



VNIVERSIDAD D SALAMANCA
Escuela **Politécnica Superior**
de **Ávila**



VNIVERSIDAD
D SALAMANCA
CAMPUS DE EXCELENCIA INTERNACIONAL

ESCUELA POLITÉCNICA SUPERIOR DE ÁVILA
UNIVERSIDAD DE SALAMANCA

Indicador Integrado Multiparamétrico (IIM) para la caracterización de espacios peatonales en áreas urbanas a partir de la integración de datos LiDAR procedentes de Mobile Mapping System con otras fuentes de información

TRABAJO FIN DE MÁSTER

MÁSTER UNIVERSITARIO EN GEOTECNOLOGÍAS
CARTOGRÁFICAS EN INGENIERÍA Y ARQUITECTURA

AUTOR: David Fernández Arango
TUTORES: Diego González Aguilera
y Susana Lagüela López

Septiembre 2019

Agradecimientos

A Fco. Alberto Varela García y al resto del equipo del Laboratorio de Ingeniería Cartográfica (CartoLAB) de la Universidade da Coruña, por facilitarme toda la información y medios necesarios para poder llevar a cabo este trabajo. Sin su ayuda y constantes aportaciones no se podría haber realizado con éxito.

Al equipo de Emapic por facilitarme los medios técnicos necesarios para adquirir información relacionada con los hábitos de movilidad de los alumnos en sus trayectos diarios a los centros de estudio. Este trabajo se relaciona con los proyectos *Geomove: estudio dinámico de la movilidad escolar mediante tecnologías web de geolocalización* y *Análisis de indicadores big geo-data sobre viarios urbanos para el diseño dinámico de caminos escolares seguros (BIG-GEOMOVE)*, financiados por la Dirección General de Tráfico en los años 2015 y 2017, respectivamente.

A mis tutores Diego González Aguilera y Susana Lagüela López por su interés en dirigir este estudio.

Resumen

En este estudio se propone una metodología de investigación que permite identificar los caminos escolares peatonales más adecuados en áreas urbanas. En base a ciertas variables de seguridad vial, a la distancia de desplazamiento y al estado de los viales, entre otros parámetros de interés, se generará un indicador de movilidad que permitirá visualizar de manera sencilla los trayectos domicilio-colegio más adecuados.

El trabajo se divide en dos partes bien diferenciadas, la primera de ellas se focaliza en segmentar y clasificar nubes de puntos LiDAR para reconocer diferentes elementos viarios que condicionan la movilidad del peatón urbano. En la segunda parte se analiza la accesibilidad peatonal a un centro educativo aplicando técnicas de costes acumulados de desplazamiento, para identificar los caminos peatonales más apropiados en función de los elementos identificados en la fase previa.

Abstract

This study proposes a methodology to identify optimal pedestrian paths in urban environments. Based on certain road safety variables, travel distance and roads state, among other parameters of interest, we will generate a mobility indicator that allows us to visualize the most appropriate home-school paths.

This work has two different parts, the first one focuses on segmenting and classifying clouds of LiDAR points to recognize different road elements that condition the mobility of urban pedestrians. In the second part, it analyzes the pedestrian accessibility in an educational center applying techniques of accumulated travel costs, to identify the most suitable pedestrian paths based on the elements identified in the previous phase.

Índice general

Agradecimientos	III
Resumen	v
Abstract	VII
1. Introducción	1
2. Materiales y método	5
2.1. Identificación de elementos viarios	7
2.1.1. Segmentación grosera de la nube de puntos en 'terreno' y 'no terreno'	9
2.1.2. Depuración de la nube de puntos segmentada	10
2.1.3. Segmentación precisa de la nube de puntos	11
2.1.4. Generación de productos geomáticos a partir de la nube segmentada	11
2.2. Análisis de accesibilidad	15
3. Resultados	19
3.1. Identificación de elementos viarios	19
3.1.1. Segmentación grosera de la nube de puntos en 'terreno' y 'no terreno'	19
3.1.2. Depuración de la nube de puntos segmentada	20
3.1.3. Segmentación precisa de la nube de puntos	22

3.2. Generación de productos a partir de la nube segmentada	24
3.3. Análisis de accesibilidad	29
4. Discusión	31
5. Conclusiones	35
Bibliografía	37

Índice de figuras

2.1. Área de estudio con las escenas a analizar	6
2.2. Modelo cartográfico empleado para generar la nube de puntos depurada y segmentada, así como diferentes productos geomáticos	8
2.3. Filtro ELM (Chen et al., 2012)	10
2.4. Cálculo del vector normal a la componente Z de cada punto de la nube. . .	11
2.5. MDT sin interpolar.	12
2.6. Raster de intensidades sin interpolar.	12
2.7. Pipeline de procesamiento para segmentación automática de nubes de puntos LiDAR MMS.	13
2.8. Modelo cartográfico para identificación de pasos de peatones a partir de diferentes rasters de intensidad	14
2.9. Pipeline de procesamiento para identificación de aceras a partir de datos LiDAR y capas de viario, edificaciones y MDT	15
3.1. Nube de puntos segmentada	20
3.2. Detalle de la nube de puntos segmentada	20
3.3. Resultado de la segmentación de la nube de puntos mediante filtro de normales en Z	21
3.4. Detalle del resultado de la segmentación de la nube de puntos mediante filtro de normales en Z	21

3.5. Segmentación previa a la aplicación de KD	22
3.6. Segmentación posterior a la aplicación de KD	22
3.7. Segmentación previa a la aplicación de filtros y PMF	23
3.8. Segmentación posterior a la aplicación de filtros y PMF	23
3.9. Obstáculos para peatones y usuarios de sillas de ruedas	24
3.10. MDT interpolado mediante Kriging Residual	25
3.11. Pendiente	26
3.12. Rugosidad	26
3.13. Pasos de peatones detectados	27
3.14. Pasos peatones agrupados	27
3.15. Detalle resultado de detección automática de aceras	28
3.16. Superficie de coste acumulado	30
3.17. Caminos peatonales óptimos	30

Índice de tablas

2.1. Tiempo de desplazamiento por celda según pendiente	16
2.2. Tiempo de desplazamiento por celda según rugosidad	17
3.1. Resultados de la detección de las aceras	29

Capítulo 1

Introducción

Los desplazamientos realizados a los centros de enseñanza son unos de los comportamientos de movilidad más sensibles debido principalmente a la vulnerabilidad de sus protagonistas, los niños. Asimismo, su temporalidad es un factor de alto impacto, pues provoca problemas puntuales de congestión en zonas próximas a los colegios en horas concretas de entrada y salida, por lo que se generan conflictos en la circulación, poniendo en riesgo a conductores y peatones del entorno.

Además de los hábitos y comportamientos del peatón, otro factor importante para entender la movilidad urbana es el conocimiento de las infraestructuras disponibles. El estado de conservación del viario y de los elementos que lo conforman es clave ya que condicionan los hábitos de movilidad de los peatones. Su gestión requiere inspecciones periódicas y aunque a nivel tecnológico se ha avanzado significativamente, la mayor parte de las labores de inspección continúan realizándose mediante simples controles visuales. En este sentido, las administraciones responsables del mantenimiento viario demandan cada vez más una información objetiva y actualizada.

La tecnología LiDAR facilita notablemente estas labores gracias a su idoneidad para capturar datos con gran rapidez y precisión geométrica. Son varios los estudios que han demostrado capacidad para segmentar nubes de puntos LiDAR en elementos pertenecientes al terreno/no terreno y crear una superficie que represente el viario con precisión. En este sentido, [1] presentan un método que permite segmentar las superficies de las carre-

teras, árboles y fachadas a partir de datos procedentes de Mobile Laser Scanner (MLS). En este caso, la superficie del vial se caracteriza como un plano horizontal y posteriormente la información segmentada se emplea para calcular el ancho y la curvatura de la carretera. Los árboles y las fachadas son identificados como planos verticales y elementos discontinuos en el histograma. En [2] extraen las superficies viales mediante datos MLS empleando RANSAC¹ [4] en secciones pequeñas y posteriormente interconectando esas secciones mediante filtros de Kalman. [5] proponen el método *fuzzy clustering*² para clasificar automáticamente la superficie del vial. [6] clasifican superficies, bordillos y marcas viales a partir de datos MLS. Los bordillos se clasifican filtrando la imagen por alturas, encontrando los píxeles que no son totalmente horizontales ni verticales y empleando esta información para estimar los puntos pertenecientes a la superficie del vial. El conocimiento de los puntos clasificados permite crear una red de triángulos irregulares y posteriormente generar una superficie aplicando restricciones de pendiente y longitud de bordes. Por último, se identifican las marcas viales según valores de intensidad. Las futuras mejoras planteadas para el algoritmo pasan por aumentar la precisión en la clasificación de cruces, líneas centrales del vial y otros tipos de carreteras.

Algunos autores emplean fuentes complementarias a los propios datos LiDAR, como [7], que han demostrado la eficacia de la combinación de imágenes QuickBird con datos LiDAR para discriminar automáticamente diferentes tipos de cubiertas terrestres en entornos urbanos, [8], que son capaces de modelizar la superficie vial mediante la combinación de datos 3D LiDAR aeroportado con mapas topográficos o [9], que proponen un método basado en la fusión de nubes de puntos 3D procedentes de ALS y un road map.

Otros estudios se focalizan en la identificación y clasificación de elementos presentes en los viarios. Uno de los principales, debido a la importancia de conocer su ubicación, son los bordillos, ya que permiten delimitar las áreas de calzada y acera. Destacan artículos

¹RANdom SAMple Consensus es un método iterativo para estimar parámetros de un modelo matemático a partir de un conjunto de datos observados [3]. Una de sus múltiples aplicaciones consiste en segmentar geoméricamente nubes de puntos gracias a su capacidad para reconocer formas de manera automática (planos, cilindros, esferas y toros).

²Método de agrupamiento basado en la teoría de máxima entropía, que permite agrupar puntos pertenecientes a una línea de escaneo LiDAR.

como [10], que desarrollan un método para clasificar bordillos a partir de datos LiDAR aeroportados con una densidad de 20 pts/m² basándose en la detección de diferencias de altura drásticas en la nube de puntos capturada, considerando que son causadas por los bordillos. [11] evalúan la superficie del vial mediante el cálculo de su pendiente y la desviación estándar de los puntos LiDAR y emplean esos valores para estimar los bordes del vial. [12] propone un método de clasificación de puntos en función de su elevación, capaz de detectar la superficie vial y las líneas de bordillo/calzada a partir de datos MLS. [13] rasterizan las nubes de puntos LiDAR MLS para poder aplicar técnicas de procesamiento de imágenes que permitan definir características lineales, identificando como bordillos las líneas que presenten un mayor cambio de pendiente. [14] proponen una voxelización de la nube y una clasificación de los puntos del terreno. Posteriormente, los puntos candidatos a bordillo son seleccionados en base a tres variables: diferencia de altura, valor de gradiente y orientación normal. La línea de bordillo definitiva se genera a partir de un modelo de ajuste parabólico de puntos candidatos, proponiendo el algoritmo RANSAC para eliminar falsos positivos. [15] extraen bordillos de carreteras basándose en la detección de puntos de rotura de pendientes y el algoritmo RANSAC. [16] proponen un método de clasificación de bordillos a partir de datos MLS. Primero detectan los bordes del vial reconociendo bordillos y rampas y posteriormente realizan una reconstrucción de las posibles oclusiones basándose en modelos de filtros de Kalman. [17] proponen un método que filtra los datos adquiridos en puntos de terreno/no terreno, para detectar patrones de bordillos. Exponen además, que la mejora de su algoritmo pasa por incorporar el valor intensidad de los puntos o de las imágenes registradas para detectar diferentes tipologías de bordillos, algo que se incluye en otros estudios como [18], que emplean la elevación, la reflectancia y la amplitud de pulso para distinguir bordillos, calzada y diferentes cubiertas vegetales.

La detección automática de marcas viales, como señales horizontales, pasos de peatones o líneas de delimitación de carriles o calzada también son elementos fundamentales en los análisis de accesibilidad. Ciertos estudios han demostrado ser eficaces identificando marcas viales a partir de imágenes, como [19] que las clasifican a partir de imágenes de intensidad georreferenciadas empleando una interpolación IDW (Inverse Distance Weighted) y un umbral de densidad dependiente de los puntos; o [7] en donde se aplica una transformación de Hough. Sin embargo, el tratamiento único de nubes de puntos LiDAR

también permite realizar estas tareas, basándose en los valores de intensidad de cada punto capturado. Estudios como [20] son capaces de identificar marcas viales empleando el método de binarización de Otsu y clasificando los puntos en cuatro clases mediante *Deep Boltzman Machines (DBM)* y en un segundo nivel de jerarquía, en siete clases de marcas viales identificando flechas, pasos de peatones o líneas de detención. [21] emplean datos MLS basándose en segmentar puntos pertenecientes al terreno y aplicar un filtro identificando los que tengan intensidades mayores para diferenciar pasos de peatones y otras marcas viales. [22] también emplean datos MLS para identificar diferentes marcas viales como pasos de cebra, líneas de delimitación o flechas de dirección basándose en una metodología dividida en cuatro fases: (1) extracción de la superficie del vial, (2) identificación de objetos candidatos, (3) clasificación de elementos y (4) evaluación de la calidad obtenida.

También cabe destacar la importancia de posibles obstáculos sobre el viario o sobre las aceras, que pueden llegar a dificultar la movilidad del peatón. [2] han sido capaces de extraer elementos sobresalientes del viario mediante el empleo de RANSAC y filtros de Kalman, [23] se focalizan en la extracción de señales verticales empleando una discretización basada en un análisis de componentes principales, [24] clasifican diferentes elementos obstáculos (árboles, vehículos, edificios...) empleando un análisis por componentes principales (PCA - Principal Components Analysis). [25] emplean un enfoque basado en tres fases (1) detectar discontinuidades en el terreno, (2) conectar objetos segmentados mediante *watershed* y (3) clasificar objetos mediante *Support Vector Machine (SVM)*.

En el presente estudio se propone obtener un indicador de caracterización de espacios peatonales en ámbitos urbanos para establecer rutas óptimas seguras y de calidad, centrándose especialmente en caracterizar espacios viarios para definir recorridos peatonales que permitan llegar andando a los centros educativos. La metodología empleada se basa en el tratamiento automático de nubes de puntos LiDAR MLS para identificar automáticamente diferentes elementos viarios que permitirán caracterizar los viales de forma precisa para, posteriormente, realizar un análisis de costes acumulados de desplazamiento y obtener los caminos peatonales óptimos en áreas urbanas.

Capítulo 2

Materiales y método

El área de estudio de este proyecto se focalizó en el centro urbano de la ciudad de A Coruña (España) ya que se trata de un ambiente urbano con múltiples servicios públicos, entre los que destacan diferentes centros educativos de las etapas de enseñanza obligatoria. Concretamente se analizaron 8 calles, completando 4460 metros en torno al centro educativo Fogar de Santa Margarita, figura (2.1), situado en un área céntrica de la ciudad y cuyos estudiantes suelen desplazarse diariamente caminando. Para llevar a cabo este estudio se han obtenido datos sobre los hábitos y comportamientos de los alumnos en sus desplazamientos diarios a sus centros educativos y también sobre las características físicas de los viales que emplean los estudiantes en sus trayectos. La información sobre los hábitos de movilidad se consiguió gracias a la colaboración de 309 alumnos participantes en un cuestionario web creado a medida en el que se preguntaba, además de otros datos, la ubicación del domicilio y el trayecto diario de los estudiantes hasta su colegio. Este cuestionario se puede consultar en: <https://emapic.es/custom/geomove-test>. Los datos relacionados con la geometría de los viales se ha adquirido mediante un sistema Mobile Mapping (MMS) -Lynx Mobile Mapper M1- de la casa Optech, que consta principalmente de dos sensores LiDAR y 4 cámaras RGB. Según sus especificaciones, el sensor permite capturar hasta 4 retornos por punto, con un rango de alcance de 200m, unas velocidades de hasta 500KHz y una frecuencia de escaneo de hasta 200Hz. Los datos obtenidos en cada escena fueron dos nubes de puntos 'S1' y 'S2', capturadas por los dos sensores del sistema. El formato de los datos es de tipo punto, $P=\{x, y, z, I, ts, nr, rn...\}$, que indican

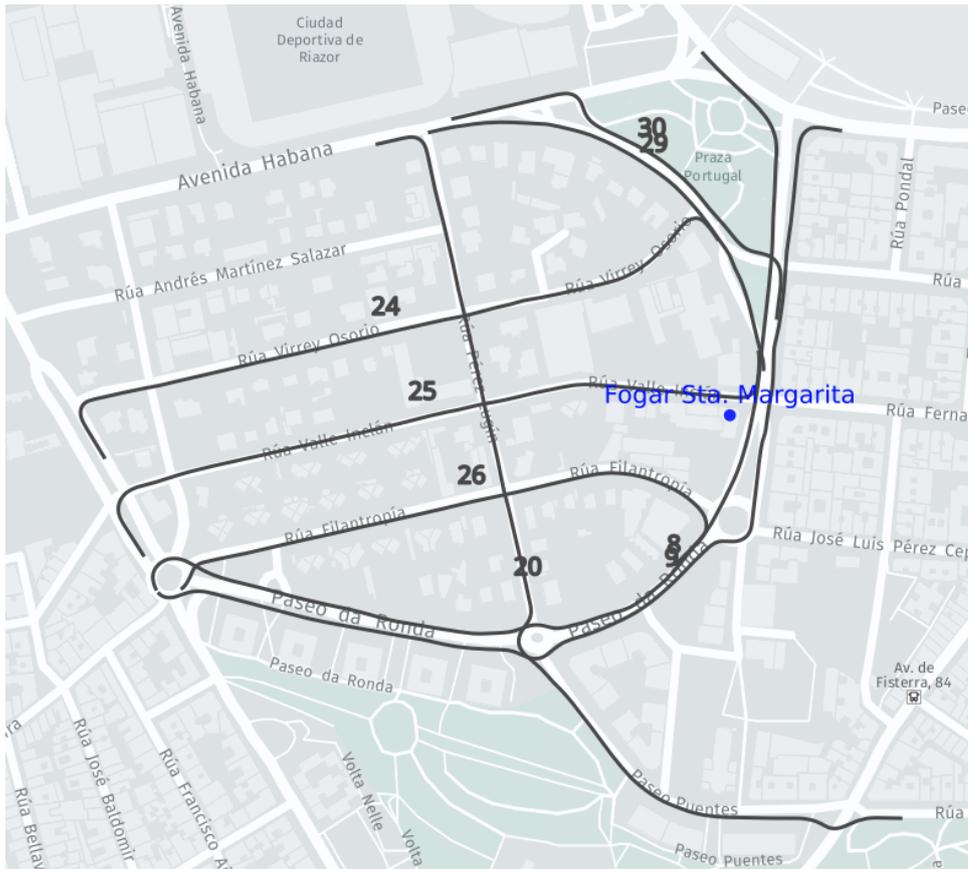


Figura 2.1: Área de estudio con las escenas a analizar

las coordenadas en 3D, valor de Intensidad, time stamp que recoge el tiempo GPS de adquisición del punto, número de retornos totales de cada punto y número de retorno dentro del total de retornos de cada punto.

La metodología propuesta ha permitido identificar los caminos escolares peatonales óptimos en base a la ejecución de dos fases consecutivas y claramente diferenciadas: (1) identificar diferentes elementos viarios mediante el tratamiento automático de las nubes de puntos adquiridas con MMS y otras fuentes de datos, y (2) crear, a partir de los elementos identificados, diferentes superficies de fricción al desplazamiento peatonal, que permitieron alimentar el análisis de accesibilidad posterior.

2.1. Identificación de elementos viarios

La primera fase de la identificación de elementos viarios consistió en generar una nube de puntos segmentada en las clases 'terreno' y 'no terreno' para, posteriormente, crear ciertas superficies de fricción al desplazamiento a partir de esta nube segmentada. El proceso se ejecutó en 4 etapas, tal y como se muestra en el modelo cartográfico de la figura (2.2): (a) segmentación grosera de la nube de puntos en terreno/no terreno, (b) depuración de la nube de puntos segmentada, (c) segmentación precisa de la nube de puntos y (d) generación de productos geomáticos. Para realizar esta tarea se empleó la librería de tratamiento de nubes de puntos Point Data Abstraction Library (PDAL)¹, sobre la que se crearon diferentes algoritmos que permitieron realizar el tratamiento de los datos. Todo el código empleado en este trabajo se puede ver y descargar libremente en el repositorio de código gitlab².

¹<https://pdal.io/>

²https://gitlab.com/darango/geomove_pipelines

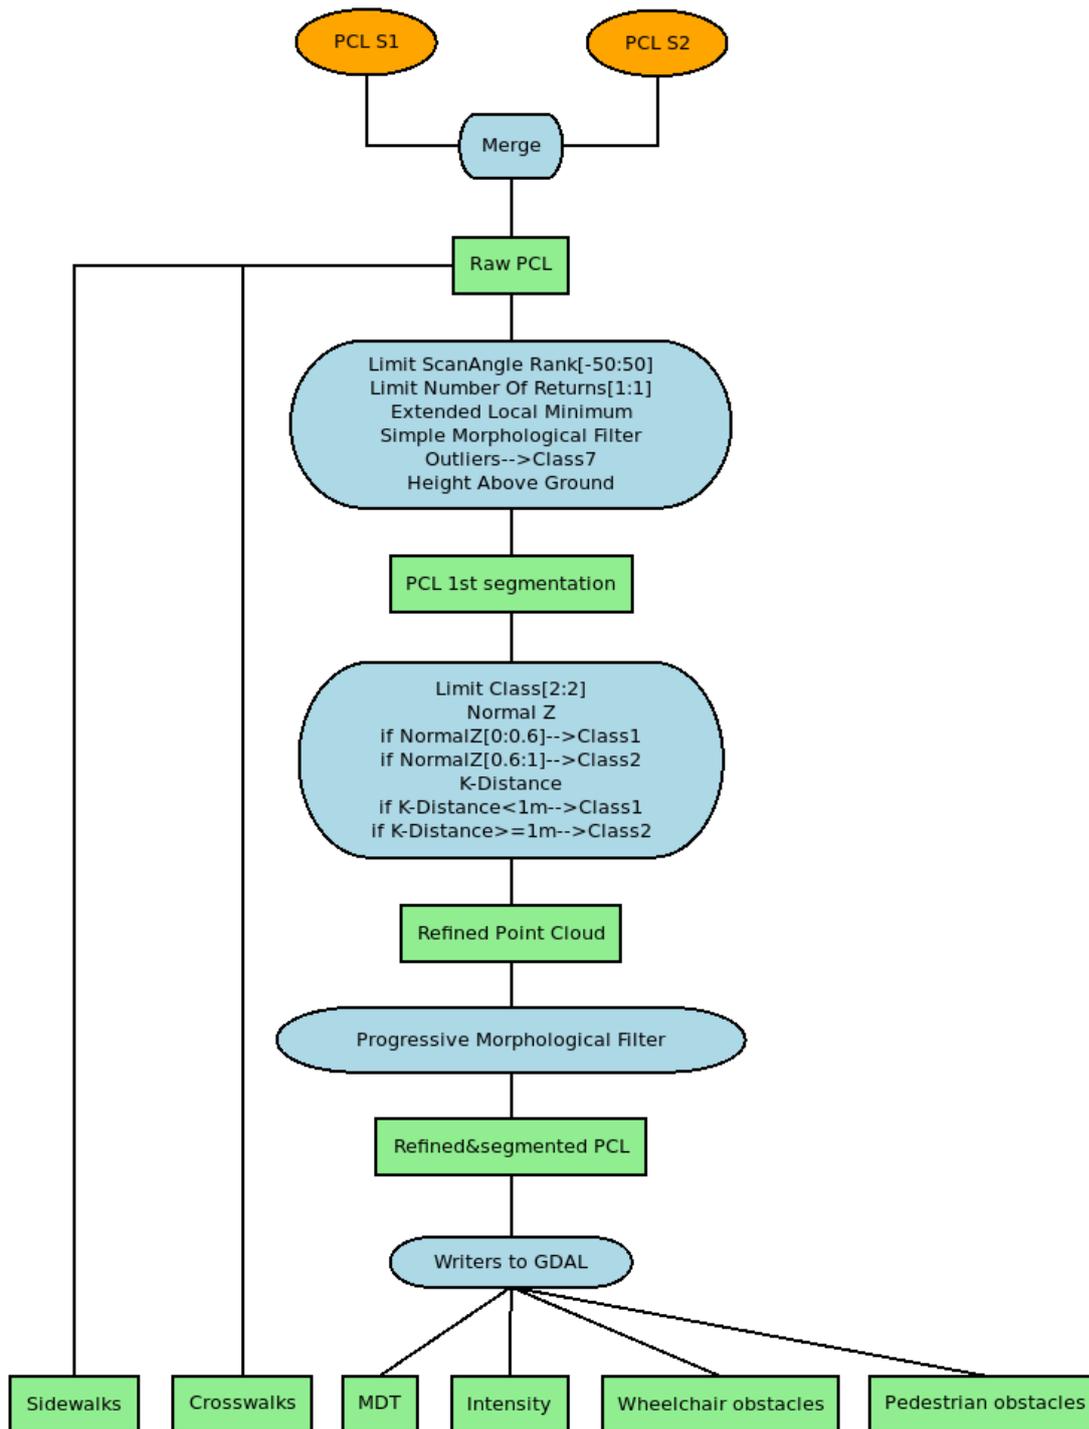


Figura 2.2: Modelo cartográfico empleado para generar la nube de puntos depurada y segmentada, así como diferentes productos geomáticos

2.1.1. Segmentación grosera de la nube de puntos en 'terreno' y 'no terreno'

Los datos de entrada fueron las dos nubes de puntos crudas capturadas por los dos sensores S1 y S2 del sistema MMS. El objetivo de esta fase del algoritmo fue segmentar, de forma grosera, los puntos pertenecientes al viario. Para ello, se agruparon los puntos de la nube analizada en dos categorías numéricas '1' y '2' correspondientes a *unclassified points* y *ground*, respectivamente, según las especificaciones del estándar ASPRS para las nubes de puntos LiDAR (ASPRS las specification)[26], a partir de ahora llamadas *Class1* y *Class2*.

El proceso comenzó fusionando las dos nubes de puntos para conseguir una única nube. Posteriormente se seleccionaron sólo los puntos con un único retorno (se comprobó que los puntos con más de un retorno pertenecían a áreas de vegetación, esquinas de edificios y retornos de cristales de vehículos, provocando problemas en la segmentación) y con un *Scan Angle Rank* comprendido entre [-50, 50], a fin de eliminar puntos demasiado altos que no interesasen para identificar elementos viarios.

Sobre estos puntos se aplicaron dos filtros: un *Extended Local Minimum Filter (ELM)* [27] para eliminar ruido en la nube analizada, y un *Simple Morphological Filter (SMF)* [28] para obtener una nube segmentada en puntos de 'terreno' y 'no terreno'. El filtro ELM, ilustrado mediante la figura (2.3), comienza rasterizando la nube de puntos en una cuadrícula con un tamaño de pixel, establecido por el usuario de 18cm. Para cada celda se considera como ruido el punto de menor cota, siempre que el siguiente punto más bajo esté por encima de un umbral dado, en este estudio fue de 25cm. Si se identifica como ruido, se estudia la diferencia de cota entre los dos puntos siguientes, marcándose como ruido si es necesario. El proceso continúa hasta que se encuentre una diferencia de cota entre dos puntos vecinos menor que el umbral establecido, en este caso la iteración sobre la celda se detiene y el proceso continúa en la celda siguiente.

Se seleccionaron los puntos pertenecientes a 'no terreno' (Class1) y sobre ellos se aplicó el filtro *Outlier - Statistical Method* [29] que permitió identificar puntos con valores atípicos, a los que se les asignó un valor de *Class7 (low point-noise)*, excluyéndolos del

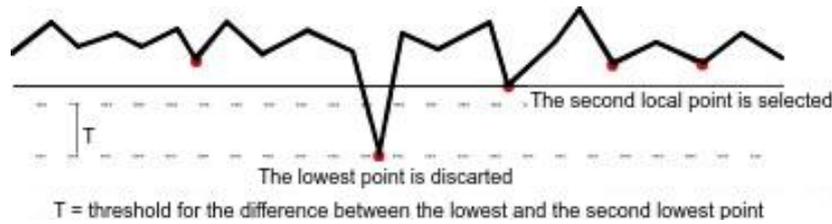


Figura 2.3: Filtro ELM (Chen et al., 2012)

estudio. Por último, sobre los puntos de *Class2*, se calculó la HAG (Height Above Ground)³, que indica un valor de altura media relativa desde cada punto respecto a sus vecinos. Este cálculo se realizó iterando sobre todos los puntos, encontrando el vecino más cercano en planimetría de entre los puntos del terreno y calculando la distancia entre los dos valores de la componente 'Z'.

2.1.2. Depuración de la nube de puntos segmentada

Esta fase permitió filtrar la nube de puntos anterior, como paso previo a una segmentación más precisa. El primer paso fue aplicar un filtro de normales. Se seleccionaron sólo los puntos 'terreno' y sobre ellos se calculó el vector normal en las componentes 'X', 'Y' y 'Z' a cada punto, en función de sus 30 vecinos más próximos. Con la aplicación de este filtro sobre la componente 'Z' se identificaron de manera clara las transiciones entre el terreno y los planos verticales. En la figura (2.4) se muestran en color rojo los puntos pertenecientes al terreno *Class2*, en azul los no clasificados, *Class1*, y en verde las regiones de transición.

En este caso, si el valor de la normal en la componente 'Z' estaba comprendido en el intervalo $[0, 0.6]$ se consideraba horizontal y por tanto el punto se asignaba a un elemento vertical (fachada de edificio, obstáculo, etc.) con *Class1*. En el caso de que los puntos tuviesen una normal en la componente 'Z' prácticamente vertical $(0.6, 1]$ se consideraban como puntos de terreno con *Class2*.

El siguiente paso fue calcular *K-distance*. Sobre los puntos *Class2* se calculó, y almacenó en forma de un campo nuevo, la distancia euclídea desde cada punto analizado a

³<https://pdal.io/stages/filters.hag.html#filters-hag>

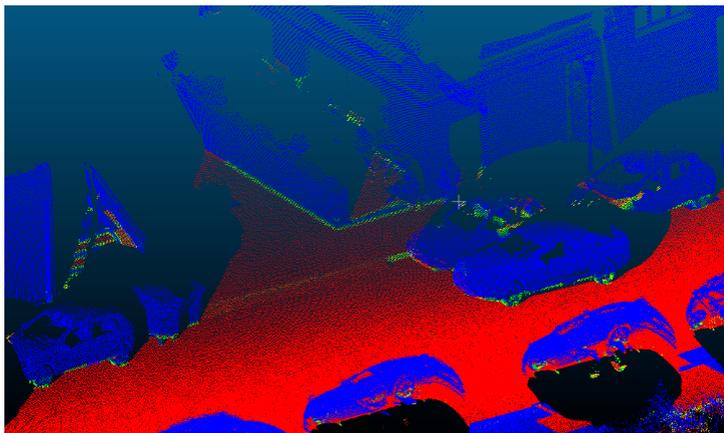


Figura 2.4: Cálculo del vector normal a la componente Z de cada punto de la nube.

sus 'k' vecinos (en este caso $k=300$) mediante el filtro *K-distance*. Se estableció que, si la distancia entre ellos era inferior a 1m, los puntos pertenecían a una misma clase, *Class2* y si la distancia era superior, pertenecerían a clases diferentes y por lo tanto se asignaban a *Class1*.

2.1.3. Segmentación precisa de la nube de puntos

La última segmentación de la nube de puntos ya filtrada consistió en la aplicación de un *Progressive Morphological Filter*, que permitió segmentar los puntos de 'terreno' y 'no terreno' mediante la implementación del método descrito en [30].

2.1.4. Generación de productos geomáticos a partir de la nube segmentada

Con la nube de puntos filtrada y adecuadamente segmentada se generaron cuatro archivos en formato raster con un tamaño de pixel de 18cm: raster de obstáculos para peatones, raster de obstáculos para usuarios de sillas de ruedas, MDT y raster de intensidades.

Para generar los rasters de obstáculos para peatones y usuarios de sillas de ruedas se identificaron y convirtieron a una cuadrícula todos los puntos cuyos valores de HAG estaban comprendidos entre 5 y 220cm. Se consideró que todos los puntos con $HAG \geq 5$ cm eran obstáculos para usuarios de sillas de ruedas y los que tenían $HAG \geq 25$ cm eran

obstáculos para peatones.

El MDT y el raster de intensidades tenían como valores de pixel las alturas e intensidades medias, respectivamente, de los puntos que se encontraban sobre dicho pixel. Sin embargo, en ciertas escenas existían gran cantidad de vehículos aparcados en los márgenes de la calzada que provocaban zonas de sombra en las nubes de puntos LiDAR y que dificultaban enormemente la labor de identificar con precisión la geometría de los elementos viarios en ciertas regiones, tal y como se puede ver en las figuras (2.5) y (2.6).

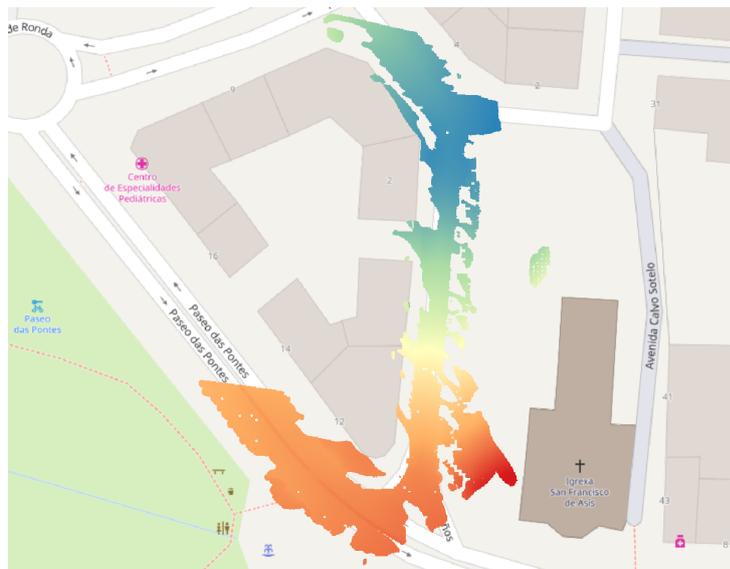


Figura 2.5: MDT sin interpolar.



Figura 2.6: Raster de intensidades sin interpolar.

Para solucionar este problema se optó por realizar una interpolación de tipo Kriging, directamente en QGIS. En este caso, para interpolar los valores en las áreas de sombra, se empleó un método geostadístico no paramétrico. En geostadística [31] se tiene en cuenta la componente espacial de los datos, no solo para modelar la tendencia (variación de gran escala), sino también para modelar la dependencia (variación de pequeña escala). La idea es que datos cercanos en el espacio son más semejantes que aquellos que están más alejados y se habla por tanto de dependencia espacial.

Para ejecutar secuencialmente todos los algoritmos necesarios se ha creado la *pipeline* que se muestra en la figura (2.7).

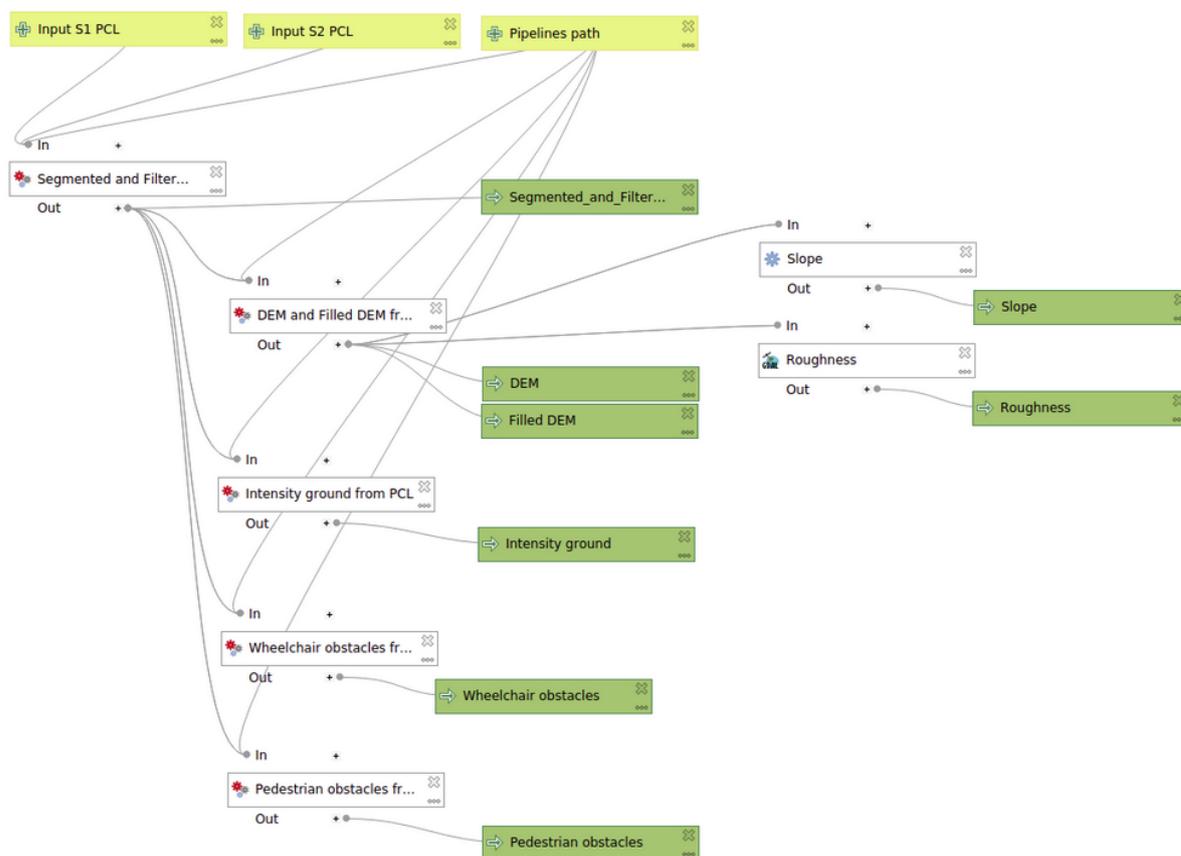


Figura 2.7: Pipeline de procesamiento para segmentación automática de nubes de puntos LiDAR MMS.

Además de los rasters anteriores, extraídos directamente de la *pipeline* de procesamiento, y para completar el análisis de accesibilidad, también se detectaron de manera automática los pasos de peatones del entorno y la geometría y topología de las de las

aceras.

Para la detección automática de los pasos de peatones se realizó un análisis espacial sobre los rásters de intensidad generados previamente en la *pipeline* de procesamiento. Tal y como se muestra en el modelo cartográfico de la figura (2.8), el algoritmo toma como parámetro inicial un raster de intensidad generado a partir de la unión de todas las escenas a analizar. Posteriormente se seleccionaron los píxeles con un valor de intensidad igual o superior a 2700 y se transformaron en polígonos vectoriales. Sobre ellos se ejecutó un *buffer* de 50cm, para agrupar de forma simple las diferentes bandas que componen un paso de peatones y se realizó un *dissolve* para unificar las agrupaciones establecidas. Por último, sobre esta capa vectorial se calculó el área de cada polígono y se seleccionaron los mayores de 6m^2 , correspondientes a pasos de peatones.

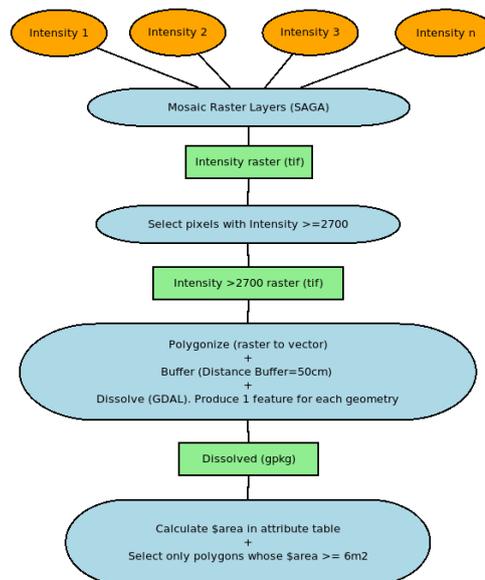


Figura 2.8: Modelo cartográfico para identificación de pasos de peatones a partir de diferentes rasters de intensidad

La identificación de la geometría y la topología de las aceras se llevó a cabo mediante la *pipeline* que se muestra en el modelo cartográfico de la figura (2.9). El análisis se basó en la aplicación del algoritmo *watershed segmentation* de QGIS, muy empleado en el análisis de cuencas hidrográficas y que en este caso permitió diferenciar elementos viarios basándose en las variaciones morfológicas del terreno identificadas en el MDE. El algoritmo tenía como parámetros de entrada una capa vectorial de líneas que contenía el viario del área

de estudio, extraído directamente de OpenStreetMap⁴, una capa vectorial de polígonos con los bloques de edificios de la zona, descargada de la Sede Electrónica del Catastro⁵ y el MDE con resolución espacial de 18cm de pixel obtenido de manera automática desde la nube de puntos LiDAR. El resultado fue un raster de 18cm de resolución espacial y valores de pixel '1' y '3', correspondientes a las clasificaciones de 'acera segura' y 'acera probable', respectivamente.

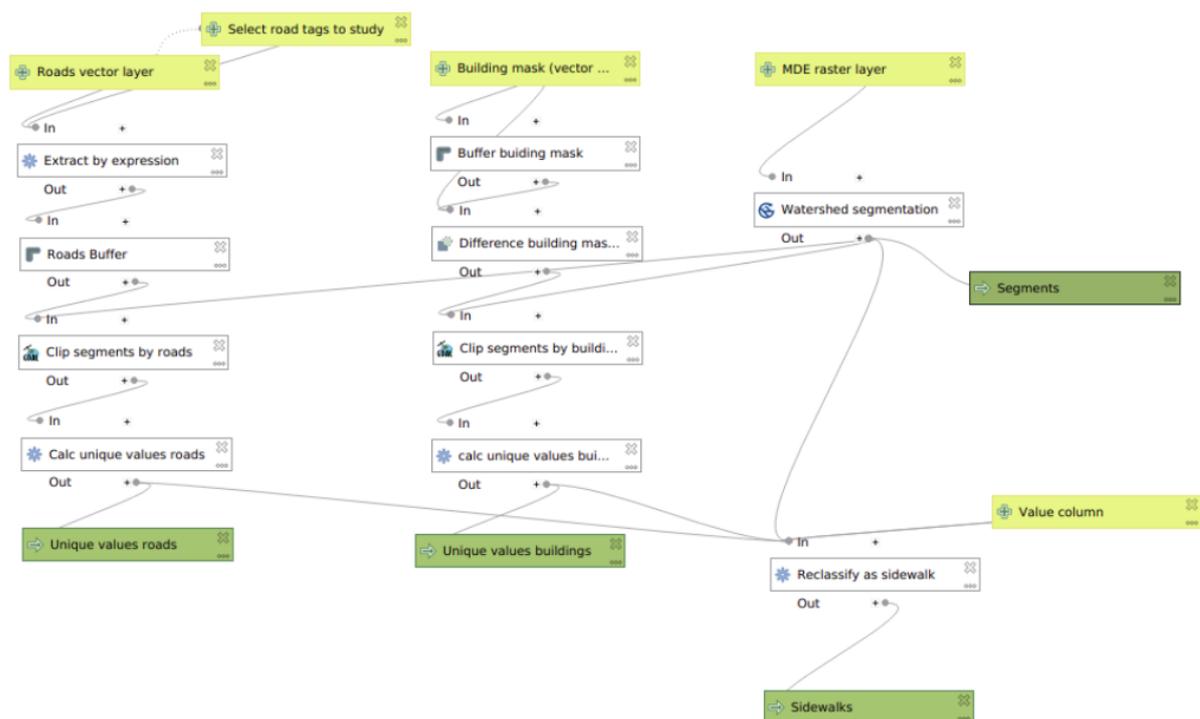


Figura 2.9: Pipeline de procesamiento para identificación de aceras a partir de datos LiDAR y capas de viario, edificaciones y MDT

2.2. Análisis de accesibilidad

A partir de la información obtenida por el sensor LiDAR, además de la recopilada en la encuesta y en otras fuentes de datos, se ha desarrollado un análisis de accesibilidad basado en la superposición de diferentes capas de información geográfica. Con los elementos viarios identificados en el apartado anterior se han generado diferentes superficies de fricción al

⁴<https://www.openstreetmap.org/#map=7/40.007/-2.488>

⁵<https://www.sedecatastro.gob.es/>

desplazamiento peatonal para alimentar el análisis. Como el tratamiento automático de las nubes de puntos requería un gran coste computacional, la nube se dividió en múltiples escenas más pequeñas que se analizaron por separado: s8, s9, s20, s24, s25, s26, s29 y s30. Una vez analizadas individualmente, los productos geomáticos generados en cada una de ellas se fusionaron para generar una sola escena global, a partir de la cual se crearon cinco superficies de fricción al desplazamiento que se incluyeron en el análisis: (1) tiempo de desplazamiento en función de la pendiente del terreno, (2) obstáculos para peatones, (3) obstáculos para usuarios de sillas de ruedas, (4) ponderación de tiempos de desplazamiento en función de la rugosidad del terreno, (5) identificación de pasos de peatones y (6) identificación de las aceras.

El tiempo de desplazamiento es el tiempo medio que tarda un peatón en atravesar una celda raster y se calcula en función de la pendiente del terreno. Con el MDT interpolado, extraído directamente del análisis de nubes de puntos LiDAR, se obtuvo un raster de pendientes del terreno mediante el algoritmo *slope* de la librería GDAL. Con esta superficie de pendientes y mediante una reclasificación con el algoritmo *reclassify by table* de QGIS se generó una superficie de fricción de tiempos de desplazamiento. En la tabla (2.1) se muestran los tiempos de desplazamiento empleados en el análisis, extraídos de [32].

Tabla 2.1: Tiempo de desplazamiento por celda según pendiente

Pte(%)	V(km/h)	t/1m (s)	t/18cm (s)
0-8	4.5	0.8	0.1
8-15	3	1.2	0.2
15-25	1	3.6	0.6
25-60	0.5	7.2	1.3
> 60	0.1	36	6.5

Sobre la nube de puntos se identificaron y seleccionaron todos los puntos cuyo HAG estaba comprendido entre 0.25 y 2.20m, ya que se consideraron como obstáculos para peatones. Con ellos generó una superficie de fricción de 18cm de resolución espacial y valores de tiempo de desplazamiento muy altos (1000s para recorrer la celda de 18cm), pues se identificaron como obstáculos insalvables para los peatones. De la misma manera obtuvieron los obstáculos para usuarios de sillas de ruedas, con la única diferencia que, en este caso, se seleccionaron los puntos cuyo HAG estaba comprendido entre 0.05 y

2.20m. El raster resultado también tenía una resolución de 18cm y valores de tiempo de desplazamiento de 1000s para recorrer cada celda.

El raster de rugosidad, al igual que el de pendientes, se extrajo del MDT, esta vez mediante el algoritmo *roughness* de GDAL. De esta manera se obtuvo un grado de irregularidad de la superficie calculada mediante la mayor diferencia entre celdas de un pixel central y su celdas vecinas. Una vez obtenido un valor de rugosidad para cada celda, se transformó en valores de tiempo del desplazamiento mediante una reclasificación basada en cuartiles, según los valores de la tabla (2.2).

Tabla 2.2: Tiempo de desplazamiento por celda según rugosidad

-	Valor rugosidad	Peso
Q1	0-0.343	1
Q2	0.343-0.687	1.25
Q3	0.687-1.03	1.5
Q4	1.03-1.37	1.75

Por último, se generó una superficie que incluía aceras, pasos de peatones y viario. Con el objetivo de priorizar la movilidad por las aceras y pasos de peatones en detrimento del viario, se clasificaron los pixeles de acera segura y pasos de peatones con valor de fricción '1', los de acera probable con valor '3' y los de viario con valor '10'. De esta manera se aseguraba que el trayecto transcurriese prioritariamente por las regiones más adecuadas para los peatones.

Con todas estas superficies de fricción se construyó un indicador integrado multiparamétrico que tenía en cuenta la pendiente del terreno (calculada a partir de los datos LiDAR), la geometría del viario y su diferenciación entre calzada y acera (a partir de los datos LiDAR y de otros datos SIG), la presencia de obstáculos (identificados mediante el análisis de los datos LiDAR, y clasificados tanto para una movilidad peatonal como para personas con movilidad reducida), las características del pavimento (en función de la rugosidad calculada mediante los valores de los datos LiDAR) y la presencia de pasos de peatones (calculados automáticamente a partir de los datos LiDAR). Con todo ello se otorgó un valor de resistencia al desplazamiento peatonal para cada unidad de superficie definida por celdas cuadradas de 18 cm de lado. Se empleó el modelo de coste distancia

para calcular costes acumulados de desplazamientos y trazar rutas de conexión entre los domicilios del alumnado (extraídos de la encuesta geolocalizada) y la entrada del centro escolar, a partir de los datos definidos según los parámetros de movilidad de los viarios tratados. Para crear la superficie de coste se multiplicaron todas las superficies de fricción al desplazamiento mediante 'Raster Calculator' de GDAL en QGIS y posteriormente, para calcular la superficie de costes acumulados, se empleó el algoritmo 'Accumulated Cost' de SAGA. Los parámetros de entrada fueron una capa vectorial de puntos con la ubicación del centro educativo y la superficie de costes calculada previamente. Una vez generada esta superficie de coste acumulado hasta el colegio, se calcularon los caminos óptimos desde cada domicilio hasta el centro educativo mediante el algoritmo 'Least Cost Path' de SAGA, indicando como parámetros de entrada la ubicación de los domicilios mediante una capa vectorial y la superficie de costes acumulados.

Capítulo 3

Resultados

3.1. Identificación de elementos viarios

3.1.1. Segmentación grosera de la nube de puntos en 'terreno' y 'no terreno'

El resultado de esta primera segmentación ha sido una nube cuyos puntos sólo disponían de un único retorno, tenían un ángulo de escaneo comprendido entre $[-50: 50]$ y estaban agrupados en tres clases diferentes: *Class1* (*unclassified points*), *Class2* (*ground*) y *Class7* (*low point-noise*). También se ha obtenido y almacenado a modo de un nuevo campo, el HAG, que muestra la altura relativa de cada punto respecto a sus 'n' vecinos. En la figura (3.1) se puede ver la nube después de la segmentación. El algoritmo propuesto fue capaz de identificar en gran medida los puntos pertenecientes a suelo y aislarlos del resto de puntos de la nube. Sin embargo, en zonas de confluencia entre el suelo y ciertos planos verticales se detectaron algunos errores en la segmentación. En la figura (3.2) se expone un detalle de la segmentación obtenida en una zona de confluencia entre planos ortogonales. En ella se puede comprobar que la parte baja de los vehículos y de los edificios no ha quedado correctamente segmentada pues fueron clasificados como *Class2* cuando deberían ser *Class1*. Por este motivo, se aplicaron diferentes filtros en la segunda parte de método propuesto.

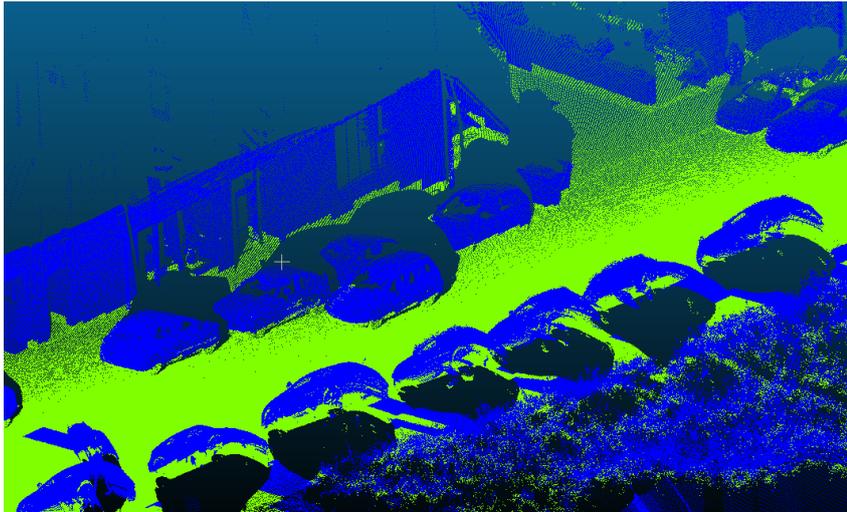


Figura 3.1: Nube de puntos segmentada

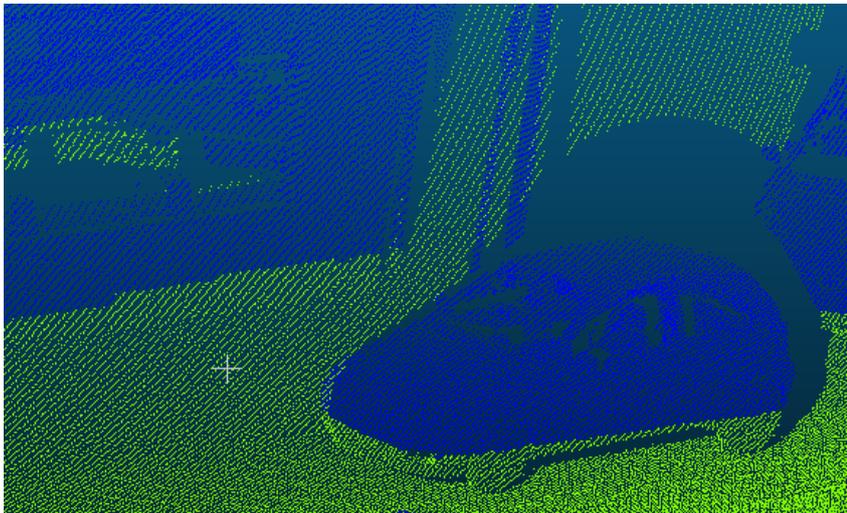


Figura 3.2: Detalle de la nube de puntos segmentada

3.1.2. Depuración de la nube de puntos segmentada

La aplicación del filtro de normales en 'Z' permitió depurar las áreas de transición entre el terreno y planos verticales de tal manera que las áreas problemáticas entre los vehículos, edificios... y el terreno, que anteriormente estaban mal clasificadas, han quedado ahora definidas con precisión. En las figuras (3.3) y (3.4) se muestra un ejemplo de las mejoras obtenidas en algunas zonas problemáticas, como las transiciones entre vehículos-terreno y edificios-terreno.

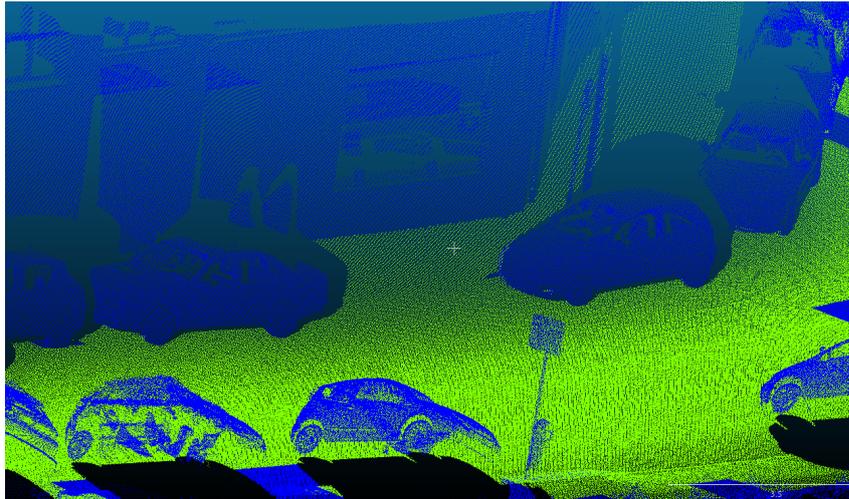


Figura 3.3: Resultado de la segmentación de la nube de puntos mediante filtro de normales en Z

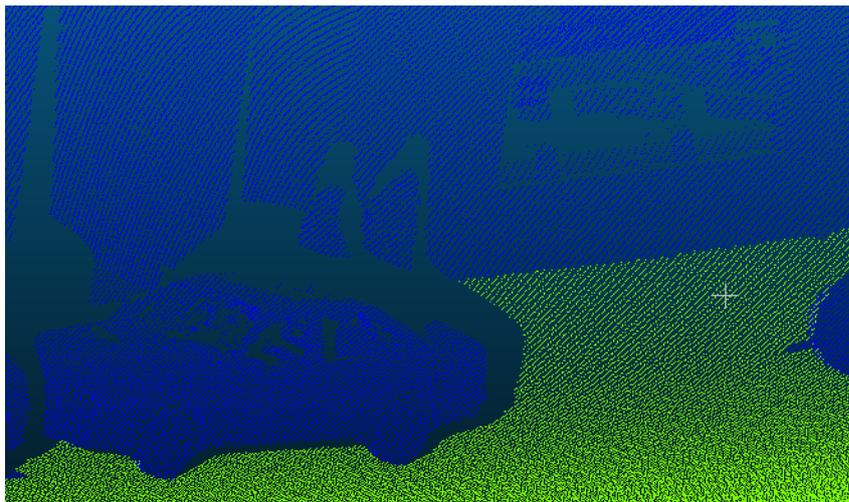


Figura 3.4: Detalle del resultado de la segmentación de la nube de puntos mediante filtro de normales en Z

El filtro K -distance permitió identificar grupos de puntos que habían sido clasificados como categorías iguales debido a sus características similares pero que realmente pertenecían a elementos y clases diferentes. De esta manera, se pudieron detectar errores en la clasificación, como el que se muestra en la figuras (3.5) y (3.6). En este caso, puntos de regiones muy concretas como las partes altas de los vehículos, que en la segmentación grosera se clasificaron como $Class2$, han sido depurados y clasificados de manera correcta.

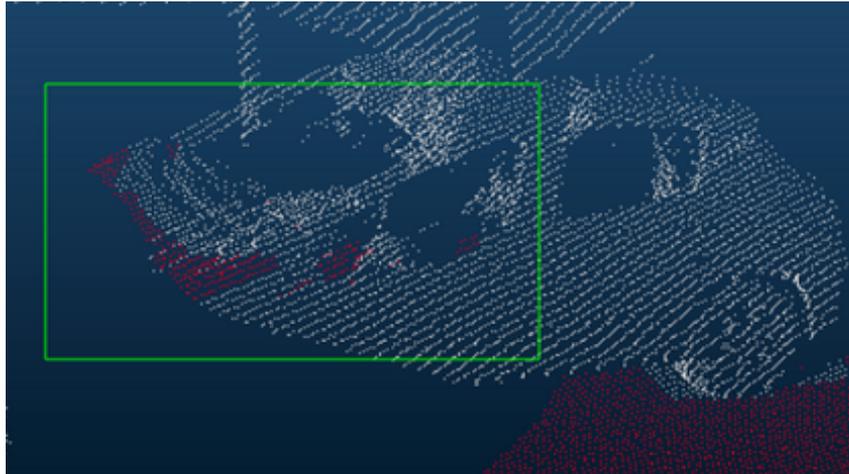


Figura 3.5: Segmentación previa a la aplicación de KD

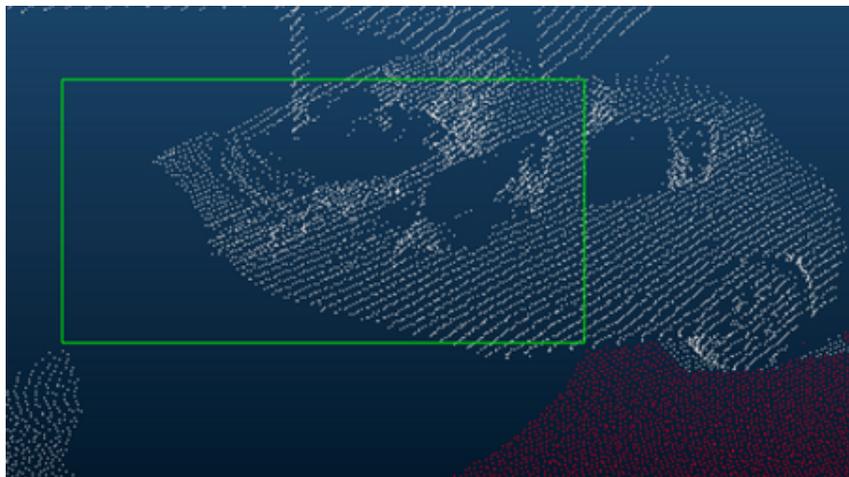


Figura 3.6: Segmentación posterior a la aplicación de KD

3.1.3. Segmentación precisa de la nube de puntos

Por último, la aplicación del *Progressive Morphological Filter (PMF)* permitió obtener una nueva segmentación, esta vez mucho más precisa que la anterior. El resultado obtenido fue una nube de puntos filtrada y segmentada desde la cual obtuvieron diferentes productos geomáticos, para emplearlos en el análisis de accesibilidad. Tal y como se muestra en las figuras (3.7) y (3.8), en las que se comparan los resultados obtenidos en la segmentación antes y después de la aplicación de los filtros mencionados, el resultado obtenido ha sido mucho más preciso que en la segmentación inicial. En esta imagen se muestra un ejemplo del resultado de la segmentación en una zona de extrema problemática como es

la parte inferior de los vehículos. En la figura (3.7) se muestran puntos pertenecientes a los vehículos que han sido clasificados como terreno mientras que en la (3.8) la clasificación es correcta.

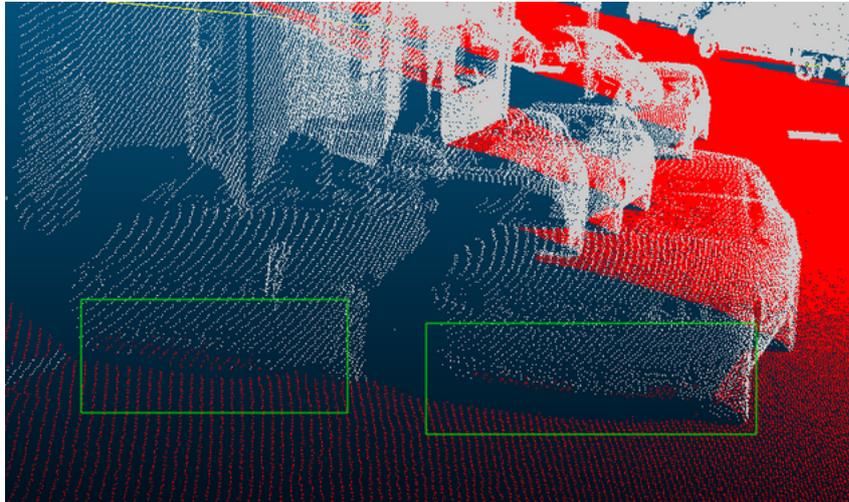


Figura 3.7: Segmentación previa a la aplicación de filtros y PMF

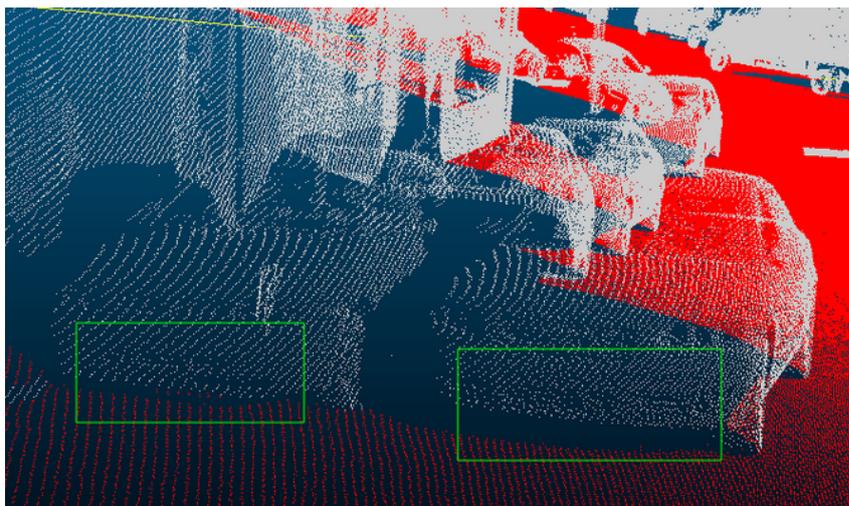


Figura 3.8: Segmentación posterior a la aplicación de filtros y PMF

3.2. Generación de productos a partir de la nube segmentada

El cálculo de HAG, en el que se estimaron diferencias de cota desde cada punto a sus vecinos, permitió identificar obstáculos para peatones y usuarios de sillas de ruedas. En la figura (3.9) se muestra la identificación de estos obstáculos, superiores a 5cm en color negro y a 25cm en color rojo, para una de las escenas analizadas. Como se puede comprobar, la mayor parte son vehículos estacionados en los márgenes de la calzada y bordillos, que suponen una limitación de accesibilidad para las sillas de ruedas. También se han identificado y ubicado con claridad las rampas y los bordillos rebajados (visualizado mediante los recuadros verdes). Sin embargo, también han quedado identificadas como obstáculos algunas fachadas de edificios o vallas de cierre de parcelas, que deben ser depuradas ya que no deben incluirse en el posterior análisis de accesibilidad.



Figura 3.9: Obstáculos para peatones y usuarios de sillas de ruedas

El MDT creado permitió identificar con detalle los puntos pertenecientes al terreno dentro del área estudiada. Para las zonas de sombra, la interpolación mediante Kriging residual ha devuelto resultados visualmente satisfactorios. En la figura (3.10) se muestra el resultado del MDT interpolado mediante Kriging residual en una de las escenas más desfavorables del área de estudio, en la que se puede comprobar que la mayor parte de las zonas de sombra han sido correctamente interpoladas. Esta capa raster es el parámetro

inicial para calcular dos superficies de fricción al desplazamiento que se incluyen en el estudio de accesibilidad: la pendiente y la rugosidad.

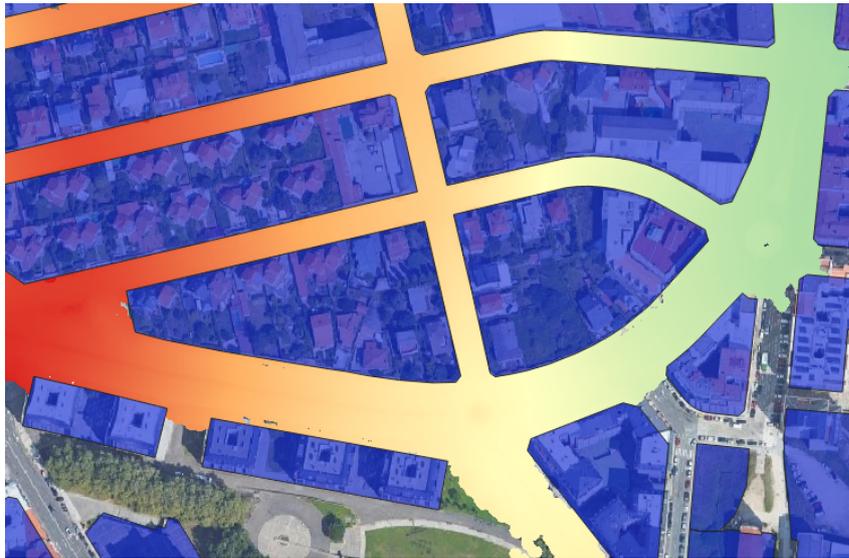


Figura 3.10: MDT interpolado mediante Kriging Residual

Las superficies de pendiente y rugosidad obtenidas, figuras (3.11) y (3.12), muestran resultados visualmente apropiados, identificando las zonas con variaciones importantes en cota, como los bordillos, medianas o rotondas, que son elementos que dificultan la accesibilidad. Sin embargo, también es notable que en algunas regiones que han sido interpoladas los resultados no son buenos, sobre todo en la superficie de rugosidad, en la que existen algunas áreas con valores de pixel demasiado altos.

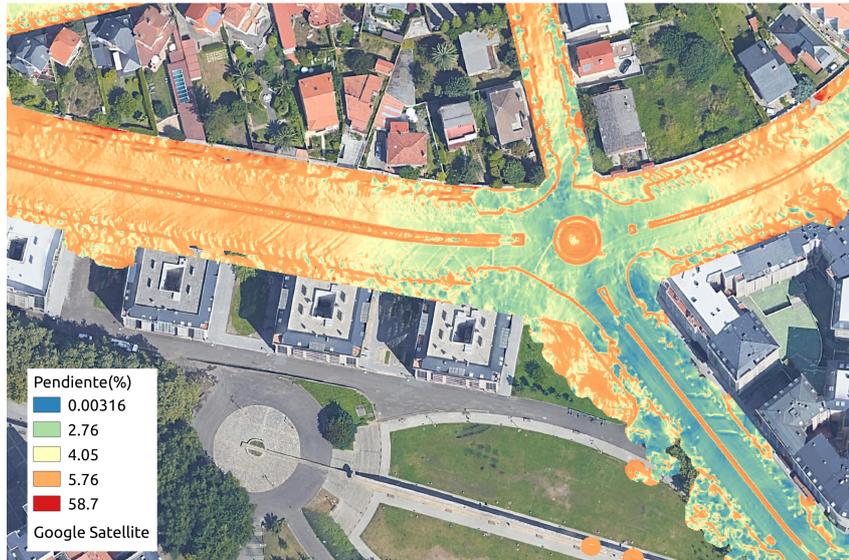


Figura 3.11: Pendiente



Figura 3.12: Rugosidad

Respecto a la identificación de los pasos de peatones, en la imagen (3.13) se pueden ver los pasos de peatones identificados, antes de su agrupamiento y en la (3.14) un detalle del resultado de los pasos una vez detectados y agrupados. Para comprobar cuantitativamente la calidad de los resultados obtenidos se ha comparado este resultado con una digitalización manual, realizada sobre los propios rasters de intensidad de cada escena estudiada. Los resultados muestran que, para un total de 33 pasos de peatones existentes en la zona de estudio, se han identificado correctamente 31 (94 %), no se han podido detectar 2 (6 %)

3.2. GENERACIÓN DE PRODUCTOS A PARTIR DE LA NUBE SEGMENTADA 27

y se han registrado 2 (6%) falsos positivos, correspondientes a dos marcas viales en los márgenes de la calzada y con valores de intensidad muy altos.

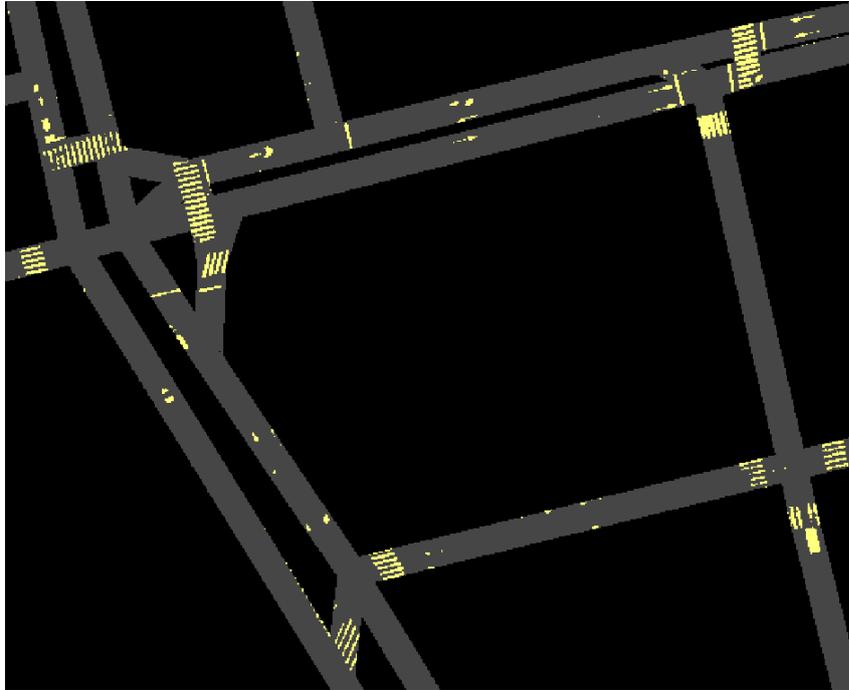


Figura 3.13: Pasos de peatones detectados

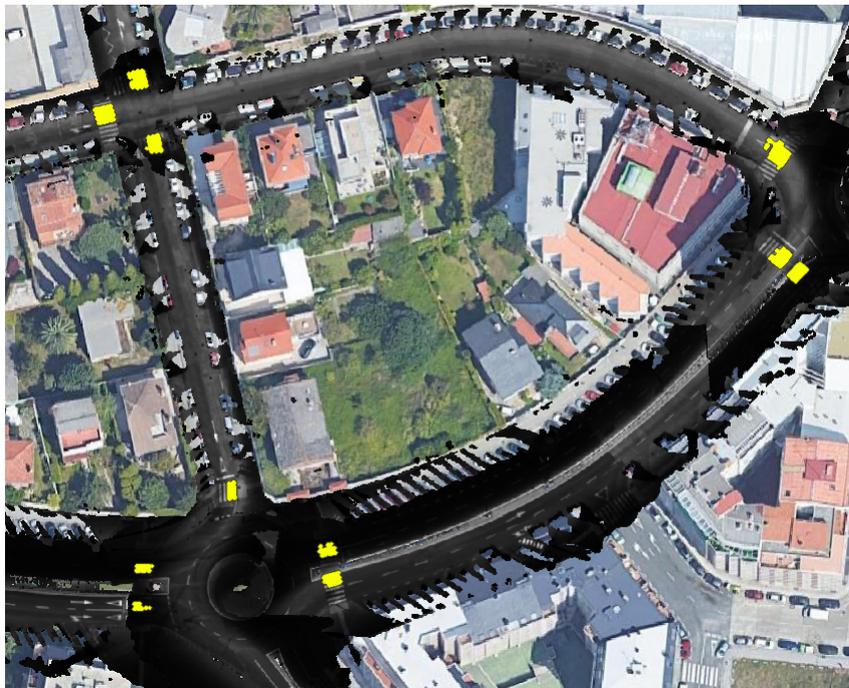


Figura 3.14: Pasos peatones agrupados

El último elemento viario que se incluyó como parámetro en el estudio de accesibilidad fue la geometría y topología de las aceras. En la figura (3.15) se muestra un detalle del resultado de su identificación automática. En color verde se muestran los tramos de acera catalogados como "acera segura" y en azul los identificados como "acera probable".



Figura 3.15: Detalle resultado de detección automática de aceras

Para la verificación de los resultados se realizó una comparativa entre la superficie de acera detectada automáticamente y la real. Para ello, se digitalizaron manualmente las aceras teniendo como base la ortofotografía proporcionada por Google Satellite en QGIS, dentro del plugin *QuickMapServices*¹. Como algunas aceras no eran perfectamente visibles en la ortofoto, debido a la falta de verticalidad en algunas zonas, se seleccionaron las cinco calles en las que la acera estaba perfectamente definida, correspondientes a las escenas LiDAR s08, s20, s24, s25 y s26. Cada acera digitalizada se asoció a una escena analizada mediante un campo nuevo en la tabla de atributos de la capa vectorial generada. Posteriormente, se recortó el raster de aceras identificadas de cada escena con el polígono de aceras digitalizadas mediante el algoritmo *Clip raster with polygon* de SAGA, se transformó a una capa vectorial de tipo polígono (*algoritmo polygonize -raster to vector*) y se cuantificó la superficie de acera detectada en las categorías '1' (acera segura) y '3' (acera probable) mediante el algoritmo *Statistics by Categories* de QGIS, para compararla con los resultados obtenidos en la digitalización manual.

¹https://plugins.qgis.org/plugins/quick_map_services/

En la tabla (3.1) se muestran los resultados obtenidos en las cinco escenas analizadas. La información contenida en ella muestra la superficie 'real' de la acera, correspondiente al área digitalizada manualmente, la cantidad de acera detectada automáticamente, en unidades de superficie y en porcentaje, y un desglose de las categorías en las que se ha clasificado esta identificación, siendo 1=acera segura y 2=acera probable.

Tabla 3.1: Resultados de la detección de las aceras

Scene	08	20	24	25	26	Total
Real (m^2)	1248.9	1657.3	1019.2	1803.2	1462.7	7191.3
Detected (m^2)	612.5	1218.7	953.6	1676.7	1319.6	5781.1
Detected (%)	49.0	73.5	93.6	93.0	90.2	80.4
Category 1 (m^2)	544.3	1081.1	856.3	1649.3	1220.2	5351.2
Category 1 (%)	88.9	88.7	89.8	98.4	92.5	92.6
Category 3 (m^2)	68.2	137.6	97.3	27.4	99.4	429.9
Category 3 (%)	11.1	11.3	10.2	1.6	7.5	7.4

Según los resultados obtenidos, el algoritmo propuesto es válido para la identificación de aceras en las escenas s24, s25 o s26, en donde los bordillos delimitan claramente las calzadas y aceras y los resultados de área detectada superan el 90%. En cambio, en la escena 20 y sobre todo en la s08, correspondiente a una calle abierta, con múltiples elementos viarios como isletas o rotondas y carriles separados por una mediana con vegetación, sólo se han podido detectar el 73.5% y el 49.0% de la superficie total de la acera, respectivamente.

3.3. Análisis de accesibilidad

La superficie de coste acumulado, figura (3.16), creada a partir de las superficies de fricción al desplazamiento hasta el centro educativo, permite identificar con claridad los elementos viarios que obstaculizan el desplazamiento y delimitar las zonas de tránsito más adecuadas para los viandantes. De la misma manera, en la figura (3.17) se muestran todos los caminos peatonales óptimos, calculados desde cada domicilio hasta el centro educativo, en este caso el colegio Fogar de Santa Margarita, trazados a partir de los píxeles con menor valor de coste acumulado de desplazamiento.



Figura 3.16: Superficie de coste acumulado

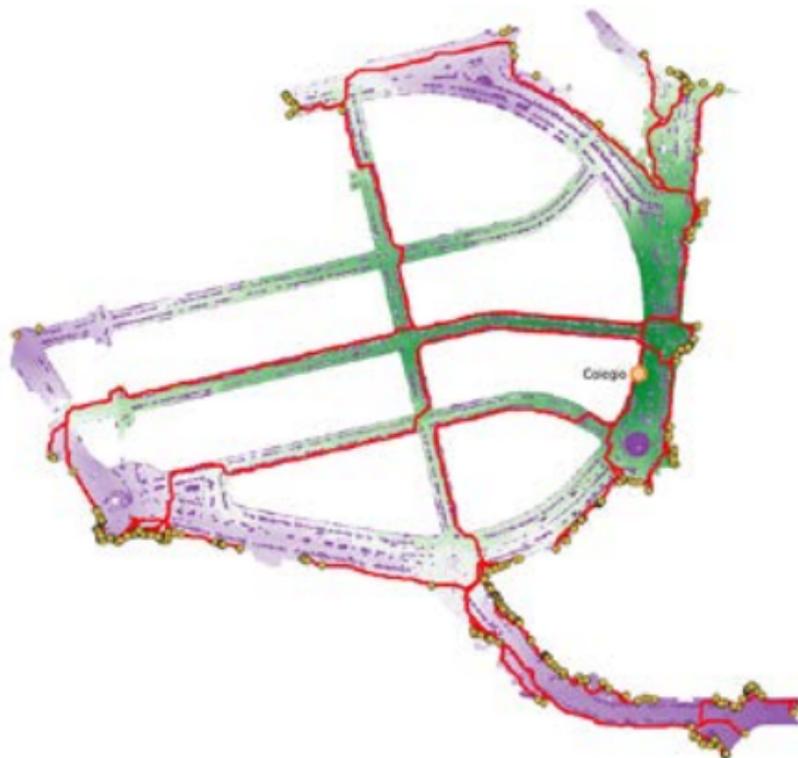


Figura 3.17: Caminos peatonales óptimos

Capítulo 4

Discusión

En el presente trabajo se plantea una metodología completa para la ejecución de un análisis de accesibilidad peatonal en áreas urbanas, que comprende todas las fases del mismo, desde la captura de los datos iniciales hasta el establecimiento de los caminos peatonales óptimos. El procedimiento conlleva la generación de diferentes algoritmos específicos para trabajar directamente sobre las nubes de puntos LiDAR, adquiridas con un sistema Mobile Mapping. Estos algoritmos permiten identificar diferentes elementos viarios que son los parámetros de partida del posterior análisis de accesibilidad.

En la primera fase del método propuesto, se ha segmentado la nube de puntos en 'terreno' y 'no terreno'. Los resultados obtenidos en las 9 calles analizadas demuestran que el algoritmo es robusto incluso en áreas con geometrías desfavorables, como escaleras o rampas. De la misma forma, la identificación de la geometría de diferentes elementos como vehículos, queda bien delimitada aunque las zonas de sombra que provocan influyen en gran medida en la identificación final del terreno. Esta nube de puntos segmentada permitirá generar los diferentes elementos que se incluirán en el posterior análisis de accesibilidad a modo de superficies de fricción al desplazamiento peatonal.

La creación del MDT a partir de los puntos identificados como 'terreno' obtuvo resultados satisfactorios en áreas con información espacial, asignando a cada pixel del MDT el valor medio de altura de los puntos pertenecientes a esa celda. Sin embargo, en zonas de sombra provocadas por vehículos u otros obstáculos, la falta de información ha obligado

a realizar una interpolación de tipo kriging residual que, si bien ha devuelto resultados visualmente satisfactorios en la mayoría de escenas analizadas, existen algunas regiones que no han podido ser totalmente interpoladas debido a la excesiva extensión de la zona de sombra. De la misma manera, es posible que algunos elementos que presentan cambios drásticos de altura, como escaleras, no sean identificados correctamente si se encuentran dentro de alguna zona de sombra. Un trabajo a futuro será la comprobación cuantitativa de los resultados obtenidos comparando la superficie obtenida con un MDT generado por levantamiento topográfico clásico, identificando todos los elementos viales inmóviles. La precisión del MDT influye directamente en la calidad de las superficies de fricción 'pendiente' y 'rugosidad' que se incluyen en el estudio de accesibilidad. En las escenas analizadas en el estudio aparecen algunas áreas con valores de rugosidad demasiado altos, mostrando una vez más la limitación debida a la falta de datos LiDAR en las aceras.

La estimación del HAG ha permitido identificar con claridad diferentes obstáculos viarios, como vehículos estacionados, además de elementos que facilitan el tránsito de los peatones y usuarios de sillas de ruedas, como rampas o bordillos rebajados, considerados fundamentales en el análisis de accesibilidad. También se observa que algunas fachadas de edificios o vallas de cierre de parcelas han quedado identificadas como obstáculos. Si bien es cierto que lo son y que no influyen en el resultado del análisis, deberían eliminarse para obtener un resultado más depurado. Estas regiones han quedado identificadas debido a que la capa vectorial de bloques de edificios no delimita exactamente con la acera y por tanto, una de las futuras mejoras a realizar en este estudio pasa por incluir en el algoritmo de análisis la ejecución de un *buffer* de algunos centímetros sobre la capa de edificios que permita eliminarlas de manera automática y no incluirlas como obstáculos en el estudio de accesibilidad.

En las fases de segmentación y clasificación de los pasos de peatones también se han obtenido resultados positivos, identificándose la mayor parte de los pasos existentes y registrando un 6% de falsos positivos, pertenecientes a marcas viales con valores de intensidad muy altos. Esta identificación ha permitido generar una capa de fricción al desplazamiento peatonal que sirve para establecer las áreas de cruce de calzada más seguras. Una posible incorporación a esta identificación pasa por la reconstrucción total de los pasos de

peatones que presenten deficiencias en su estado, sobre todo relacionados con la falta de pintura. Se debería, además, disponer de unos valores de porcentaje de superficie pintada real frente a un total de superficie de paso de peatón idealmente pintado, con lo que se podría crear un producto que permitiese identificar automáticamente aquellos pasos en mal estado de conservación y que requiriesen mantenimiento.

La clasificación de las aceras y su verificación muestran que el algoritmo propuesto para esta tarea es robusto en calles estructuradas, en las que la delimitación entre acera y calzada está claramente definida mediante bordillos. Sin embargo, en calles abiertas, con múltiples elementos geométricos diferentes como isletas o rotondas, los resultados revelan importantes errores. También es notable, a falta de una valoración cuantitativa basada en una correlación entre la superficie de sombras en una escena y la calidad de los resultados obtenidos, que las calles con menos zonas de sombra y por tanto mejor precisión del MDT debido a la menor superficie interpolada, presentan mejores resultados, tal y como ocurre en estudios como [13] o [10], en el que la precisión de los resultados está condicionada por las zonas de sombra. La verificación realizada no permite identificar falsos positivos pues la región de estudio se acota al polígono vectorial digitalizado, pudiendo identificarse falsos píxeles de acera en el exterior del polígono de estudio que no se cuantificarían. La razón de realizar esta comprobación es que resultaba difícil delimitar, sobre la nube de puntos cruda, el comienzo y final de cada escena mediante la identificación de puntos LiDAR. Sin embargo, la mejora de esta metodología de verificación es una de las líneas de trabajo abiertas en la investigación, a fin de crear un método que permita identificar la posible existencia de falsos positivos.

El resultado obtenido en el análisis de accesibilidad es satisfactorio, pues como se puede comprobar, los caminos óptimos discurren en su mayoría por aceras, pasos de peatones y evitan por completo todos los obstáculos identificados, lo que indica que la superficie de costes acumulados generada es precisa. Cabe destacar que existen algunas posibles mejoras, sobre todo en la delimitación de las aceras, que permitirán mejorar la definición de los trayectos. También es destacable la presencia de vehículos estacionados en los márgenes del viario, provocando zonas de sombra en las aceras, que han tenido que ser interpoladas provocando errores en la definición de las mismas.

Capítulo 5

Conclusiones

En este estudio se ha realizado un análisis de accesibilidad peatonal en áreas urbanas mediante la generación de diferentes superficies de fricción al desplazamiento creadas a partir del tratamiento automático de nubes de puntos LiDAR capturadas mediante *Mobile Mapping System* y otras fuentes de información geográfica.

Si bien los datos empleados en el estudio no son los más adecuados debido a la ausencia de puntos LiDAR sobre las aceras, generando múltiples y extensas zonas de sombra provocadas por la presencia de vehículos estacionados en los márgenes del viario, los resultados obtenidos demuestran la capacidad de la metodología propuesta para obtener trayectos peatonales óptimos en áreas urbanas.

Dentro de las futuras líneas de investigación abiertas en este trabajo, destacan la extrapolación y comprobación de la metodología propuesta en diferentes entornos urbanos y con diferentes nubes de puntos procedentes de MMS. Además de ello, cualquier mejora en la precisión de la clasificación de los elementos viarios empleados en el análisis o la inclusión de otros nuevos podría ayudar a mejorar la definición de los trayectos peatonales.

Este trabajo pretende ser un punto de partida para continuar analizando la movilidad escolar urbana dentro de un proyecto de tesis doctoral en desarrollo. En esta investigación se optimizarán los algoritmos de segmentación y clasificación propuestos y se completará el posterior análisis de accesibilidad a fin de identificar de manera eficaz los caminos escolares óptimos y facilitar a los centros educativos su gestión de manera autónoma.

Bibliografía

- [1] Goulette, F., Nashashibi, F., Abuhadrous, I., Ammoun, S., & Laurgeau, C. (2006). An integrated on-board laser range sensing system for on-the-way city and road modelling. *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 34(A).
- [2] Lam, J., Kusevic, K., Mrstik, P., Harrap, R., & Greenspan, M. (2010, May). Urban scene extraction from mobile ground based lidar data. In *Proceedings of 3DPVT* (pp. 1-8).
- [3] Corso Sarmiento, J. M. (2012). Levantamiento TLS como base en el análisis del trazo oculto de pinturas en geometrías complejas. RGB, Intensidad y características geométricas, como base para el estudio de las pinturas de Santa Maria de Terrassa.
- [4] M. A. Fischler, R. C. Bolles. Random Sample Consensus: A Paradigm for Model Fitting with Applications to Image Analysis and Automated Cartography. *Comm. of the ACM*, Vol 24, pp 381-395, 1981
- [5] Yuan, X., Zhao, C. X., Cai, Y. F., Zhang, H., & Chen, D. B. (2008, December). Road-surface abstraction using ladar sensing. In *Control, Automation, Robotics and Vision, 2008. ICARCV 2008. 10th International Conference on* (pp. 1097-1102). IEEE.
- [6] Jaakkola, A., Hyyppä, J., Hyyppä, H., & Kukko, A. (2008). Retrieval algorithms for road surface modelling using laser-based mobile mapping. *Sensors*, 8(9), 5238-5249.
- [7] 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(7), 1101-1110.

- [8] Oude, S. J., & Vosselman, G. (2009). 3D information extraction from laser point clouds covering complex road junctions. *The Photogrammetric Record*, 24(125), 23-36.
- [9] Boyko, A., & Funkhouser, T. (2011). *Extracting roads from dense point clouds in large scale urban environment*. *ISPRS Journal of Photogrammetry and Remote Sensing*, 66(6), S2-S12.
- [10] Vosselman, G., & Liang, Z. (2009). Detection of curbstones in airborne laser scanning data. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 38, 111-116.
- [11] Yoon, J., & Crane III, C. D. (2009, August). Evaluation of terrain using LADAR data in urban environment for autonomous vehicles and its application in the DARPA urban challenge. In *ICCAS-SICE, 2009* (pp. 641-646). IEEE.
- [12] Zhang, W. (2010, June). LIDAR-based road and road-edge detection. In *Intelligent Vehicles Symposium (IV), 2010 IEEE* (pp. 845-848). IEEE.
- [13] Rodríguez-Cuenca, B., García-Cortés, S., Ordóñez, C., & Alonso, M. C. (2016). Morphological operations to extract urban curbs in 3D MLS point clouds. *ISPRS International Journal of Geo-Information*, 5(6), 93.
- [14] Zhao, G., & Yuan, J. (2012, September). Curb detection and tracking using 3D-LIDAR scanner. In *Image Processing (ICIP), 2012 19th IEEE International Conference on* (pp. 437-440). IEEE.
- [15] Smadja, L., Ninot, J., & Gavrilovic, T. (2010). Road extraction and environment interpretation from Lidar sensors. *IAPRS*, 38, 281-286.
- [16] Hervieu, A., & Soheilian, B. (2013). Semi-automatic road/pavement modeling using mobile laser scanning. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2, 31-36.
- [17] Yang, B., Fang, L., & Li, J. (2013). Semi-automated extraction and delineation of 3D roads of street scene from mobile laser scanning point clouds. *ISPRS Journal of Photogrammetry and Remote Sensing*, 79, 80-93.

- [18] Kumar, P., McElhinney, C. P., Lewis, P., & McCarthy, T. (2013). An automated algorithm for extracting road edges from terrestrial mobile LiDAR data. *ISPRS Journal of Photogrammetry and Remote Sensing*, 85, 44-55.
- [19] Guan, H., Li, J., Yu, Y., Wang, C., Chapman, M., & Yang, B. (2014). Using mobile laser scanning data for automated extraction of road markings. *ISPRS Journal of Photogrammetry and Remote Sensing*, 87, 93-107.
- [20] Yu, Y., Li, J., Guan, H., Jia, F., & Wang, C. (2014). Learning hierarchical features for automated extraction of road markings from 3-D mobile LiDAR point clouds. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 8(2), 709-726.
- [21] Soilán, M., Riveiro, B., Sánchez-Rodríguez, A., & Arias, P. (2018). Safety assessment on pedestrian crossing environments using MLS data. *Accident Analysis & Prevention*, 111, 328-337.
- [22] Guo, J., Tsai, M. J., & Han, J. Y. (2015). Automatic reconstruction of road surface features by using terrestrial mobile lidar. *Automation in Construction*, 58, 165-175.
- [23] Liberge, S., Soheilian, B., Chehata, N., & Paparoditis, N. (2010). Extraction of vertical posts in 3D laser point clouds acquired in dense urban areas by a mobile mapping system. *International Archives of Photogrammetry Remote Sensing and Spatial Information*, 38, 126-130.
- [24] Chauhan, I., Brenner, C., Garg, R. D., & Parida, M. (2014). A new approach to 3D dense LiDAR data classification in urban environment. *Journal of the Indian Society of Remote Sensing*, 42(3), 673-678.
- [25] Serna, A., & Marcotegui, B. (2014). Detection, segmentation and classification of 3D urban objects using mathematical morphology and supervised learning. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 243-255.
- [26] ASPRS LAS Specification V1.4

- [27] Chen, Z., Devereux, B., Gao, B., & Amable, G. (2012). Upward-fusion urban DTM generating method using airborne Lidar data. *ISPRS journal of photogrammetry and remote sensing*, 72, 121-130. Chen, Y., Su, W., Li, J., & Sun, Z. (2009). Hierarchical object oriented classification using very high resolution.
- [28] 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.
- [29] Rusu, R. B., Marton, Z. C., Blodow, N., Dolha, M., & Beetz, M. (2008). Towards 3D point cloud based object maps for household environments. *Robotics and Autonomous Systems*, 56(11), 927-941.
- [30] 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(4), 872-882.
- [31] Cressie, N. (2013). *Statistics for Spatial Data*. John Wiley & Sons.
- [32] Varela-García, F.A. (2013). *Análisis geoespacial para la caracterización funcional de las infraestructuras viarias en modelos de accesibilidad territorial utilizando Sistemas de Información Geográfica (Tesis Doctoral)*. Universidade da Coruña, A Coruña.