

머신러닝을 이용한 3차원 도로객체의 분류

Classification of 3D Road Objects Using Machine Learning

홍송표¹⁾ · 김의명²⁾

Hong, Song Pyo · Kim, Eui Myoung

Abstract

Autonomous driving can be limited by only using sensors if the sensor is blocked by sudden changes in surrounding environments or large features such as heavy vehicles. In order to overcome the limitations, the precise road-map has been used additionally. This study was conducted to segment and classify road objects using 3D point cloud data acquired by terrestrial mobile mapping system provided by National Geographic Information Institute. For this study, the original 3D point cloud data were pre-processed and a filtering technique was selected to separate the ground and non-ground points. In addition, the road objects corresponding to the lanes, the street lights, the safety fences were initially segmented, and then the objects were classified using the support vector machine which is a kind of machine learning. For the training data for supervised classification, only the geometric elements and the height information using the eigenvalues extracted from the road objects were used. The overall accuracy of the classification results was 87% and the kappa coefficient was 0.795. It is expected that classification accuracy will be increased if various classification items are added not only geometric elements for classifying road objects in the future.

Keywords : Autonomous Driving, Terrestrial Mobile Mapping System, Machine Learning, Support Vector Machine, Classification

초 록

급변하는 주변상황이나 대형차량과 같은 큰 지형지물에 센서가 가려질 경우에는 센서만을 이용한 완전 자율주행에는 한계가 따른다. 이에 자율주행을 위해서 센서를 이용한 한계점을 극복할 수 있도록 정밀한 도로지도를 부가적으로 이용하는 방법이 사용되고 있다. 본 연구는 국토지리정보원에서 제공하는 지상 MMS(Mobile Mapping System)로 취득된 3차원 점군자료를 이용하여 도로 객체를 분류하는 연구를 수행하였다. 본 연구를 위해서 원본 3차원 점군자료를 전처리 하고, 지면과 비지면점을 분리하기 위한 필터링 기법을 선정하였다. 또한 차선, 가로등, 안전펜스 등에 해당하는 도로객체를 초기 분할한 후 분할된 객체를 머신러닝의 종류인 서포트 벡터 머신을 이용하여 학습시킨 후 분류하였다. 학습데이터는 분할된 도로객체에서 추출한 고유값을 이용한 기하학적 요소와 높이정보만을 사용하였으며 분류결과 전체정확도는 87%, 카파계수는 0.795로 나타났다. 향후 도로객체의 분류를 위하여 기하학적인 요소 뿐만 아니라 다양한 항목을 추가한다면 분류정확도가 높아질 것으로 예상된다.

핵심어 : 자율주행, 지상 모바일 매핑시스템, 머신러닝, 서포트 벡터 머신, 분류

Received 2018. 11. 19, Revised 2018. 12. 04, Accepted 2018. 12. 10

1) Dept. of GIS Engineering, Namseoul University (E-mail: bbcuco@gmail.com)

2) Corresponding Author, Member, Dept. of Spatial Information Engineering, Namseoul University (E-mail: kemyoung@nsu.ac.kr)

This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

자율주행차에는 관성항법장치(INS: Inertial Navigation System), 위성항법장치(GNSS: Global Navigation Satellite System), 라이다(LIDAR: Light Detection And Ranging), 카메라 등의 센서들이 탑재되어 있다. 자율주행차에 탑재된 센서의 인식범위는 약 200m 내외로 도로상의 모든 정보를 스스로 인지, 판단, 제어하는 것이 현실적으로 어려우며, 운전자와 탑승자의 안전을 위해서는 자율주행차가 도로요소들을 사전에 인지할 수 있는 인프라 정보가 필수적으로 필요하다(So and Moon, 2018).

도로주변의 인프라에 해당하는 정밀도로지도의 구축을 위해서 지상 모바일 매핑시스템(MMS: Mobile Mapping System)을 이용하여 3차원 점군(point cloud) 자료를 취득하고 이를 가공 및 처리하여 지도를 제작하고 있다(NGII, 2015). 3차원 점군자료를 이용하여 정밀한 도로지도를 제작하기 위해서는 객체를 분할(segmentation)하여 유의미한 정보로 구분하고 이를 이용하여 분류(classification)하는 과정이 필요하다.

3차원 점군자료는 지상의 MMS 뿐만 아니라 항공라이다를 이용해서도 취득가능하며 이를 이용하여 지면점과 비지면점을 분류하는 필터링 과정을 거쳐 수치표고모델(DEM: Digital Elevation Model)을 제작할 수 있다(Axelsson, 2000; Zhang and Whitman, 2005; Yoo *et al.*, 2005; Chang *et al.*, 2008; Kim and Cho, 2012; Zhang *et al.*, 2016).

객체 분류에 있어 항공라이다 자료는 넓은 지역을 거의 연속적으로 촬영하여 데이터를 취득하기 때문에 비교적 간단한 건물의 지붕, 수목, 도로 등을 수학적 모델에 적용하여 분류하는 연구들이 대부분이었다(Lee and Lee, 2010; Lee *et al.*, 2014; Sun *et al.*, 2016). 이에 반해 지상 MMS를 이용하여 취득한 3차원 점군자료는 항공라이다를 이용하여 취득한 3차원 점군자료에 비해 점밀도가 높고 측면정보를 세밀하게 취득할 수 있기 때문에 분류항목을 세분화할 수 있는 장점이 있는 반면에 분류항목을 세분화 하였을 경우에는 복잡한 방정식과 임계값을 설정해야 하기 때문에 수학적 모델을 이용한 객체분류에는 한계가 따른다(Jeong and Lee, 2016).

머신러닝(machine learning)은 학습데이터(training data)를 이용하여 새로운 데이터가 주어졌을 때 이를 예측하는 기법으로서 수학적 모델을 이용한 기법과 달리 데이터의 특성 및 임계값을 고려할 필요가 상대적으로 적은 장점이 있다(Jeong and Lee, 2016; Hong *et al.*, 2018). 관련된 연구에는 분할된 3차원 객체의 점밀도 및 법선 벡터를 계산하여 이를 학습데이터로

구축하고 머신러닝을 이용하여 객체를 분류하는 연구(Caputo *et al.*, 2014), 분할된 3차원 객체를 주성분 분석(PCA: Principal Component Analysis)하여 계산된 고유값 비율을 이용하여 학습데이터를 구축하고 머신러닝을 이용하여 객체를 분류하는 연구(Lalonde *et al.*, 2006; Jeong and Lee, 2016)등이 수행되어 왔다.

지상 MMS 데이터를 이용한 머신러닝 기반의 3차원 객체 분류에 대한 기존 연구는 이미 객체들을 분할하였다고 가정하거나, 객체 분할에 있어서도 도로가 평면이라고 가정하고 비교적 간단한 평면의 방정식을 이용하여 지면점과 비지면점을 분할하는 연구들이 대부분이었다(Lehtomäki *et al.*, 2015). 객체를 분할하는 과정은 객체분류를 위해서 필수적으로 선행되어야 하는 과정임에도 불구하고 이에 대한 연구는 다소 미흡한 실정이다.

이에 본 연구에서는 국토지리정보원(NGII: National Geographic Information Institute)에서 연구목적으로 제공하였던 지상 MMS로 취득된 원본 3차원 점군자료를 전처리 하고, 지면과 비지면점을 분리하기 위한 필터링을 기법을 선정하였다. 또한 차선, 가로등, 안전펜스 등에 해당하는 도로객체를 초기 분할한 후 분할된 객체를 머신러닝 기반으로 분류하는 방법론을 제안하고자 한다.

2. 연구방법

2.1 제안한 방법론의 흐름도

본 연구에서 제안한 객체분류의 방법론은 Fig. 1과 같으며 다섯 가지로 구분할 수 있다. 첫 번째는 지상 MMS를 이용하여 취득한 원본 3차원 점군자료에는 이상점(outlier point)등의

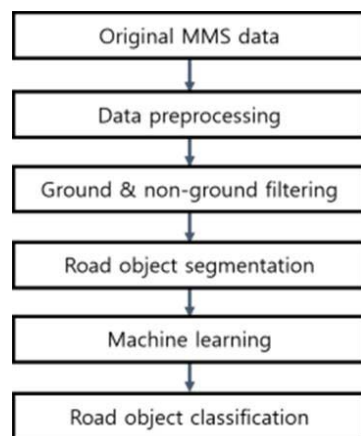


Fig. 1. Research flow chart

불필요한 점들이 포함되어 있기 때문에 객체분류에 효율적인 데이터로 전처리를 수행한다. 두 번째는 전처리된 데이터를 지면점과 비지면점으로 분리하기 위한 필터링기법을 적용한다. 세 번째는 분류된 지면점과 비지면점을 분할 알고리즘에 적용하여 유의미한 도로객체로 분할한다. 네 번째는 머신러닝 기반의 객체분류를 위한 학습데이터를 구축한 후, 마지막으로 분할된 도로객체와 기 구축된 학습데이터를 바탕으로 객체를 분류한다.

2.2 데이터 전처리

지상 MMS에 탑재된 지상 라이더는 물리적인 측정한계로 인하여 이상점이 포함되어 있으며, 높은 점밀도로 인하여 자료처리 과정에 많은 시간이 소요된다. 따라서 이상점을 제거하고 데이터의 특성을 잃지 않을 정도로 다운샘플링(down sampling) 할 필요성이 있으며, 도로 외의 불필요한 점을 제거하여야 한다 (Hong and Kim, 2017).

따라서 본 연구에서는 통계적 이상점 제거(SOR: Statistical Outlier Removal) 기법을 적용하여 이상점을 제거하고 옥트리(octree)기반의 공간분할 기법을 이용하여 데이터를 다운샘플링 하였으며, 다운샘플링된 데이터는 옥트리기반의 연결요소 레이블링(CCL: Connected Component Labeling) 기법을 이용하여 도로그룹을 추출하였다.

2.2.1 통계적 이상점 제거

SOR이란 관심점(query point)을 기준으로 인접한 주변 점들과의 통계분석을 이용하여 통계범위 이외의 점들을 제거하는 기법이다(Rusu and Cousins, 2011). 관심점을 기준으로 인접한 주변 점들의 탐색은 kd-tree기반의 k-최근접점 이웃 기법(KNN: K-Nearest Neighbors)을 이용하였다. Eq. (1)은 관심점으로 부터 k개의 최근접점들의 평균거리(\bar{d})와 표준편차(σ)를 계산한 후, 임계값 범위 이외의 점들은 이상점으로 판단하여 제거하는 수식을 나타낸 것이다. 여기서 k와 n은 사용자가 입력하는 매개변수이며, n의 값은 Fig. 2와 같이 데이터가 표준정규분포를 따른다고 가정하여 일반적으로 2(95.5%)~3(99.7%)의 값으로 설정하였다.

$$threshold = \bar{d} \pm n\sigma$$

$$\bar{d} = \frac{1}{k} \sum_{i=1}^k (d_i) , \sigma = \sqrt{\frac{1}{k} \sum_{i=1}^k (d_i - \bar{d})^2} \quad (1)$$

where \bar{d} represents a mean distance, n represents a threshold of sigma, and σ represents a standard deviation.




Fig. 2. Standard normal distribution (Wikipedia, 2005)

2.2.2 데이터 다운샘플링

점밀도가 높은 3차원 점군자료는 자료처리과정에서 많은 시간이 소요되기 때문에 자료의 특성을 잃지 않을 정도로 점의 개수를 줄일 필요가 있다(Hong and Kim, 2017). 이를 위해 옥트리 기반의 공간분할 기법을 이용하여 3차원 복셀(voxel) 격자를 생성하고 격자 내에 있는 점들을 하나의 점으로 근사화하였다. 여기서 옥트리란 Fig. 3과 같이 2차원 쿼드트리(quadtree)의 삼차원 확장이라고 할 수 있으며 3차원의 공간을 8등분으로 재귀적으로 나누는 방식이다. 따라서 옥트리는 하나의 노드가 8개의 자식노드를 가지는 트리구조가 된다. 옥트리 레벨(n)당 셀의 크기는 Eq. (2)와 같이 정의되며 옥트리의 복셀개수가 다운샘플링 된 점군자료의 점 개수가 된다.

$$l_x^m = \frac{l_x^0}{2^m}, l_y^m = \frac{l_y^0}{2^m}, l_z^m = \frac{l_z^0}{2^m} \quad (2)$$

$$l_x : l_y : l_z = l_x^0 : l_y^0 : l_z^0$$

where, $l_x^0 = x_{max} - x_{min}$, $l_y^0 = y_{max} - y_{min}$, $l_z^0 = z_{max} - z_{min}$, $n : OctreeLevel$




Fig. 3. Structure of quadtree and octree (Apple developer, 2018)

2.2.3 도로그룹 추출

지상 MMS에 탑재된 지상 라이더는 도로 이외의 점들 또한 측정하게 되므로 도로 이외의 점들을 제거할 필요가 있다. 따라서 이상점 제거와 다운 샘플링이 수행된 점군자료를 CCL를 적

용하여 가장 많은 점이 포함된 그룹을 도로 점군으로 가정하여 도로그룹을 추출하였다. CCL이란 Fig. 4와 같이 2차원의 영상 처리에서 4방향 또는 8방향으로 픽셀값을 탐지하면서 서로 연결된 셀들에 고유한 라벨을 부여하여 분할하는 기법으로 3차원의 점군자료의 경우 옥트리를 이용하여 복셀을 생성한 후 서로 연결되어 있는 복셀에 고유한 라벨을 부여하는 방법이다. 3차원 점군자료에서 CCL을 수행하기 위해서 사용되는 입력 매개변수에는 복셀의 크기 또는 옥트리 레벨 그리고 복셀의 최소 점의 개수가 있다.




Fig. 4. Connected component labeling in 2d space (Wikipedia, 2010)

2.3 지면·비지면 분류

전처리가 완료된 3차원 점군자료는 지면점과 비지면점의 모든 정보가 포함되어있기 때문에 효율적인 도로객체 분할을 위해서는 지면점과 비지면점으로 구분하는 필터링이 선행적으로 이루어져야 한다. 필터링 알고리즘에는 PCFA(Perspective Center based Filtering Algorithm), ATIN(Adaptive-TIN), PM(Progressive Morphology), ETEW(Elevation Threshold Expanding Window) 등이 있으나 본 연구에서는 지면점을 과소 추정하거나 비지면점을 과대추정하는 경향이 거의 없고 임계값이 지형에 관계없이 일관적인 PCFA 기법을 사용하였다 (Kim and Cho, 2012).




Fig. 5. PCFA

PCFA기법은 실감정사영상 제작시에 폐색영역을 탐지하는 기법과 유사하게 Fig. 5와 같이 일정한 크기의 격자를 생성한 후 8개의 가상 투영중심점을 지상에 내리고 격자 상에 존재하는 점과 각도를 비교하여 각도가 증가하다가 감소하면 건물, 수목 등의 지형지물에 의하여 가려지는 폐색영역으로 탐지되어 지면점으로 분류를 수행하는 알고리즘이다(Chang et al., 2008).

2.4 도로객체 분할

필터링으로 분류된 지면점을 이용하여 차선, 노면표지와 같은 도로평면정보의 객체를 분할하고, 비지면점을 이용하여 가로등, 도로표지, 안전펜스 등과 같은 도로 시설물정보의 객체로 분할하였다. 도로평면정보의 객체 분할에 있어서는 도로의 아스팔트, 차선, 노면표지 등의 점들이 연속되어 있는데 이를 반사강도를 이용하여 유의미한 점들을 추출하고, CCL기법을 이용하여 도로평면정보의 객체를 분할하였다. 이때 반사강도란 대상체에서 반사되어 스캐너에 도달한 레이저 강도 대 발사된 레이저 강도의 비율로서 대상체의 물리적인 특성과 사용된 광원에 의해 고유한 반사도를 가지므로 대상체에 따라 반사강도가 상이하게 나타난다(Lee and Son, 2016). 따라서 차선, 노면표지 등의 반사강도는 도로 아스팔트의 반사강도보다 크기 때문에 아스팔트보다 높은 반사강도 값을 사용하였다. 도로시설물 정보의 객체분할은 지면점이 제거된 비지면점을 CCL기법을 이용하여 도로시설물 객체를 분할하였다.

2.5 학습데이터 구축

머신러닝을 이용하여 도로객체를 분류하기 위해서는 학습 데이터를 구축하여야 하는데 본 연구에서는 주성분 분석을 이용하여 기하학적인 정보를 추정 하였다. 이를 위해 분할된 도로객체로 추정되는 점군자료에 대해 Eq. (3)을 이용하여 분산 및 공분산 행렬을 구성하고, Eq. (4)와 같이 고유값 분해를 수행하였다.

$$\frac{1}{n} AA^T = \frac{1}{n} \begin{bmatrix} \hat{x}_1 & \hat{x}_2 & \dots & \hat{x}_n \\ \hat{y}_1 & \hat{y}_2 & \dots & \hat{y}_n \\ \hat{z}_1 & \hat{z}_2 & \dots & \hat{z}_n \end{bmatrix} \begin{bmatrix} \hat{x}_1 & \hat{y}_1 & \hat{z}_1 \\ \hat{x}_2 & \hat{y}_2 & \hat{z}_2 \\ \vdots & \vdots & \vdots \\ \hat{x}_n & \hat{y}_n & \hat{z}_n \end{bmatrix} \quad (3)$$

$$= \begin{bmatrix} var(x) & cov(x,y) & cov(x,z) \\ cov(x,y) & var(y) & cov(y,z) \\ cov(x,z) & cov(y,z) & var(z) \end{bmatrix} = C$$

where $\hat{x}_i = x_i - (\frac{1}{n} \sum_{i=1}^n x_i)$, $\hat{y}_i = y_i - (\frac{1}{n} \sum_{i=1}^n y_i)$, $\hat{z}_i = z_i - (\frac{1}{n} \sum_{i=1}^n z_i)$, n represents a number of points, and C represents a variance-covariance matrix.

$$\begin{aligned}
 Cx &= \lambda x \\
 (C - \lambda)x &= 0 \\
 \det(C - \lambda) &= 0
 \end{aligned}
 \tag{4}$$

where $x \neq \vec{0}$, C represents a variance-covariance matrix, and λ represents a scala.

3차원 점군자료에 대한 고유값을 계산하였기 때문에 3개의 고유값에 대해 Eq. (5)를 이용하여 정규화를 시키고 Eq. (6)을 이용하면 Fig. 6과 같이 선형(L), 면형(P), 불규칙형(S)의 기하학적 요소를 대략적으로 파악할 수 있다(Lalonde *et al.*, 2006). Eq. (6)에서 알 수 있듯이 3개의 고유값을 정규화하였기 때문에 그 합은 1이 된다.

$$\begin{aligned}
 \hat{\lambda}_0 &= \frac{\lambda_0}{\lambda_0 + \lambda_1 + \lambda_2} \\
 \hat{\lambda}_1 &= \frac{\lambda_1}{\lambda_0 + \lambda_1 + \lambda_2} \\
 \hat{\lambda}_2 &= \frac{\lambda_2}{\lambda_0 + \lambda_1 + \lambda_2} \\
 \lambda_0 &\geq \lambda_1 \geq \lambda_2
 \end{aligned}
 \tag{5}$$

where $\lambda_0, \lambda_1, \lambda_2$ represent eigenvalues.

$$L = \frac{\hat{\lambda}_0 - \hat{\lambda}_1}{\hat{\lambda}_0}, P = \frac{\hat{\lambda}_1 - \hat{\lambda}_2}{\hat{\lambda}_0}, S = \frac{\hat{\lambda}_2}{\hat{\lambda}_0}
 \tag{6}$$

where L represents a linear element, P represents a planar element, S represents a scatter element, and $L + P + S = 1$.




Fig. 6. Geometric elements of 3d point cloud data using principal component analysis

주성분 분석을 통해서 점군자료에서 추출할 수 있는 선형, 면형, 불규칙형의 기하학적인 정보 뿐만 아니라 추출된 점군자료의 높이정보(Z)를 추가하여 학습데이터에 이용하였다(Jeong and Lee, 2016).

2.6 도로객체 분류

객체분류의 항목으로는 가로등, 나무, 도로표지, 차선, 안전 펜스, 불명으로 총 6개의 분류항목을 선정하였다. 이러한 이유는 학습데이터 수집에 있어 비교적 쉽게 취득할 수 있으며, 도로에서 볼 수 있는 주된 객체이기 때문이다. 도로객체 분류를 위해 주성분 분석을 수행한 후 계산한 고유값 비율을 이용하여 추정된 기하학적 요소(L, P, S)와 객체의 높이정보(Z)로 구성된 학습데이터를 서포트 벡터 머신(SVM: Support Vector Machine)을 이용하여 도로객체를 분류하였다.

SVM이란 머신러닝에서 지도학습(supervised learning) 기법 중의 하나로서 여러 클래스간에 분류를 수행할 때 선형의 회귀식을 이용하여 초평면(hyper plane)을 생성하여 분류하는 기법이다. 이 때 초평면은 각 분류 데이터 중에서 분리하는 초평면에 가장 가까운 자료 사이의 거리를 최대화할 수 있어야 한다(Park *et al.*, 2011). SVM에서 서포트 벡터란 Fig. 7의 점선과 같이 각 클래스 중에 식별경계(실선)에서 가장 가까운 벡터를 뜻하며 2차원의 경우 벡터이지만 3차원 이상부터는 초평면(hyperplane)이라 한다. 또한 서포트 벡터 사이의 거리를 최대화할 수 있는 초평면을 식별경계로 결정한다.




Fig. 7. Support vector machine

클래스를 구분하는 초평면은 여러 개가 있지만 경계가 최대화된 초평면은 유일하다. 이러한 최적의 초평면은 Eq. (7)과 같이 정의된다. 여기서 \vec{w} 는 초평면의 법선벡터 \vec{x} 는 초평면상의 한 점, b 는 절편이다. 또한 Fig. 7과 같이 $w^T x$ 가 -1보다 작으면 Class 1, 1보다 크면 Class 2로 판별할 수 있으며 Eq. (8)과 같은 조건식을 설정할 수 있다.

$$(\vec{w} \cdot \vec{x}) + b = w^T x = 0
 \tag{7}$$

where \vec{w} represents a normal vector of hyper plane and \vec{x} represents a point in hyperplane, and b represents a bias.

$$\begin{aligned}
 y_i &= +1 \text{ when } (\vec{w} \cdot \vec{x}_{class1}) + b \geq +1 \\
 y_i &= -1 \text{ when } (\vec{w} \cdot \vec{x}_{class2}) + b \geq -1 \\
 y_i(\vec{w} \cdot \vec{x}_i + b) - 1 &= 0
 \end{aligned}
 \tag{8}$$

where \vec{x}_{class1} represents points in class1 and \vec{x}_{class2} represents points in class2.

SVM은 Eq. (9)와 같이 두 클래스 사이의 거리를 최대화하기 위한 것으로 목적함수를 Eq. (10)과 같이 나타낼 수 있다.

$$\frac{\vec{w}}{\|w\|} \cdot (\vec{x}_{class1} - \vec{x}_{class2}) = \frac{2}{\|w\|}
 \tag{9}$$

where $\frac{2}{\|w\|}$ denotes a distance from class 1 to class 2.

$$\max \frac{2}{\|w\|} \Rightarrow \min \left(\frac{1}{2} \|w\|^2 \right)
 \tag{10}$$

3. 실험

3.1 연구지역 및 데이터

본 연구에는 NGII에서 제공하는 지상 MMS를 이용하여 취득된 3차원 점군자료를 사용하였다. NGII의 국토정보플랫폼에서 연구목적으로 데이터를 무상으로 취득할 수 있었다(2017년 11월 기준). 3차원 점군자료는 Fig. 8과 같이 300m×300m 크기로 분할하여 Index 및 LAS파일 포맷으로 제공된다. 본 연구에서는 영동고속도 이천구간(약 41km)의 일부 구간(index 155 ~ 200, 약 14km)을 이용하여 학습데이터를 수집하고, 객체 분할 알고리즘의 적용은 index 155번을 사용하였다. 또한 객체 분류에는 여의도 일대(약 21km)구간에서 index 218번을 사용하였다.



Fig. 8. Data index

Fig. 9는 본 연구에 사용한 데이터를 나타낸 것으로 3차원 점군자료에는 UTM좌표계를 기준으로 한 3차원 좌표, 촬영시간, 반사강도 등의 정보가 있다.





Fig. 9. Representation of 3d point cloud data

3.2 데이터 전처리

객체분류에 효율적인 데이터를 구축하기 위하여 원본 3차원 점군자료를 SOR기법을 이용하여 노이즈를 제거하고 옥트리 기반의 다운샘플링 및 CCL기법을 이용하여 Fig. 10(a)와 같이 도로 그룹을 추출하였으며, Figs. 10(b), 10(c)와 같이 점밀도가 감소한 것을 확인할 수 있다. SOR는 k는 10, n은 2를 적용하여 이상점을 제거하고 다운샘플링을 위한 옥트리 레벨은 실험적으로 10(약 0.3m)을 설정하였으며, 도로 그룹 추출을 위한 CCL의 옥트리 레벨은 8(약 1.2m)을 적용하였다. 여기서 도로그룹 추출을 위한 옥트리 셀의 크기는 다운샘플링을 위한 옥트리 셀의 크기 보다 크게 설정해야 한다. 원본 3차원 점군자료의 전처리를 수행한 결과 점의 개수가 10,864,953에서 380,708점으로 96.5% 정도로 간략화 되었다. 원본 3차원 점군자료에서 점의 개수가 약 3.5%만 남겨진 상태에서 Fig. 10(c)와 같이 도로의 특성이 잃지 않는 것을 확인할 수 있다.



(a) Extraction of road point group (b) Before downsampling (c) After downsampling

Fig. 10. Data preprocessing


3.3 지면점과 비지면점 분류

전처리된 3차원 점군자료는 PCFA를 이용하여 지면점과 비지면점으로 분류하였다. PCFA기법에 사용한 임계값은 Table

1과 같으며 그 결과는 Fig. 11(a)와 같이 지면점과 비지면이 분류된 것 확인할 수 있으며, 지면점의 높이에 대한 그레이스케일 맵을 확인하였을 때 Fig. 11(b)와 같이 양호한 결과를 보였다.

Table 1. Parameter values for PCFA (unit: m)

Parameters	Threshold
Non-ground	2
Ground	1.5
Offset(X, Y)	150
Offset(Z)	100
Resolution(grid size)	10
Standard deviation	0.5




(a) Ground and non-ground point (b) Grayscale map of ground point for height

Fig. 11. Result of PCFA

3.4 도로객체 분할

분류된 지면점에서 반사강도를 이용하면 Fig. 12(a)와 같이 노이즈점(이상점) 들이 포함되는데 이를 SOR기법(k: 10, n: 2)을 이용하여 노이즈를 제거하였다. 그리고 나서 Fig. 12(b)와 같이 노이즈가 제거된 데이터에 대해 CCL을 실시하여 도로평면 객체를 분할하였다.




(a) Extraction of the information of road plane object using intensity (b) CCL of road plane object

Fig. 12. Segmentation of road plane objects

Fig. 13(a)과 같이 도로시설물 객체추출은 이미 지면점이 제거되었기 때문에 비지면점에 대해서 CCL기법을 적용하였으며 Fig. 13(b)와 같이 도로시설물 객체가 분할된 것을 알 수 있다. 여

기서 CCL의 옥트리 레벨은 9(약0.6m)로 설정하여 수행하였다.



(a) Upper view (b) Side view

Fig. 13. Segmentation of road facility objects

3.5 학습데이터 구축 및 검증

본 연구에서는 가로등, 나무, 도로표지, 차선, 안전펜스, 불명으로 총 6개의 분류항목을 선정하였으며, 데이터 전처리, 지면·비지면 분류, 도로 객체분할은 3.2, 3.3, 3.4절의 기법을 적용하였다. 학습데이터는 Table 2와 같이 분할된 도로객체를 이용하여 기하학적 요소(L, P, S)와 높이정보(Z)에 대한 총 825개를 구축하였으며, 라벨작업은 수작업으로 수행하였다.

Table 2. Training dataset example

N	L	P	S	Z	Label
1	0.978	0.022	0.000	10.692	street lamp
2	0.969	0.030	0.001	10.183	street lamp
3	0.576	0.154	0.270	6.935	tree
4	0.778	0.117	0.105	6.721	tree
5	0.989	0.011	0.000	2.482	safety fence
...
825	0.348	0.412	0.240	1.320	unknown

3.5.1 모델 검증

구축된 학습 데이터셋은 SVM을 이용하여 학습하였다. 이때 구축된 데이터셋 중에서 전체의 75%(618개)는 학습데이터로 이용하고 25%(207개)는 평가데이터로 이용하였다. 학습된 모델의 혼동행렬(confusion matrix)은 Table 3과 같으며 전체 정확도(PCC: Percent Correctly Classified)는 93%, 카파(kappa) 계수는 0.917로 나타났다. 카파 계수는 0 ~ 1사이의 값으로 1에 가까울수록 분류정확도가 높다는 것을 뜻하며 Eq. (12)와 같다(Han, 2016).

$$kappa = \frac{P_0 - P_c}{1 - P_c}$$

$$P_0 = \sum_{i=1}^m P_{ii} = \frac{1}{N} \sum_{i=1}^m n_{ii}$$

$$P_c = \sum_{i=1}^m P_{i+} P_{+i} = \frac{1}{N^2} \sum_{i=1}^m n_{i+} n_{+i}$$
(12)

Table 3. Confusion matrix of SVM

		Classified results						
		Street lamp	Tree	Roadsign	Safety fence	Lane	Unknown	Recall
Actual items	Street lamp	54	0	0	1	0	0	0.98
	Tree	0	38	0	0	0	2	0.95
	Road sign	4	0	29	0	0	0	0.88
	Safety fence	0	0	0	30	0	2	0.94
	Lane	0	0	0	0	24	0	1
	Unknown	0	0	5	0	0	18	0.78
	Precision	0.93	1	0.85	0.97	1	1	-


where P_0 represents the ratio of diagonal cells to all cells, n_{ii} represents a diagonal cell, N represents the number of data, P_{ii} represents a percentage for diagonal cells, P_{i+} represents the percentage of total row sum of each sample data, and P_{+i} represents the percentage of total column sum of each sample data.

3.6 도로객체 분류

객체 분류에는 여의도 일대(약 21km)구간에서 index 218번을 사용하였다. 이러한 이유는 구축한 학습 모델이 다른 지역에 적용가능한지 알아보기 위해서이다. 데이터의 전처리와 지면·비지면 분류 및 객체 분할 알고리즘 기법에 사용된 매개변수 3.2, 3.3, 3.4절과 동일하게 설정하였다.


Fig. 14(a)는 원본 3차원 점군자료이며 Fig. 14(b)는 전처리된 데이터를 나타내고 이를 지면점과 비지면점으로 분류한 결과는 Fig. 14(c)와 같다. 분류된 지면점을 이용하여 Fig. 15(a)와

같이 도로평면 정보의 객체를 분할하고, 비지면점을 이용하여 Fig. 15(b)와 같이 도로시설물 정보의 객체를 분할하였으며, 총 128개의 객체가 분할되었다. 3.5절에서 구축한 학습모델을 적용하여 도로객체를 분류하였으며 그 결과는 Fig. 16과 같다.



(a) Original data (b) Preprocessing data (c) Classified ground and non-ground points

Fig. 14. Pre-processing and ground classification



(a) Segmentation of road plane objects (b) Segmentation of road facility objects

Fig. 15. Segmentation of road objects





Fig. 16. Result of classification



(a) Mis-classified as a unknown (b) Mis-classified as a street lamp (c) Mis-classified as a road sign

Fig. 17. Mis-classified objects

머신러닝 기법을 적용하여 분류한 결과 전체 정확도는 87% 이고 카파 계수는 0.795로 나타났다. Table 4의 혼동행렬과 Fig. 17을 살펴보면 Fig. 17(a)와 같이 나무가 불명으로 오분류된 경우나 Fig. 17(b)와 같이 나무가 가로등으로 오분류되는 경우가 발생하였다. 뿐만 아니라 Fig. 17(c)와 같이 나무가 도로표지

오분류 되는 경우가 있었다. 이러한 이유는 본 연구에서 머신러닝 기법을 적용하여 학습을 시킬 때 기하학적 요소와 객체의 높이정보만을 사용하였기 때문에 나무, 가로등, 도로표지는 서로 기하학적 요소가 유사할 뿐만 아니라 나무넙클 및 미제거된 지면점등으로 인하여 두 개의 객체가 하나의 객체로 분할되었기 때문이다.

Table 4. Confusion matrix of object classification

		Classified results					
		Street lamp	Tree	Road sign	Safety fence	Lane	Unknown
Actual items	Street lamp	2	0	0	0	0	0
	Tree	2	23	2	0	0	3
	Road sign	0	0	1	0	0	0
	Safety fence	0	0	0	1	0	0
	Lane	0	0	0	0	25	1
	Unknown	0	1	0	5	3	59

4. 결론

본 연구에서는 지상 MMS를 이용하여 취득한 3차원 점군자료를 이용하여 도로객체를 분할하고 분류하는 연구를 수행하였으며 다음과 같은 결론을 도출하였다.

첫째, NGII에서 제공하는 원본 3차원 점군자료는 지상 MMS에 탑재된 지상 레이저 스캐닝 장비의 물리적인 측정 한계로 인하여 노이즈(이상점)가 포함되어 있을 뿐만 아니라 점밀도가 매우 높아 자료처리에 매우 많이 시간이 소요되었다. 따라서 옥트리 기반의 공간 분할기법을 이용하여 데이터를 다운 샘플링한 후 도로로 추정되는 그룹을 추출한 후 SOR기법을 이용하여 노이즈를 제거하는 전처리 방법론을 제시하였다.

둘째, 지상 MMS를 이용하여 취득한 3차원 점군자료의 필터링을 위해 PCFA기법을 적용한 결과 지면점과 비지면점을 효율적으로 분류할 수 있었고, 분류된 지면점을 이용하여 도로평면 객체를 분할하고 비지면점을 이용하여 도로시설물 객체를 분할할 수 있었다.

셋째, 분할된 객체를 분류하기 위해 머신러닝 기법중의 하나인 SVM을 이용하여 도로객체를 분류하였다. 지도학습을 위하여 분할된 3차원 객체에서 주성분분석을 통한 고유값을 이용하여 3차원 객체의 선형, 면형, 볼구직형의 비율을 고려할 수 있는 기하학적 요소와 객체의 높이정보를 이용하였다.

본 연구에 사용된 학습모델의 카파계수는 0.917로 나타났지만 새로운 지역에 적용하였을 경우 카파계수는 0.795로 분류정확도가 감소하였다. 이러한 이유는 학습데이터 수집이 상대적으로 적었기 때문이다. 따라서 새로운 지역에서도 적용 가능한 학습모델을 구축하기 위해서는 다양한 지역에서 다수의 학습데이터를 수집할 필요가 있다. 향후 3차원 점군자료의 객체분류를 자동화하기 위해서는 3차원 객체의 분할 성능을 높여야 하며 머신러닝을 위한 학습데이터를 구축할 때 분류항목에 따른 학습데이터 구축 및 분류기법 선정에 대한 후속 연구가 필요할 것으로 판단된다.

감사의 글

이 논문은 2017년 정부(국토교통부)의 재원으로 공간정보 융복합 핵심인재 양성사업의 지원을 받아 수행된 연구임 (2017-02-02)

References

- Apple developer. (2018), Spatial and logical arrangement of an example octree, *Apple*, URL: <https://developer.apple.com/documentation/gameplaykit/gkocctree>(last date accessed: 10 November 2018).
- Axelsson, P. (2000), DEM generation from laser scanner data using adaptive TIN models, *International Archives of Photogrammetry and Remote Sensing*, 16-22 July, Amsterdam, Nederland, Vol. 33, Part B4, pp. 110-117.
- Caputo, M., Denker, K., Franz, M.O., Laube, P., and Umlauf, G. (2014), Support vector machines for classification of geometric primitives in point clouds, *Curves and Surfaces*, Vol. 9213, pp. 80-95.
- Chang, Y., Habib, A., Lee, D.C., and Yom, J.H. (2008), Automatic classification of LIDAR data into ground and non-ground points, *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 3-11 July, Beijing, China, Vol. 37, Part B4, pp. 457-462.
- Han, S.H. (2016), *Introduction to Photogrammetry and Remote Sensing*, Goomibook, Seoul.
- Hong, S.P. and Kim, E.M. (2017), Object segmentation of laser data using terrestrial mobile mapping system, *Proceedings*

- of *Journal of Korean Society for Geospatial Information System*, Korean Society for Geospatial Information Science, 18-19 May, Jeonju, Korea, pp. 197-198.
- Hong, S.P., Seo, H.D., and Kim, E.M. (2018), Road object classification using a terrestrial laser data, *Proceedings of Journal of Korean Society for Geospatial Information System*, Korean Society for Geospatial Information Science, 1-2 November, Jeju, Korea, pp. 199-200.
- Jeong, J.H. and Lee, I.P. (2016), Classification of mobile LIDAR data acquired from urban roads based on eigenvalue ratios and support vector machine, *Journal of the Korean Cadastre Information Association*, Vol. 18, No. 2, pp. 195-206. (in Korean with English abstract)
- Kim, E.M. and Cho, D.Y. (2012), Comprehensive comparisons among LIDAR filtering algorithms for the classification of ground and non-ground points, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 30, No. 1, pp. 39-48. (in Korean with English abstract)
- Lalonde, J.F., Vandapel, N., Huber, D.F., and Hebert, M. (2006), Natural terrain classification using three-dimensional LIDAR data for ground robot mobility, *Journal of Field Robotics*, Vol. 23, Issue 1, pp. 839-861.
- Lee, G.W. and Son, H.U. (2016), *Geo-Spatial Information System*, Goomibook, Seoul.
- Lee, J.H. and Lee, D.C. (2010), LIDAR data segmentation using aerial images for building modeling, *Journal of the Korean Society of Surveying, Geodesy, Photogrammetry and Cartography*, Vol. 28, No. 1, pp. 47-55. (in Korean with English abstract)
- Lee, S.J., Park, J.Y., and Kim, E.M. (2014), Development of automated model of tree extraction using aerial LIDAR data, *Journal of the Korea Academia-Industrial cooperation Society*, Vol. 15, No. 5, pp. 3213-3219. (in Korean with English abstract)
- Lehtomäki, M., Jaakkola, A., Hyypä, J., Lampinen, J., Kaartinen, H., Kukko, A., Puttonen, E., and Hyypä, H. (2015), Object classification and recognition from mobile laser scanning point clouds in a road environment, *IEEE Transactions on Geoscience and Remote Sensing*, Vol. 54, No. 2, pp. 1226-1239.
- NGII. (2015), *A Study on the Construction of Precision Road Map for the Support of Autonomous Vehicle*, Research report, National Geographic Information Institute, Korea, pp. 23-93.
- Park, S., Kim, K.J., Lee, J.S., and Lee, S.R. (2011), Red tide prediction using neural network and SVM, *The Institute of Electronics Engineers of Korea-Signal Processing*, Vol. 48, No. 5, pp. 39-45. (in Korean with English abstract)
- Rusu, R.B. and Cousins, S. (2011), 3D is here: point cloud library (pcl). *IEEE International Conference on Robotics and Automation*, 9-13 May, Shanghai, China, pp. 1-4.
- So, J.H. and Moon, Y.J. (2018), Plan for autonomous cooperation driving safety and infrastructure implementation, *The Journal of The Korean Institute of Communication Sciences*, Vol. 35, No. 5, pp. 37-43.
- Sun, Y., Wang, C., Li, J., Zhang, Z., Zai, D., Huang, P., and Wen, C. (2016), Automated segmentation of LIDAR point clouds for building rooftop extraction, *IEEE International Geoscience and Remote Sensing Symposium*, 10-15 July, Beijing, China, pp. 1472 – 1475.
- Wikipedia. (2005), Normal distribution curve that illustrates standard deviations, *Wikimedia Foundation, Inc.*, URL: https://en.wikipedia.org/wiki/Standard_deviation (last date accessed: 10 November 2018).
- Wikipedia. (2010), Result of connected region labeling using two-pass raster scan, *Wikimedia Foundation, Inc.*, URL: https://en.wikipedia.org/wiki/Connected-component_labeling(last date accessed: 10 November 2018).
- Yoo, H.H., Kim, E.M., and Chung, D.K. (2005), Assessment of classification accuracy of ground and non-ground points from LIDAR data, *Journal of The Korean Society of Civil Engineers*, Vol. 25, No. 6D, pp. 929-935. (in Korean with English abstract)
- Zhang, K. and Whitman, D. (2005), Comparison of three algorithms for filtering airborne LIDAR data, *Photogrammetric Engineering and Remote Sensing*, Vol. 71, No. 3, pp. 313-324.
- Zhang, W., Qi, J., Wan, P., Wang, H., Xie, D., Wang, X., and Yan, G. (2016), An easy to use airborne LIDAR data filtering method based on cloth simulation, *Remote Sensing*, Vol. 8, No. 6, pp. 501-522.