

SEGMENTACIÓN 3D RÁPIDA APLICADA A LA DETECCIÓN DE ELEMENTOS ORNAMENTALES EN NUBES DE PUNTOS DEL PATRIMONIO CULTURAL

Santiago Salamanca, Pilar Merchán, Emiliano Pérez, María José Merchán y María Dolores Moreno
Universidad de Extremadura. Escuela de Ingenierías Industriales. Avda. de Elvas s/n. 06006 Badajoz. Spain,
{ssalamanca, pmerchan, emilianoph, mjmerchan, mdmorenorabel}@unex.es

Antonio Adán

Escuela Superior de Informática. Universidad de Castilla la Mancha. Paseo de la Universidad, 4. 13071
Ciudad Real. Spain. Antonio.Adan@uclm.es

Resumen

En este trabajo se presenta un procedimiento de segmentación de datos 3D pertenecientes a obras del patrimonio cultural. El objetivo es, en primer lugar, que el algoritmo sea capaz de separar las zonas ornamentales de las no ornamentales y, en segundo lugar, que el procedimiento sea rápido. Para ello se ha propuesto un método que realiza la segmentación en dos etapas, una primera en la que agrupa zonas en función de la pertenencia de los puntos a planos, y la segunda que usa tres características que son usadas por el algoritmo k-medias para obtener la segmentación definitiva. El procedimiento se ha probado en varias nubes de puntos 3D reales.

Palabras clave: segmentación 3D, nubes de puntos, escáneres láser.

1 INTRODUCCIÓN

Las nubes de puntos 3D que proporcionan los escáneres láser terrestre (TLS, de sus siglas en inglés) pueden ser usadas como datos en tareas clásicas de la visión por computador como, por ejemplo, la segmentación, que es el objetivo de este trabajo. Las diferencias con respecto al caso de usar imágenes son, sin embargo, muy grandes.

Una de esas diferencias aparece por la propia naturaleza de los datos. En una imagen se dispone de la información propia o intrínseca, es decir, el valor de nivel de gris o el color, y también la relación topológica entre esos valores, o lo que es lo mismo, la relación de vecindad entre los píxeles. En una nube de puntos sólo se dispone del valor propio de los datos, que son las coordenadas geométricas con respecto a un sistema de referencia, de cada uno de los puntos de la nube.

Otra diferencia importante está referida a la información que proporcionan los sensores en cada caso. Como se ha dicho, en las imágenes se trabaja con niveles de grises o color, mientras que en las nubes de puntos se trabaja con coordenadas geométricas. Los niveles de grises o de color pueden ser empleados directamente para segmentar, detectar características, etc. Sin embargo, las coordenadas geométricas no son útiles *per se*, siendo necesario determinar a partir de ellas otro tipo de información, como puede ser la curvatura, los vectores normales, etc. que sí puedan ser empleados en las tareas comentadas anteriormente.

Por último, hay que indicar otro factor, que es la cantidad de información que se maneja en cada caso, siendo la existente en las nubes de puntos 3D mucho mayor y de mayor complejidad, como ha quedado patente en los párrafos previos, que la existente en las imágenes. Esto hace que el tiempo necesario para la obtención de resultados sea mucho mayor en el caso de las nubes de puntos 3D.

En el caso de la segmentación de nubes de puntos 3D, es habitual hacer una estimación de los vectores normales, o de otros valores asociados con esa estimación, de cada uno de los puntos de la nube 3D y segmentar a partir de dicha información. Por ejemplo, Demantké *et al.* [1] estiman, mediante el cálculo de componentes principales (PCA), los autovalores de la matriz de covarianza. Estos autovalores los emplean para caracterizar a cada punto como perteneciente a una estructura lineal, plana o volumétrica. Además, mediante el cálculo de la entropía del conjunto de puntos, a distintas distancias del punto 3D que se esté estudiando, proporcionan el conjunto óptimo de datos para dicho punto. Aunque el trabajo es interesante y resuelve parcialmente uno de los problemas que habíamos citado, la no existencia de relaciones topológicas, el algoritmo propuesto por los autores es tan costoso computacionalmente que lo hace inabordable. Nurunnabi *et al.* [2] presentan un procedimiento basado en una variante del PCA que es el diagnóstico robusto de PCA (RDPCA, de sus siglas

en inglés). Esta variante del PCA permite estimar las normales, como su propio nombre indica, de forma robusta y más rápida que la propia PCA. A partir de estos datos y de varias heurísticas segmentan los datos 3D, que en el caso presentado son sintéticos y reales, aunque estos últimos de baja complejidad.

Otra forma de abordar la segmentación de las nubes de puntos 3D consiste, como paso previo, en la determinación del volumen, discretizados con vóxeles, que contiene a esos datos. De esta manera se consigue definir una relación topológica similar a la existente en las imágenes, siendo el vóxel el equivalente del píxel. Por ejemplo, en un trabajo bastante reciente, Xu *et al.* [3] proponen un método en el que parten de la estructuración de la nube de puntos mediante vóxeles determinados mediante octrees. A cada uno de estos vóxeles se le asignan características basadas en la normal del vóxel y su centroide y, por último, mediante modelos probabilísticos se particiona el espacio 3D para finalizar la segmentación. Los resultados y el tiempo de computación parecen ser razonables. Una variante para la estructuración de los datos es la de emplear estructuras 2D en vez de estructuras 3D, como son los vóxeles. En [4], Börcs *et al.* definen un grid 2D multiresolución en el que proyectan los datos adquiridos con un Velodyne HDL-64E S2 para realizar una segmentación en tiempo real. Este procedimiento, sin embargo, está muy limitado por el tipo de sensor empleado, siendo difícil adaptarlo a otros tipos de escáneres láser. En [5] los mismos autores propone una variante del método para la detección instantánea de vehículos y peatones.

En este trabajo se muestran los primeros resultados de un algoritmo de segmentación de nubes de puntos 3D. Los datos con los que se trabajarán serán los adquiridos con sensores láseres 3D de medio alcance en entornos de patrimonio cultural. El objetivo del algoritmo es que sea capaz de separar las zonas de interés de las de no interés, entendiendo por zona de interés a aquellas zonas ornamentales o perteneciente al estilo arquitectónico en cuestión. Además, es necesario que el tiempo de ejecución sea lo suficientemente pequeño como para permitir resolver el problema de forma eficiente.

El trabajo se divide en los siguientes apartados. En la sección 2 se indicarán y explicarán someramente las partes en las que se divide el algoritmo. En el apartado 3 se describirá de forma concreta cada una de las etapas que se habían desgranado en la sección 2. En la sección 4 mostraremos algunos resultados experimentales. Por último, en la sección 5 mostraremos las conclusiones y las mejoras que hay que realizar al algoritmo en futuros trabajos.




Figura 1: Diagrama de flujo del proceso de segmentación 3D propuesto.

2 VISIÓN GENERAL DEL ALGORITMO DE SEGMENTACIÓN 3D.

En la figura 1 se muestra el diagrama de flujo seguido en el método de segmentación propuesto. Como se puede observar, el algoritmo trabaja directamente con las coordenadas 3D de las nubes de puntos, sin estructurarlos mediante vóxeles o mallas 2D. Esto mejora su velocidad, ya que no es necesario voxelizar el espacio.

Por otro lado, el proceso se puede dividir en tres etapas:

- Etapa de lectura y preparación de datos, que se corresponde con las dos primeras tareas del diagrama de flujo.
- Etapa de agrupación basada en planos, que se realiza mediante el bucle representado en la figura 1.
- Etapa de agrupación basada en características, que se corresponde con los pasos que se realizan tras la finalización del bucle.

En la sección siguiente se explica con más detalle cada una de estas etapas.

3. SEGMENTACIÓN 3D

Como se ha comentado anteriormente, la segmentación se realiza siguiendo el diagrama de flujo de la figura 1 que, a su vez, se subdivide en tres etapas.

3.1 ETAPA DE LECTURA Y PREPARACIÓN DE DATOS.


En esta etapa se carga en memoria la nube de puntos 3D, que se denotará como \mathcal{V} . Como se ha explicado en la introducción, esta nube de puntos está formada solo por el conjunto de coordenadas 3D y no dispone de ninguna información topológica que relacione a los puntos entre sí. Además, es necesario generar alguna información que sea útil para ser empleada en el proceso de segmentación.

Esta información “útil” serán los vectores normales a cada uno de los puntos de la nube de puntos. En concreto, estas normales, que denotaremos como \mathcal{N} , son las del plano que mejor se aproxima al punto en cuestión y los seis puntos más cercanos a él.


3.2 ETAPA DE AGRUPACIÓN BASADA EN PLANOS

La segunda fase de segmentación consiste en determinar qué puntos de la nube de puntos se aproximan más al plano definido por uno de los vectores normales determinados en la etapa anterior.

Para ello se parte de un punto aleatorio, $p_i \in \mathcal{V}$, y se consulta el valor de su normal, $n_i \in \mathcal{N}$. Esta normal, junto con la nube de puntos \mathcal{V} es empleada como



(a)



(b)

Figura 2: (a) renderización de la nube de puntos 3D de la puerta del Ayuntamiento de Olivenza (Badajoz). (b) resultados de la etapa de agrupación basada en planos.

entrada al algoritmo MSAC (del inglés, M-estimator Sample and Consensus) [6], una variante de RANSAC, que determina el conjunto de puntos, que

se denotará como $Q_i \subset \mathcal{V}$, que mejor se aproximan al plano definido por n_i .

Una vez determinado Q_i , se realiza la operación diferencia entre \mathcal{V} y Q_i y se redefine \mathcal{V} . Si $\mathcal{V} \neq \emptyset$, se volverá a coger un nuevo punto aleatorio y se repetirá el proceso.

Como se puede observar, tras la realización de esta etapa, se ha realizado una primera ordenación de los datos, ya que se ha pasado de tener un conjunto de puntos 3D en los que no existía conexión entre sí, a un número de subconjuntos de puntos que tienen como característica la pertenencia al mismo plano. En la figura 2 se muestra un ejemplo de aplicación. En (a) se puede ver la renderización de la nube de puntos tratada. En (b) se representa en distintos colores, el agrupamiento realizado en esta etapa del algoritmo de segmentación. Mientras que la nube está formada por unos 475000 puntos, los grupos, tras esta etapa, son 36, con un número variable de puntos, yendo desde los 254591 puntos para el plano mayor (el correspondiente a la pared) hasta los 265 puntos para el menor.

Aunque tras esta etapa ya se tiene una primera segmentación, aún no es suficiente, ya que las zonas de interés son mucho menores a las que proporciona el agrupamiento por planos (36, como se ha dicho, en el ejemplo mostrado). Para solucionar este hecho se realiza la última etapa de segmentación.

3.3 ETAPA DE AGRUPACIÓN BASADA EN CARACTERÍSTICAS

El último paso en el algoritmo de segmentación es el de agrupación basado en características. En este caso, y a diferencia del caso anterior, la agrupación es entre los distintos grupos ya creados en la fase anterior.

Para realizarlo determinaremos para cada Q_i unas características relacionadas, de nuevo, con las normales de los puntos de Q_i y del plano que se ajustaba a Q_i . En concreto, sea $p_j \in Q_i$ y n_j el vector normal a p_j . Por otro si la normal del plano que se ajustaba a Q_i es n_{Q_i} , se puede determinar el ángulo θ_i entre n_j y n_{Q_i} como:

$$\theta_j = \text{acos}(n_j \cdot n_{Q_i}) \quad (1)$$

Donde $|\cdot|$ representa el producto escalar. Estamos suponiendo que todos los vectores normales tienen módulo unidad.

Si se realiza este cálculo para todos los puntos de Q_i , suponiendo que el número de ellos es k_i , en cada segmento determinado en la etapa anterior habrá k_i valores de ángulo. Por último, para estos conjuntos de

ángulos determinaremos, como primeras características, el valor medio y la desviación estándar:

$$\bar{\theta}_i = \frac{1}{k_i} \sum_{j=1}^{k_i} \theta_j \quad (2)$$

$$\Delta\theta_i = \sqrt{\frac{1}{k_i} \sum_{j=1}^{k_i} (\theta_j - \bar{\theta}_i)^2} \quad (3)$$

Además de los valores anteriores, se ha realizado una estimación de la curvatura de cada uno de los grupos Q_i . Esta estimación se ha realizado al determinar la normal n_{Q_i} , que se ha hecho determinado las componentes principales de los puntos de Q_i . Al determinar las componentes principales, se calculan también los autovalores de la matriz de covarianza de los datos, $\sigma = \{\sigma_1, \sigma_2, \sigma_3\}$. A partir de estos datos se puede estimar una curvatura, denominada varianza de la superficie como [7]:

$$M_C(p_i) = \frac{\sigma_1}{\sum_{j=1}^3 \sigma_j} \quad (4)$$

Estas tres características, las calculadas mediante las ecuaciones (2), (3) y (4), son las empleadas en el último paso de la segmentación, que consiste en la aplicación del conocido algoritmo de agrupación k -medias++ (o k -means++ en su nombre en inglés) [8]. La distancia empleada es la distancia euclídea.

Tras este paso, como se ha indicado, finaliza el algoritmo de segmentación.

4. RESULTADOS EXPERIMENTALES

Para verificar los resultados del método propuesto, se han empleado datos 3D capturados con escáneres láser de corto alcance, en concreto con un FARO LS-880. Este escáner tiene un alcance de unos 80 m.

Para la programación del algoritmo se ha empleado un computador con un procesador Intel i7-4720MQ y 16 Gb de RAM. Los algoritmos se han realizado usando Matlab.

Las nubes de puntos sobre las que se han probado el algoritmo de segmentación son 3. Una de la puerta del Ayuntamiento de Olivenza (Badajoz), otra del interior de una de las naves transversales de la iglesia parroquial de La Fuente del Maestro (Badajoz) y la última, la del yacimiento tartésico del Turuñuelo, ubicado en el término municipal de Guareña (Badajoz). En la figura 3 se muestran unas fotografías de cada una de estas obras de patrimonio.

Tabla 1: Datos del proceso de segmentación 3D.

	Olivenza	La Fuente	Turuñuelo
Nº puntos	474049	621394	1756175
Nº grupos por planos	36	344	137
Nº grupos por características	3	3	4
Tiempo etapa 1	12,7 s	123,4 s	145,9 s
Tiempo etapa 2	2,6 s	4,2 s	10,1 s

En la tabla 1 se muestran algunos datos de las distintas etapas del algoritmo de segmentación. Para cada una de las nubes de puntos se indica el número de puntos, el número de grupos tras las fases de agrupación por planos y por características. Por último, se indican los tiempos de ejecución, en segundos, de estas dos fases de agrupamiento.

Como se observa, el tiempo de ejecución de la primera etapa de agrupamiento no depende sólo del número de puntos de la nube 3D, sino también de los grupos que se hayan formado en la fase de agrupación por planos. En la tabla 2 se muestra las razones de tiempo teniendo en cuenta los grupos formados y la cantidad de puntos. Como se observa, la razón entre el tiempo y el número de puntos varía significativamente entre unas y otras nubes de puntos, aunque no es solo debido al número de puntos, sino también a la complejidad de las nubes de puntos, lo que implica un mayor número de planos a detectar en el algoritmo MSAC. Sin embargo, la razón entre ese mismo tiempo y el número de grupos formados permanece constante para dos nubes de puntos 3D y varía ligeramente para la tercera.

Tabla 2: Datos del proceso de segmentación 3D.

	Olivenza	La Fuente	Turuñuelo
Nº puntos	474049	621394	1756175
Nº grupos por planos	36	344	125
Tiempo etapa 1/Nº Puntos	$2,7 \cdot 10^{-5}$	$19,8 \cdot 10^{-5}$	$8,3 \cdot 10^{-5}$
Tiempo etapa 1/Nº grupos por planos	0,35 s	0,35 s	1,06 s



(a)



(b)



(c)

Figura 3: (a) Puerta del Ayuntamiento de Olivenza (Badajoz), (b) iglesia parroquial de La Fuente del Maestre (Badajoz) y (c) yacimiento arqueológico del Turuñuelo, Guareña (Badajoz).

Con respecto al número de grupos final de la segmentación 3D, los conseguidos tras la aplicación del método k -medias, hay que decir que se selecciona de forma manual por prueba y error.

En la figura 4 se muestran los segmentos obtenidos tras la aplicación del algoritmo a las nubes de puntos. Como se puede observar, en los casos (a) y (b) el algoritmo es capaz de separar las zonas no significativas o no ornamentales, fundamentalmente planos, de las significativas u ornamentales. Es reseñable cómo se ha realizado la segmentación en el caso de la iglesia parroquial de La Fuente del Maestre, (b), en el que el algoritmo ha sido capaz de separar los distintos bancos y los altares que se ven en la nave. Con respecto al caso del yacimiento arqueológico del Turuñuelo, (c), hay que indicar que el método de segmentación 3D solo ha sido capaz de separar los planos horizontales (azul) de los verticales (verde). Sin embargo, no ha sido capaz de separar los datos de los huesos (se pueden ver en la figura 4(c)) del suelo.

5. CONCLUSIONES

En este trabajo se ha presentado un método para la segmentación de datos 3D adquiridos con un escáner de medio alcance.

El procedimiento propuesto se ha dividido en tres partes, la primera es la carga en memoria de los datos y el cálculo de las normales para todos los puntos de la nube de puntos, fase necesaria para las otras dos partes del algoritmo.

A continuación, se realiza un primer paso de agrupamiento basado en la similitud entre planos. Esta fase, en la que se emplea una variante del algoritmo RANSAC, el MSAC, simplifica el problema, ya que convierte a la nube de puntos 3D en un grupo de conjuntos de puntos con una característica común entre ellos.

Por último, se procede a calcular tres características para cada grupo obtenido en la etapa anterior, que son el valor medio y la desviación de los ángulos que forman las normales de cada punto y la normal del segmento al que pertenecen; y la curvatura de los grupos determinados en la etapa anterior. A partir de estas características, se aplica el algoritmo de agrupamiento k -medias y se vuelven a agrupar los segmentos en los definitivos.

Se ha demostrado la utilidad del método con tres nubes de puntos 3D reales, aunque también se han detectado algunos errores que tendrán que ser corregidos en fases futuras del algoritmo.

Agradecimientos

Este trabajo ha sido financiado por el proyecto IB16162 de la Junta de Extremadura y el Fondo Europeo de Desarrollo Regional Una manera de hacer Europa; y por el proyecto DPI2016-76380-R AEI/FEDER, del Ministerio de Economía y Competitividad.




Figura 4: Resultado de segmentación de las nubes de puntos 3D de (a) la puerta del Ayuntamiento de Olivenza, (b) la iglesia parroquial de La Fuente del Maestre y (c) el yacimiento arqueológico del Turuñuelo.

English summary

QUICK 3D SEGMENTATION APPLIED TO DETECTION OF ORNAMENTAL ELEMENTS IN POINT CLOUDS OF THE CULTURAL HERITAGE

Abstract

This paper presents a 3D data segmentation procedure belonging to cultural heritage works. The objective is, first of all, that the algorithm be able to separate the ornamental areas from the non-ornamental ones and, secondly, that the procedure be quick. For this, a method has been proposed that performs segmentation in two stages, a first in which 3D points are grouped into zones according to whether they belong to the same plane or not, and the second that uses three characteristics that are used by the algorithm. k-means to obtain the definitive segmentation. The procedure has been tested on several real 3D point clouds.

Keywords: 3D segmentation, points cloud, laser scanners.

Referencias

- [1] Demantké, J., Mallet, C., David, N., & Vallet, B. (2012). "Dimensionality Based Scale Selection in 3D Lidar Point Clouds". ISPRS - International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XXXVIII-5/, pp. 97–102.
- [2] Nurunnabi, A., Belton, D., & West, G. (2016). "Robust Segmentation for Large Volumes of Laser Scanning Three-Dimensional Point Cloud

Data". IEEE Transactions on Geoscience and Remote Sensing, 54(8), pp. 4790–4805.

- [3] Xu, Y., Tuttas, S., Hoegner, L., & Stilla, U. (2018). Voxel-based segmentation of 3D point clouds from construction sites using a probabilistic connectivity model. Pattern Recognition Letters, 102, pp. 67–74.
- [4] Börcs, A., Nagy, B., & Benedek, C. (2015). "Fast 3-D urban object detection on streaming point clouds". In L. Agapito, M. M. Bronstein, & C. Rother (Eds.), Computer Vision-ECCV Workshops. Vol. 8926, pp. 628–639.
- [5] Börcs, A., Nagy, B., & Benedek, C. (2017). Instant Object Detection in Lidar Point Clouds. IEEE Geoscience and Remote Sensing Letters, 14(7), pp. 992–996.
- [6] Torr, P. H. S. & Zisserman, A. (1998) "Robust computation and parametrization of multiple view relations" In Proceedings of the International Conference on Computer Vision, pp. 727–732.
- [7] Foorginejad, A., & Khalili, K. (2014). "Umbrella Curvature: A New Curvature Estimation Method for Point Clouds". Procedia Technology, 12, pp. 347–352.
- [8] Arthur, D., & Vassilvitskii, S. (2007). "K-means++: The Advantages of Careful Seeding". In Proceedings of the Eighteenth Annual ACM-SIAM Symposium on Discrete Algorithms, pp. 1027–1035.



© 2018 by the authors. Submitted for possible open access publication under the terms and conditions of the Creative Commons Attribution CC-BY-NC 3.0 license (<https://creativecommons.org/licenses/by-nc/3.0>).