberturas)	532

C.18 Medidas de desacuerdo (%) usando el método híbrido *HyClass*
en función de la densidad de puntos (clasificación de nivel 1 - 5
coberturas) 533



