

CLASIFICACIÓN Y CARACTERIZACIÓN DE ELEMENTOS DEL RECORRIDO PEATONAL EN UN ENTORNO URBANO MEDIANTE DATOS LIDAR

Francisco-Alberto Varela-García

Universidade da Coruña, cartoLAB, Grupo de Visualización Avanzada e Cartografía,
Departamento de Ingeniería Civil, ETS Ingeniería de Caminos, Canales y Puertos

Francisco Fernández Rivera

Universidade de Santiago de Compostela, CiTIUS, Departamento de Electrónica y
Computación

Alberto Manuel Esmoris Pena

Universidade de Santiago de Compostela, CiTIUS, Departamento de Electrónica y
Computación

David Fernández Arango

Universidade da Coruña, cartoLAB, Grupo de Visualización Avanzada e Cartografía,
Departamento de Ingeniería Civil, ETS Ingeniería de Caminos, Canales y Puertos

David López Vilariño

Universidade de Santiago de Compostela, CiTIUS, Departamento de Electrónica y
Computación

José Carlos Cabaleiro Domínguez

Universidade de Santiago de Compostela, CiTIUS, Departamento de Electrónica y
Computación

RESUMEN

La seguridad y calidad de la movilidad de los peatones en un ámbito urbano donde conviven con otros modos de desplazamiento debe ser una de las prioridades para cualquier gestor público. Para ello es fundamental disponer de una caracterización precisa de los recorridos peatonales y de los elementos urbanos que forman parte de estos recorridos, como pueden ser los pasos de cebra o los bordillos de separación entre diferentes espacios de movilidad, por ejemplo.

El presente trabajo presenta los avances en la clasificación y caracterización de algunos de estos elementos gracias al análisis de los datos obtenidos mediante un escaneo terrestre realizado por un *Mobile LiDAR Scanner* (MLS) en las calles cercanas a un colegio de la ciudad de A Coruña. Estos análisis se enmarcan dentro de las actividades desarrolladas en el proyecto BIG-GEOMOVE para el análisis de indicadores BIG GeoDATA sobre viarios urbanos para el diseño dinámico de caminos escolares seguros, y que fue financiado en 2017 por la Dirección General de Tráfico.

En este texto se muestran los procesos de tratamiento realizados sobre los datos LiDAR y los diferentes algoritmos desarrollados para clasificar la nube de puntos y diferenciar elementos urbanos importantes en los recorridos peatonales, en especial pasos de cebra y bordillos.

Además, se presentan los procesos de identificación, cálculo y análisis estadísticos de las caracterizaciones geométricas de los pasos de cebra reconocidos mediante los datos LiDAR. También se avanza en nuevas líneas de trabajo para analizar la calidad y el estado del firme de los recorridos. Los resultados alcanzados muestran un extraordinario potencial para definir con rapidez el estado de los elementos en los recorridos peatonales e identificar lugares y puntos donde es necesario realizar una actuación o mejora en comparación con el resto de elementos caracterizados.

1. INTRODUCCIÓN Y ANTECEDENTES DEL PROYECTO

Este estudio se integra dentro de los trabajos desarrollados en el proyecto denominado “Análisis de indicadores big geo-data sobre viarios urbanos para el diseño dinámico de caminos escolares seguros (BIG-GEOMOVE)” que recibió financiación de la convocatoria de 2017 de la Dirección General de Tráfico del Ministerio del Interior para subvenciones al desarrollo de proyectos de investigación en el área de tráfico, movilidad y seguridad vial. El equipo de investigación de este proyecto, además de los dos grupos redactores de esta comunicación, estaba formado por otros tres grupos de la *Universidade da Coruña* (del grupo de Ferrocarriles y Transportes, del grupo de Estudios Territoriales y del departamento de matemáticas), además del Dpto. de Sociología y Antropología de la *Universitat de Valencia*.

El objetivo principal de ese proyecto era obtener indicadores 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 centros educativos. Su definición y desarrollo parte del proyecto previo “Estudio dinámico de la movilidad escolar mediante tecnologías web de geolocalización (GEOMOVE)”, también financiado por la DGT en la convocatoria de 2015 (Varela-García et al, 2018), completando y ampliando las líneas de investigación iniciadas entonces como se recoge en la web del proyecto <http://geomove.es>. Mientras en el primer trabajo se avanzaba en técnicas de recogida de información de hábitos de movilidad en los centros escolares mediante sistemas web de participación con mapas, en este segundo proyecto se profundiza en la integración de múltiples fuentes de datos para la parametrización de las características de los viarios urbanos. Se emplearon principalmente, además de la información adquirida mediante encuestas geolocalizadas sobre movilidad (como en el proyecto previo), datos procedentes de sensores LiDAR (*Light Detection and Ranging*), imágenes satelitales adquiridas por el sensor Worldview2 con 8 bandas espectrales y resolución espacial de 50 cm, así como imágenes del Plan Nacional de

Ortofotografía Aérea con una resolución espacial de hasta 25 cm, y otras fuentes de información vectorial y raster, como OpenStreetMap, Catastro, etc., que alimentan el análisis de accesibilidad peatonal que finalmente se realizaba.

Para el cálculo de los recorridos peatonales, además de identificar obstáculos a la movilidad, se observó la necesidad de poder diferenciar en los viales, los espacios destinados al peatón, como pueden ser las aceras o los pasos de cebra. En esta línea se estableció un trabajo específico entre el grupo de Arquitectura de Computadores de la Universidad de Santiago de Compostela (USC) y el grupo de investigación sobre Visualización Avanzada y Cartografía de la Universidade da Coruña (UDC) para desarrollar una metodología que pudiese identificar los bordillos que limitan la zona peatonal de la zona destinada a los vehículos motorizados, y también pudiesen caracterizar los pasos de cebra además de identificarlos, a partir de datos LiDAR, como describiremos en este texto.

La gestión y el mantenimiento adecuado de las carreteras, independientemente de su tipología y ubicación, requiere labores de inspección periódicas a fin de verificar su correcta conservación. Aunque a nivel tecnológico se ha avanzado significativamente, la mayor parte de las labores de inspección de viario siguen realizándose de manera subjetiva, frecuentemente mediante simples controles visuales que dependen de los criterios personales de los operarios encargados. En este sentido, las administraciones responsables del mantenimiento viario demandan cada vez más una información objetiva y actualizada a fin de asegurar su correcta conservación.

La llegada de la tecnología LiDAR ha facilitado notablemente estas labores de inspección gracias a la gran capacidad para capturar datos viarios con gran rapidez y precisión geométrica. LiDAR es un sensor de teledetección activo que emite pulsos de luz polarizada entre el ultravioleta y el infrarrojo cercano (Chuvieco, 2010) empleado tanto en el estudio y la exploración atmosférica (detección de aerosoles y partículas en suspensión, humedad, temperatura, etc.) como en el análisis de la topografía terrestre, ya que permite medir distancias desde un punto emisor.

Aunque su uso es más habitual en otros campos (inventario forestal, modelado del terreno, arqueología, conservación del patrimonio, etc.), en el área de infraestructuras viarias también existe un importante número de investigaciones que estudian la caracterización de carreteras mediante el empleo conjunto de datos LiDAR e información procedente de sensores pasivos y muchas de ellas emplean exclusivamente datos LiDAR, como pueden ser estudios sobre la construcción y el mantenimiento de viales (Akay, 2003; Collins y Sitar, 2010), la actualización automática de datos de navegación 2D y 3D para aplicaciones de consumo (Jaakkola et al., 2008), o la conducción autónoma de vehículos (Bendett y Aral, 1999; Kim et al., 2015; Lee et al., 2009; Park et al., 2011), además de una línea intensa en el control geométrico de infraestructuras singulares como puentes o túneles (Chen et al., 2014; Han et al., 2013; Martínez et al., 2014).

2. METODOLOGÍA

2.1 Datos

Para analizar físicamente los viarios se han escaneado múltiples calles de A Coruña del entorno de Colegio *Fogar de Santa Margarida*, que conforman un total de 12 km de viario, adquiriendo una nube de puntos LiDAR 3D mediante un sistema de captura de datos *Mobile Mapping* (MMS) ofertado por la empresa INSITU. El MMS empleado específicamente fue el Lynx Mobile Mapper M1 de la casa Optech. El sistema permite capturar nubes de puntos en coordenadas 3D a medida que se desplaza por el viario, y consta principalmente de dos sensores LiDAR y 4 cámaras RGB que permiten medir distancias a diferentes objetos del terreno para adquirir puntos en coordenadas X, Y, Z con un rango de precisión de 8 mm, además de información añadida, como valores de intensidad de retorno, tiempo de adquisición, ángulo de escaneo, etc., para obtener una nube de puntos densa que permite caracterizar el entorno analizado.

2.2 Tratamiento automático inicial de datos LiDAR

Para identificar los elementos de interés a partir de la nube de puntos LiDAR se ha desarrollado un método que en primer lugar clasifica los puntos en las clases “suelo” o “no suelo”, con el objetivo de obtener diferentes productos geomáticos a partir de ellas, que puedan servir como parámetros de entrada en sucesivos cálculos y análisis hasta la obtención de los indicadores de accesibilidad (que no son objeto de esta comunicación).

Este proceso parte de las nubes de puntos de los dos sensores en cada una de las escenas estudiadas, y se completa mediante cuatro etapas:

- segmentación grosera de la nube de puntos en suelo/no suelo
- depuración de la nube de puntos segmentada
- segmentación precisa de la nube de puntos
- generación de productos geomáticos.

Para realizar esta tarea se ha empleado la librería de tratamiento de nubes de puntos Point Data Abstraction Library (PDAL), sobre la que se han creado diferentes procesos y plugins para realizar el tratamiento de los datos y los análisis precisos para los cálculos de recorridos óptimos. Se muestra a continuación el modelo cartográfico empleado, que puede verse en la Figura 1, y se describe el procedimiento seguido. El código empleado con más detalles está disponible en el repositorio de código de cartoLAB: <https://gitlab.com/cartolab>. El código generado puede ejecutarse directamente desde la línea de comandos en cualquier ordenador que tenga instalada una versión de PDAL. Para hacer más sencilla la ejecución del algoritmo y que cualquier usuario no experto pudiese replicar los análisis, se ha optado por implementar el algoritmo en el software QGIS, por ser una herramienta de SIG muy extendida dentro de la comunidad geomática. De esta manera se dispone de todas las funcionalidades de PDAL dentro de QGIS, mediante el plugin PDALtools y el Geomove Processing Provider.

Una decisión alternativa hubiese sido crear un plugin de procesamiento a propósito para Geomove, ganando tiempo de análisis de datos, pero optamos por mejorar QGIS para un uso más estable en el futuro, y mayor beneficio para la comunidad de usuarios. Una vez aplicadas las mejoras pertinentes en el código fuente de QGIS, se implementa el algoritmo de Geomove mediante el plugin PDALtools y el Geomove Processing Provider. PDALtools permite instalar todas las herramientas necesarias para integrar PDAL dentro de Processing Toolbox, mientras que Geomove Processing Provider instala los modelos y algoritmos empleados en el proyecto Geomove dentro del Processing Toolbox. Para replicar los análisis realizados en este estudio es requisito imprescindible tener ambos instalados, así como una versión de PDAL en el ordenador.

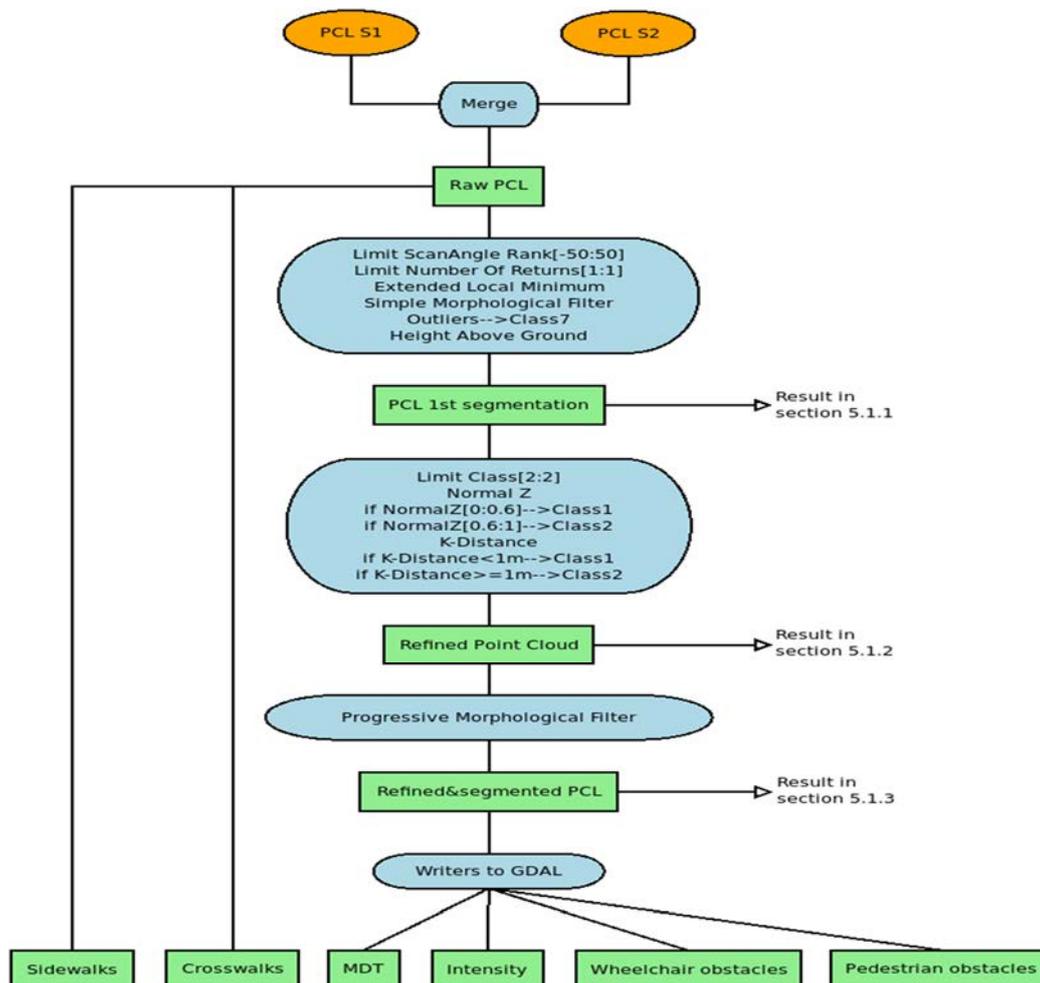


Figura 1: Modelo cartográfico empleado para la generación de la nube de puntos depurada y segmentada.

2.2.1 Segmentación grosera de la nube de puntos en suelo/no suelo

Los datos de entrada son las dos nubes de puntos crudas capturadas por los dos sensores S1 y S2 del sistema MMS, que tienen un formato de punto de tipo $P=\{x,y,z,I,ts\}$, correspondientes a las coordenadas en 3D, un valor de Intensidad y otro de *time stamp*, respectivamente.

El objetivo de esta parte del algoritmo es segmentar de forma grosera puntos que pertenecen al viario de los que no. Para ello se agruparon los puntos de la nube analizada en dos categorías numéricas "2" y "1" correspondientes a *Ground* y *Unclassified points*, según las especificaciones del estándar ASPRS para las nubes de puntos LiDAR (ASPRS las specification), a partir de ahora llamadas Class2 y Class1.

El proceso se inicia fusionando las dos nubes de puntos para conseguir una única nube [PCL]. Posteriormente se seleccionan sólo los puntos con un único retorno (se ha comprobado que pertenecen a áreas de vegetación, esquinas de edificios y retornos de cristales de vehículos, provocando problemas en la segmentación), y con un *ScanAngleRank* comprendido entre (-50,50), a fin de eliminar puntos demasiado altos que no interesan para la identificación de elementos viarios. Sobre estos puntos se aplican un *Extended Local Minimum Filter* (Chen, 2012) para identificar ciertos puntos como ruido y un *SimpleMorphologicalFilter* (Pingel, 2013) para obtener una nube segmentada en puntos de suelo y no suelo.

Se seleccionan los puntos pertenecientes a no suelo Class1, se les aplica un filtro *Outlier-Statistical Method* (Rusu, 2008) para identificar puntos con valores atípicos y se les asigna un valor de Class7 (*low point-noise*). Por último, sobre los puntos de Class2, se calcula la *Height Above Ground* (HAG), que es un valor de altura relativa desde cada punto respecto a sus vecinos. Este cálculo se realiza iterando sobre todos los puntos, encontrando el vecino más cercano en planimetría entre los puntos del terreno y calculando la distancia entre los dos valores de la componente Z.

2.2.2 Depuración de la nube de puntos segmentada

En este proceso se filtra la nube de puntos anterior, como paso previo a una segmentación más precisa. El primer paso es aplicar un filtro de normales. Se seleccionan sólo los puntos de suelo y se calcula el vector normal en las componentes x,y,z a cada punto en función de sus 30 vecinos más próximos. Con la aplicación del filtro de normales en la componente Z se identifican de manera clara los puntos de transición entre el terreno y los planos verticales. En la Figura 2 se muestran en color rojo los puntos pertenecientes al terreno Class2, en azul los no clasificados, Class1, y en verde las regiones de transición, que son el objeto de estudio en este paso del algoritmo.

Si la normal en la componente z está dentro del intervalo (0, 0.6) se considera que es bastante horizontal y por tanto el punto se asigna a un elemento vertical (fachada de edificio, obstáculo, etc.) con Class1. En el caso de que los puntos tengan una normal en la componente z prácticamente vertical (0.6, 1) se tomarán como puntos de terreno con Class2.

El siguiente paso es calcular *K-distance*. Sobre los puntos Class2 se calcula la distancia euclídea desde cada punto analizado a sus "k" vecinos (en este caso k=300) mediante el filtro *K-distance*.

Se establece que si esta distancia entre ellos es inferior a 1m, los puntos pertenecen a una misma clase (Class2) y si la distancia es superior, pertenecerán a clases diferentes y por tanto se asignan a Class1.

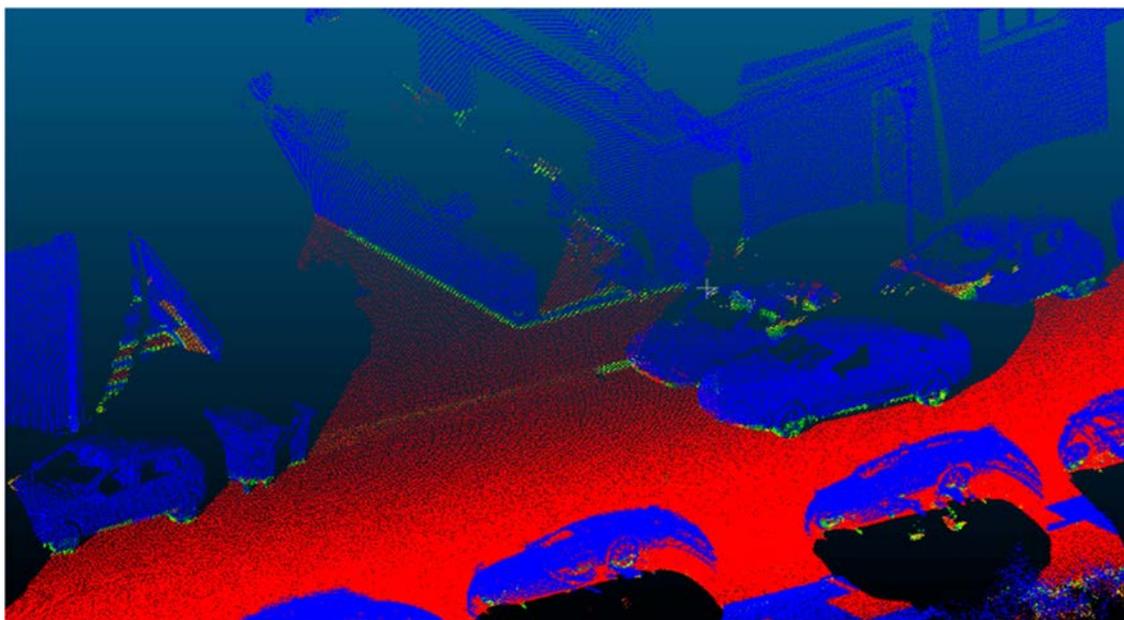


Figura 2: Cálculo del vector normal en la componente Z de cada punto de la nube.

2.2.3 Segmentación precisa de la nube de puntos

Se realiza la última segmentación de la nube de puntos ya filtrada mediante la aplicación de un *Progressive Morphological Filter* que permite segmentar puntos de suelo y no suelo mediante la implementación del método descrito en (Zhang, 2003).

2.2.4 Generación de productos geomáticos

Con la nube de puntos filtrada y adecuadamente segmentada se generan diferentes productos geomáticos, que son la base para crear las superficies de fricción al desplazamiento peatonal en el análisis de accesibilidad. Se generan cuatro archivos en formato raster con un tamaño de pixel de 18 cm: MDT, raster de intensidad, raster de obstáculos para peatones y raster de obstáculos para usuarios de sillas de ruedas. El MDT y el raster de intensidades tienen como valores de pixel las alturas e intensidades medias, respectivamente, de los puntos que se encuentran sobre dicho pixel. En ciertas escenas existen gran cantidad de vehículos aparcados en los laterales de la calzada que provocan zonas de sombra en las nubes de puntos LiDAR y que dificultan enormemente la labor de identificar con precisión la geometría de las aceras. Para solucionar este problema se ha optado por realizar una interpolación cuyo procedimiento no es objeto de esta comunicación.

Para generar los rasters de obstáculos para peatones y usuarios sillas de ruedas se han identificado y rasterizado todos los puntos cuyos valores de HAG están comprendidos entre 5 y 220 cm. Se ha considerado que todos los puntos con $HAG \geq 5$ cm son obstáculos para usuarios de sillas de ruedas y $HAG \geq 25$ cm para peatones.

Además de estos productos generados a partir de la nube de puntos filtrada y depurada, también se ha identificado la ubicación de los pasos de peatones y de los bordillos o delimitaciones calzada-acera, en este caso directamente desde las propias nubes de puntos LiDAR, como detallaremos a continuación.

2.3 Tratamiento automático específico de datos LiDAR

El tratamiento de los datos LiDAR ha sido sin duda el que ha significado un mayor número de horas de trabajo y esfuerzo realizado en este proyecto BIG-GEOMOVE, tanto en los procesos ya comentados, como en otros análisis pormenorizados de los parámetros ofrecidos por la nube de puntos de escaneo láser.

Entre ellos cabe destacar los implementados especialmente para la detección de pasos de peatones y la identificación de bordillos que delimiten convenientemente las aceras y ayuden a definir la zona de desplazamiento peatonal diferenciada de la calzada para los vehículos motorizados.

Los avances realizados han sido muy significativos en ambos casos, así como en otros procesos de detección e identificación de elementos de interés para los desplazamientos a pie, y por ello se han generado y se están generando distintos TFG y TFM con magníficos resultados en distintas líneas de investigación. Aquí expondremos brevemente una parte de estos estudios.

Un reto de estos análisis es la reducción del alto coste computacional del procesamiento de nubes de puntos LiDAR terrestre, donde se pueden alcanzar fácilmente densidades de varios cientos de puntos –e incluso miles– por metro cuadrado.

Debido a la propia naturaleza de los datos, el tratamiento de los mismos implica realizar un gran número de operaciones para llevar a cabo las tareas de segmentación y clasificación, por lo que se recurre a técnicas del ámbito de la computación de altas prestaciones, y se utiliza la infraestructura del Centro de Supercomputación de Galicia (CESGA) para realizar algunos de los procesamientos.

El punto de partida de este trabajo es un código secuencial que recibe como entrada los datos obtenidos tras la segmentación de la nube de puntos LiDAR, a partir de los métodos ya comentados, así como de los análisis de segmentación de datos LiDAR terrestre aplicada a seguridad vial implementados por (Soutullo, 2018) dentro del grupo de la USC.

El programa implementado se encarga de procesar los datos para realizar labores de detección de pasos de cebr y bordillos en entornos urbanos siguiendo un flujo de trabajo basado en la aplicación de distintas etapas de procesamiento consecutivas, obteniendo dos nubes de puntos (*bounding boxes* y elementos viales), que son:

- Algoritmo de adyacencia: Algoritmo que itera sobre la nube de puntos y marca aquellos que son susceptibles de pertenecer a un bordillo. Se basa en la suposición de que los bordillos son adyacentes a terreno (puntos cuya planaridad hace suponer que pertenecen a aceras o carreteras).
- Cálculo de línea virtual: Obtención de una línea compuesta por puntos ajenos a la nube de puntos que se ajusta a la geometría de un bordillo dado.
- Proporcionalidad por tipo de punto: Etapa que descarta grupos etiquetados como señales horizontales cuya proporción de puntos propiamente de señal supera un umbral dinámico.
- Generación de datos de bounding boxes: El principal uso de las bounding boxes consiste en envolver las señales horizontales para realizar un análisis local de las mismas, gracias al cual es posible identificar individualmente las franjas de los pasos de cebra.
- Generación de datos completos: Transformar los datos de pasos de cebra y bordillos a un formato interpretable para su visualización (especialmente usándose el visualizador “Olivia” desarrollado por el grupo de la USC).
- Otros procesamientos: Cálculo de diferentes parámetros asociados a los elementos identificados, como por ejemplo datos geométricos de los mismos (longitud, ancho, pendiente, etc.) para la caracterización final de los elementos clasificados.

En la Figura 3 se observa la nube de puntos LiDAR en una escena del viario estudiado, mostrando la zona según intensidad en la figura de la izquierda, y en la figura de la derecha se identifican con color morado las bandas del paso de cebra y con color blanco la alineación de los bordillos.

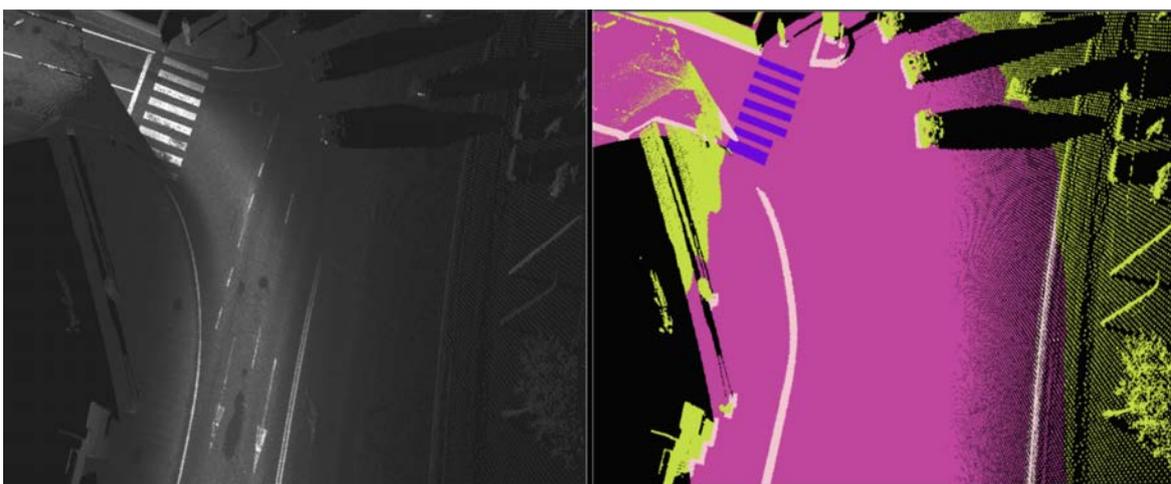


Figura 3: Ejemplo de identificación de paso de cebra y bordillos.

3. RESULTADOS

Aunque seguimos trabajando en la mejora técnicas ya se han obtenido resultados satisfactorios en diferentes entornos geográficos, a partir de distintas escenas de nubes de puntos LiDAR. En el caso de las calles del entorno del colegio de A Coruña, se han conseguido identificar los 37 pasos de cebra existentes, aunque las características de los mismos han hecho que su caracterización no siempre pudiese corresponderse con las geometrías de los mismos. En la Figura 4 puede verse la localización de estos pasos de peatones, identificando aquellos que presentan mejores resultados en cuanto a la geometría final obtenida de forma automática en el proceso de clasificación.

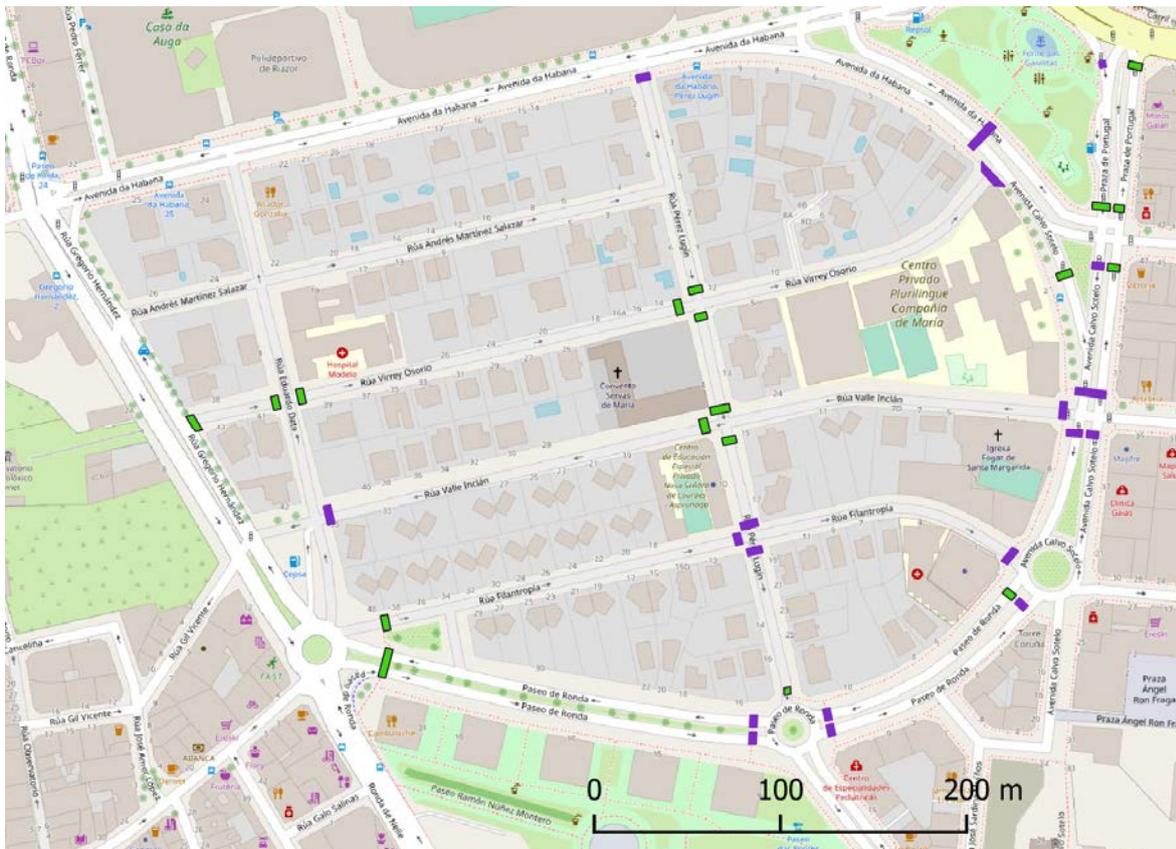


Figura 4: Mapa de localización de los 37 pasos de cebra identificados. En verde aparecen los que consiguen una geometría final similar a la existente y en morado los que presentan algún tipo de problema.

Los problemas de definición final de los pasos de cebra hemos comprobado que no son debidos a deficiencias en el proceso de identificación empleado, sino a las irregularidades y deficiencias presentes en estos elementos de señalización vial, como podemos observar en los ejemplos mostrados en la Figura 5. En general se deben a pérdida de calidad en la pintura de las bandas del paso de cebra, pero también nos encontramos con problemas adicionales cuando hay un cambio de pavimento en el entorno del paso de cebra, o en parte de él, lo que provoca intensidades muy altas de alguna zona del firme.

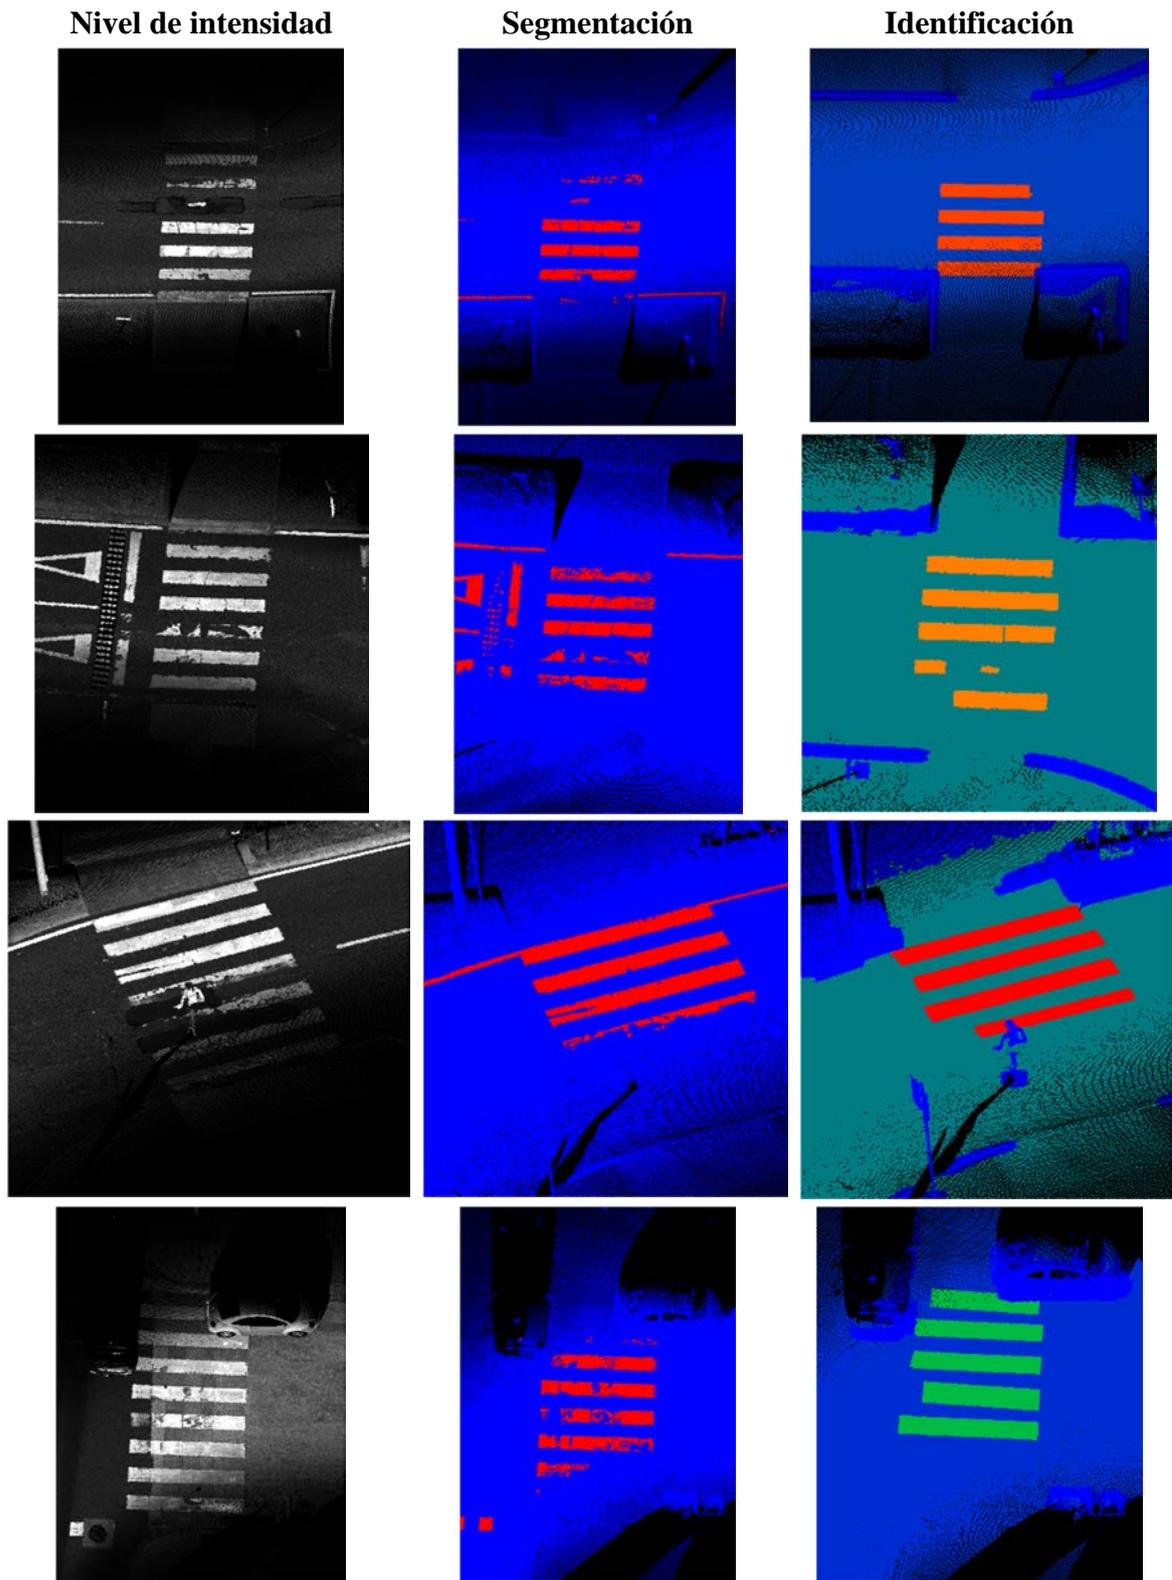


Figura 5: Ejemplos de pasos de cebra no caracterizados en su globalidad debido a distintos factores. Se presentan 3 imágenes de cada paso de cebra, para ver su nivel de intensidad, su segmentación y la detección final realizada.

Además, podemos observar como la presencia de un peatón, o de un vehículo sobre el paso de cebra, imposibilita la reconstrucción completa de parte de este elemento.

Sin embargo, lo que podría considerarse un problema en una primera interpretación de los resultados, creemos que esta circunstancia permite que con el sistema de análisis empleado, no sólo se puedan identificar los pasos de cebra de forma automática en una nube de puntos LiDAR, sino que se puedan clasificar automáticamente aquellos pasos de cebra que presentan irregularidades en su estado. Este hecho, sin duda es de especial interés para cualquier gestor o administrador de la integridad de la señalización viaria, especialmente en ámbitos urbanos, para conocer el grado de calidad de los pasos de cebra de una forma eficiente y objetiva, y poder plantear con ello medidas paliativas para solucionar los problemas detectados.

Pero el proceso de identificación automática de los pasos de cebra, también nos ha permitido caracterizar ciertos parámetros de cada uno de estos elementos de señalización viaria horizontal. Estos parámetros se corresponden tanto con los valores de los datos obtenidos directamente por el LiDAR, como la intensidad o el ángulo de incidencia, como de las métricas calculadas a partir de las coordenadas X, Y, Z de los puntos que caracterizan un paso de cebra, y cada una de sus bandas. Así, podemos obtener el ancho y la longitud de cada paso de peatones, y de cada una de sus bandas de pintura, la pendientes longitudinal y transversal de estos elementos, la diferencia de altura con las aceras de sus extremos, los valores estadísticos (medio, máximo, mínimo, desviación, etc.) de cada valor de intensidad o ángulo de incidencia de todos los puntos LiDAR que forman cada elemento, indicadores calculados a partir de esos datos, como la rugosidad o calidad de la pintura, y un largo etcétera. A modo de ejemplo, se incluye una Tabla 1 con las características más significativas de los pasos de cebra que se consideraron bien clasificados con respecto a los existentes.

PARÁMETRO CALCULADO	VALOR
Media del área real medida	31,85
Media del área calculada	32,19
Longitud media del paso de cebra	7,88
Ancho medio del paso de cebra	4,07
Relación media entre longitud y anchura	1,93
Número medio de barras	8,15
Longitud entre el número de barras	0,97
Longitud máxima de una barra	4,05
Ancho máximo de una barra	0,65
Longitud mínima de una barra	1,49
Ancho mínimo de una barra	0,38
Longitud media de una barra	3,82
Ancho medio de una barra	0,54
Relación media entre longitud y anchura por barra	7,04
Calidad media de la pintura por barra (máx 1)	0,91
Intensidad media por barra	2197,34
Intensidad máxima por barra	3446,03
Intensidad mínima por barra	400,84
Desviación estandar de la intensidad por barra	491,59

Tabla 1: Resumen de parámetros obtenidos sobre los 18 pasos de cebra bien caracterizados.

Además de estos análisis, también se iniciaron procedimientos para la identificación de obstáculos en el recorrido peatonal (farolas, árboles, papeleras, etc.) con el objetivo de definir espacios donde el peatón pueda desplazarse, y lugares donde la movilidad es imposible o presenta limitaciones. En este sentido, también se está estudiando la identificación de deficiencias en el pavimento mediante el análisis de la nube de puntos LiDAR, observándose incluso ligeras anomalías en ciertas zonas de las calles, por lo que sería posible no sólo detectar baches consolidados, sino también aquellas regiones del pavimento donde están empezando a formarse desperfectos significativos, y calcular las características de los mismos (longitudes, profundidades, volúmenes de deterioro, etc.).

4. CONCLUSIONES

La integración de diferentes fuentes de datos para el análisis y gestión de las infraestructuras viarias debe ser una línea de investigación importante en los próximos años, pues las posibilidades que ofrecen los nuevos sensores de captura de datos geográficos mediante técnicas de teledetección (LiDAR, radar, imágenes multiespectrales, etc.) amplían enormemente las posibilidades de identificación, clasificación y caracterización de cualquier elemento territorial. La coordinación de diferentes grupos de investigación, combinando conocimientos en tecnologías diversas y experiencias y capacidades compatibles para abordar estudios diferentes sobre infraestructuras viarias, debe ser también potenciada para encontrar nuevas líneas de análisis.

El ejemplo mostrado en este texto, es sólo una muestra de las iniciativas que con tiempo y recursos, se podrían conseguir para disponer de métodos rápidos y eficaces para aumentar las capacidades de gestión de los siempre complicados procesos de conservación y mantenimiento de las infraestructuras, especialmente las viarias.

Los resultados alcanzados en la identificación y caracterización de bordillos y pasos de cebra, así como de otros elementos relacionados con los recorridos peatonales en zonas urbanas, muestran unos niveles de eficiencia de alto interés para seguir avanzando en las líneas de investigación marcadas desde un proyecto financiado inicialmente por la DGT. Además, los problemas identificados abren líneas de mejora en las características de obtención de los datos, que podrían ser implementadas en futuros trabajos.

AGRADECIMIENTOS

Debemos agradecer la financiación conseguida en la convocatoria de subvenciones a proyectos de investigación 2017 de la DGT con el proyecto de referencia SPIP2017-02340 con el título de “Análisis de indicadores big geo-data sobre viarios urbanos para el diseño dinámico de caminos escolares seguros (BIG-GEOMOVE)” que ha servido de base para gran parte de los análisis mostrados en esta comunicación.

Además, parte de este trabajo ha recibido el soporte de la Consellería de Educación, Universidade e Formación Profesional de Galicia a través de la acreditación ED431G-2019/04 y del grupo competitivo ED431C-2018, y por el Ministerio de Economía y Competitividad con el proyecto PID2019-104834GB-I00 y fondos FEDER.

REFERENCIAS

AKAY, A. E. (2003). Minimizing total cost of construction, maintenance, and transportation costs with computer-aided forest road design (Doctoral dissertation).

BENDETT, M. P., & ARAL, A. Y. (1999). U.S. Patent No. 5,875,408. Washington, DC: U.S. Patent and Trademark Office.

CHEN, S. E., ET AL. (2014). 3D LiDAR scans for bridge damage evaluations. *Bridges*.

CHEN, Z., ET AL. (2012). "Upward-Fusion Urban DTM Generating Method Using Airborne Lidar Data." *ISPRS Journal of Photogrammetry and Remote Sensing* 72 (2012): 121–130.

CHUVIECO, E. (2010). Teledetección ambiental. La observación de la Tierra desde el espacio. Barcelona: Ariel.

COLLINS, B. D., & SITAR, N. (2010). Stability of steep slopes in cemented sands. *Journal of geotechnical and geoenvironmental engineering*, 137(1), 43-51.

ESMORÍS, A. (2019). Detección y caracterización de bordillos y pasos de cebra con nubes de puntos de LiDAR terrestre. TFM del Máster de computación de altas prestaciones (USC). Tutores David López Vilariño y José Carlos Cabaleiro.

FERNÁNDEZ, David. (2019). Indicador Integrado Multiparamétrico (IIM) para la caracterización de espacios peatonales en áreas urbanas a partir de la integración de datos LiDAR procedente de Mobile Mapping System con otras fuentes de información. TFM Universidad Salamanca.

HAN, J., ET AL. (2014). Road boundary detection and tracking for structured and unstructured roads using a 2D LiDAR sensor. *International Journal of Automotive Technology*, 15(4), 611.

KIM, J. K., ET AL. (2015). Experimental studies of autonomous driving of a vehicle on the road using LiDAR and DGPS. In *Control, Automation and Systems (ICCAS), 2015 15th International Conference on* (pp. 1366-1369). IEEE.

JAAKKOLA, A., ET AL. (2008). Retrieval algorithms for road surface modelling using laser-based mobile mapping. *Sensors*, 8(9), 5238-5249.

LEE, J. Y., ET AL. (2009). The development of a map building algorithm using LADAR for unmanned ground vehicle. *Journal of Institute of Control, Robotics and Systems*, 15(12), 1246-1253.

- MARTÍNEZ M., R., ET AL. (2014). Application of Airborne LiDAR to the Determination of the Height of Large Structures. Case Study: Dams. *Revista Facultad de Ingeniería Universidad de Antioquia*, (70), 45-53.
- PARK, J. U., ET AL. (2011). The Research of Unmanned Autonomous Navigation's Map Matching using Vehicle Model and LIDAR. *Journal of Institute of Control, Robotics and Systems*, 17(5), 451-459.
- PINGEL, T. J., ET AL. (2013). "An Improved Simple Morphological Filter for the Terrain Classification of Airborne LIDAR Data." *ISPRS Journal of Photogrammetry and Remote Sensing* 77: 21–30.
- RUSU, R. B., ET AL. (2008). "Towards 3D point cloud based object maps for household environments." *Robotics and Autonomous Systems* 56.11: 927-941.
- SOUTULLO, S. (2018). Segmentación de datos LiDAR terrestre aplicada a seguridad vial, Trabajo de Fin de Grado, Escuela Técnica Superior de Ingeniería de la Universidad de Santiago de Compostela.
- VARELA-GARCÍA, F.A., Fernández Arango, D., Novales Ordax, M., Orro Arcay, A., Gutiérrez Puebla, J. (2018). Estudio dinámico de la movilidad escolar mediante Tecnologías web de Geolocalización. XIII Congreso de Ingeniería del Transporte, Gijón.
- ZHANG, K., ET AL. (2003). "A progressive morphological filter for removing nonground measurements from airborne LIDAR data." *Geoscience and Remote Sensing, IEEE Transactions on* 41.4: 872-882.