Journal of the Korea Industrial Information Systems Research Vol. 19, No. 2, Apr. 2014
http://dx.doi.org/10.9723/jksiis.2014.19.2.085

모바일 레이저 스캐닝 데이터로부터 철도 시설물 인식에 관한 연구†

(Railway Object Recognition Using Mobile Laser Scanning Data)

LUO CHAO[1], 좌 윤 석[2], 손 건 호[3], 원 종 운[4], 이 석[5]
(Chao Luo, Yoon Seok Jwa, Gun Ho Sohn, Jong Un Won, and Suk Lee)

요 약 본 연구는 MLS 데이터로부터 자동으로 철도 시설물들을 인식하여 시설물 간의 기하학적인 공간정보를 추출하는데 기여 하고자 한다. 본 연구에서 제안된 방법은 9개 주요 철도 시설물(노반, 레일, 철로, 수목, 플렛폼, 방음벽, 철주, 절연체, 고압선)들의 분류를 목적으로 하고 있다. 이를 위해 제안된 방법은 크게 두 단계로 나뉘어 진행된다. 첫 번째 단계에서는 포인트, 라인, 체적과 수직 프로파일 레벨에서 데이터의 맥락 특징(contextual feature)들이 추출된다. 두 번째 단계에서는 CRF(Conditional Random Field)가 맥락 분류자(contextual classifier)로 사용되어 각 데이터 포인트에 객체 정보가 할당되고 철도 시설물들이 분류된다. 사용된 CRF 모델은 다른 맥락 분류자 와는 달리 로컬지역에서 데이터들의 분류정보가 일관성을 유지하게 하는 장점이 있다. 제안된 방법의 성능은 commission과 omission 오류분석을 통해 입증되었다.

핵심주제어 : 철도시설물 인식, Conditional Random Field, 맥락 분류, 모바일 레이저 스캐닝

Abstract The objective of the research is to automatically recognize railway objects from MLS data in which 9 key objects including terrain, track, bed, vegetation, platform, barrier, posts, attachments, powerlines are targeted. The proposed method can be divided into two main sub-steps. First, multi-scale contextual features are extracted to take the advantage of characterizing objects of interest from different geometric levels such as point, line, volumetric and vertical profile. Second, by considering contextual interactions amongst object labels, a contextual classifier is utilized to make a prediction with local coherence. In here, the Conditional Random Field (CRF) is used to incorporate the object context. By maximizing the object label agreement in the local neighborhood, CRF model could compensate the local inconsistency prediction resulting from other local classifiers. The performance of proposed method was evaluated based on the analysis of commission and omission error and shows promising results for the practical use.

Key Words : Railway Object Recognition, Conditional Random Field, Contextual Classifier, Mobile Laser Scanning

† 이 논문은 2013년 국토교통부의 재원으로 철도기술연구개발사업인 철도선로 및 시설물 기반정보 구축 플랫폼 기술 개발 사업(13RAIL-C065004 -01)의 연구비 지원에 의해 연구되었음.
1) 요크대학교 지리정보공학과, 제1저자
2) 요크대학교 지리정보공학과, 제2저자
3) 요크대학교 지리정보공학과, 제3저자
4) 한국철도기술연구원, 교신저자(juwon@krri.re.kr)
5) 한국철도기술연구원, 제5저자

1. 서 론

일반적으로 철도 선로는 지반침식 및 열차바퀴의 마찰로 인한 외부적인 요소에 의해 종종 변형을 유발함에 따라 철도 운행에 따른 승객 안전에 관한 문제가 대두 되어 왔다. 이와 관련해서 철도 선로를 포함하는 시설물들을 효율적으로 관리하여 잠재적 위험요소에 대한 최적의 의사 결정 시스템을 구축하는 연구가 꾸준히 진행되어 왔다. 이런 연구들은 원격탐사로부터 취득된 양질의 3차원 데이터를 이용하여 철도 시설물들의 3차원 공간정보 구축을 목표로 하고 있으며, 더 나아가 기 구축된 지리정보를 최대한 활용하여 철도 시설물들의 위험요소를 효과적으로 모니터링 할 수 있도록 시스템 개발이 요구되어 지고 있다. 현재, 철도 시설물들에 대한 데이터는 주로 MMS (Mobile Mapping System)을 이용하여 철도 선로를 따라 고밀도 레이저 스캐닝 데이터와 영상 정보가 취득 되고 있다. 이를 이용하여 철도 시설물에 대한 3차원 공간정보 모델 구현 기술들이 활발히 개발 되어 지고 있다. 하지만, 현재 까지 핵심 기술로 인식되는 철도 시설물 자동 탐지 기술은 아직 개발 초기에 머물고 있어서 많은 양의 수작업과 품질 확인의 절차가 필요한 실정이다. 따라서 대용량 MMS 데이터를 이용하여 철도시설물들을 자동으로 정확하게 탐지하는 기술 개발이 시급히 요구되어 지고 있다.

2. 연구의 범위 및 연구동향

2.1 연구범위

본 연구 목적은 레이저 스캐닝 데이터로부터 자동으로 철도 시설물들을 탐지하고 분류하는 기술을 개발하는 것이다. 이를 위해 <그림 1>에서와 같이 9개의 주요 철도 시설물들(노반, 레일, 철로, 수목, 플랫폼, 방음벽, 철주, 절연체, 고압선)을 분류 대상 객체로 선정하였다.

2.2 연구동향

최근 철도 시설물 및 전력선들을 포함하는 공공시설물 들을 효과적적으로 관리하기 위해 레이저 스캐닝데이터와 영상으로부터 관련된 객체들의 탐지 및 모델링에 대한 연구가 활발히 진행되고 있다. Neubert[1]은 5cm GSD(Ground Sample Distance)을 갖는 고해상도 영상을 이용하여 철도 선로를 추출하였다. 먼저 HT(Hough Transformation) 이용하여 선형 객체들을 추출한 후 Fourier Transformation을 이용하여 노이즈를 줄였다. 영상마다 다른 radiometric 특징을 갖기 때문에 수동으로 적절한 값을 부여하여 처리되었다. 최종적으로 감독 분류를 수행하여 철도 선로를 탐지하였다. 또한, 레이저 데이터로부터 수동으로 객체를 분류하고 RANSAC (RANdom SAmple Consensus)을 수행하여 철도 선로를 추출하였다. 추출된 선로로부터 지식 기반 분류 방식을 이용하여 주변 시설물들을 탐지하였다. Beger[2]은 철도 선로의 중심라인 추출을 위해 영상처리 기법을 적용하여 탐색영역을 줄이고 라인과 아크를 이용하는 수학적 철도 선로 모델을 RANSAC을 기반으로 레이저 데이터에서 최적의 모델 변수들을 계산하였다. 기타 공공 시설물인 파이프와 전력선 및 도로 시설물들을 탐지하고 추출하는 연구들도 수행되었다[3,4]. 하지만, 언급된 연구들은 객체들의 기하학적 구조에 대한 지식을 기반으로 수행됨에 따라 객체를 탐지하고 모델링하는 정확도면에서 한계를 나타내었다. 이를 보완하기 위해 학습(machine learning)을 통한 접근 방식이 최근 널리 사용되고 있다. Golovinskiy[5]와 Ishikawa[6]은 SVM (Support Vector Machines) 분류자를 이용하여 객체 추출 연구를 제안하였다. Siegemund[7]은 CRF (Conditional Random Field)을 기반으로 실시간으로

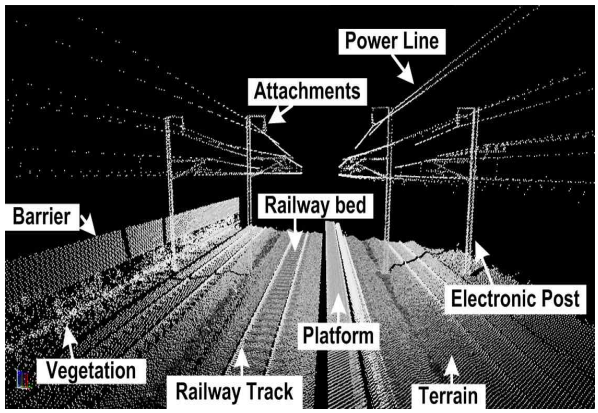

<그림 1> 주요 철도 시설물 객체
<Fig. 1> Railway objects of interest

도로 경계석을 탐지하였다. 사용된 CRF는 객체관련 속성(feature)들 간의 맥락 관계(contextual relation)을 모델링하는 기술로서 객체분류 시 중요한 역할을 한다.

3. 철도 시설물 분류 알고리즘

본 연구에서 제안된 방법은 <그림 2>와 같이 학습을 통해 선정된 9개의 주요 철도 시설물들의 맥락 정보를 추출하고 TIN(Triangulated Irregular Network)을 이용하여 점들 간의 인접 그래프를 형성 한 후 CRF모델 파라미터들을 계산한다. 마지막으로 실험 데이터에서 각 점에 최적의 객체 클래스를 추정하여 분류 작업을 수행한다. 각 처리단계는 Visual C++ 프로그램밍 디버거 및 MATLAB에서 제공되는 함수들을 이용하여 개발되었다.

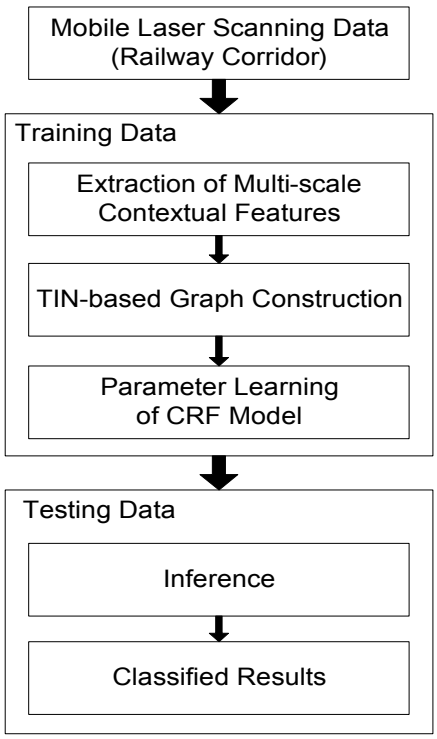

<그림 2> 전체 프로세스 흐름도
<Fig. 2> Workflow of proposed method

3.1 다중 맥락 특징 추출

지역적 탐색결과 객체간의 기하학적인 속성정보의 유사함 때문에 객체 인식을 수행하는 과정에서 오류들이 발생한다. 이를 개선하기 위해 각 객체들과 그 주변의 데이터 분포로부터 맥락특징 (Contextual Feature)을 추출하는 것이 중요하다. 본 연구에서는 <표 1>에서와 같이 4개 레벨, 점, 선, 체적, 수직 프로파일(Point, Line, Volumetric Space, Vertical Profile)에서 특징벡터(Feature Vector)들을 추출하였다[8,9].

<표 1> 다중 스케일 맥락 특징
<Table 1> Multi-scale contextual feature

Level	Feature
Point	- Elevation - Intensity - Range - Height from DTM ground
Line	- Line length - Line slop - Line height
Volumetric Space	- Roughness of the estimated surface - Distance to the estimated surface - 2D point density - Point density ratio (2D/3D) - Sphericity - Anisotropy - Linearity-based HT
Vertical Profile	- Number of occupied segments - Number of continuously occupied segments - Number of continuously empty segments

Point-level: 점 레벨에서는 각 점 별로 그의 주변 점들의 탐색하여 특징 벡터들이 계산된다. 고도(Elevation)와 레이저 강도(Intensity)는 원시 자료로부터 추출하였고, 거리(Range)는 각 점과 객체의 중심과의 거리를 의미한다. 높이(Height)는 DTM(Digitial Terrain Model)로부터 각 점까지의 높이 값을 의미한다. 여기서, DTM은 Sohn[10]에 의해 제안된 RTF (Recursive Terrain Fragmentation) 필터를 이용하여 형성되었다.

Line-level: 선 레벨에서 각 특징 벡터들은 철도 선로 방향으로 0.5m 폭을 갖는 탐색 영역으로부터 계산된다. 탐색 영역에 속한 점들은 먼저 수직 평면으로

투영된 후, 가능한 라인 벡터들이 RANSAC 알고리즘을 이용하여 추출되고 길이(Length)와 기울기(Slop)가 계산된다.

Volumetric Space-level: 체적 레벨에서는 각 점별로 3차원 탐색 공간(Voxel)을 형성하여 해당되는 점들의 기하학적인 특성들을 추출한다. 거친 정도(Roughness)와 거리(Distance)는 해당 점들로부터 구성된 평면과 점 사이의 관계로부터 계산된다. 2차원 점 밀도(2D point density)와 점 밀도 비율(point density ratio)는 탐색 공간에서 분포되는 점들의 양을 이용하여 계산된다. 구형도(Sphericity)과 이방성(Anisotropy) 및 선형성(Linearity)는 고유치(Eigenvalue) 분석을 통해 추정된다[11].

Vertical Profile-level: 수직 프로파일 레벨에서는 3차원 공간을 수직을 따라 분할하여 점들이 포함된 해당 공간들의 연속성을 분석하여 특징 벡터들을 추출하였다.

제안된 4개 레벨에서 총 17개의 가능한 특징벡터들이 계산될 수 있다. 하지만, 모든 특징벡터들을 사용할 경우 벡터 상호간의 상관도(Correlation)와 계산 복잡성(Computational Complexity)을 증가시켜 객체 분류 정확도를 떨어뜨리는 결과를 초래한다. 이와 같은 문제점을 해결하기 위해 본 연구에서는 PCA(Principle Component Analysis)을 이용하여 두드러진 특징벡터를 선택하여 사용되는 벡터의 차원을 감소시켰다.

3.2 맥락 분류자

지역 분류자(Local Classifier)는 해당 객체들 사이에 맥락관계 설정 부분이 없어 알고리즘 적용이 용이하기 때문에 일반적으로 쉽게 사용된다. 하지만, 국부적으로 객체특징들의 유사성 때문에 종종 분류 오류를 발생시킨다. 위와 같은 문제점들을 최소화하기 위해 본 연구에서는 널리 사용되는 맥락 분류자(Contextual Classifier)로서 CRF 모델을 이용하여 객체들 사이에 맥락 관계를 고려하였다. 이런 관계설정을 용이하게 하기위해 TIN을 이용하여 점들 간에 인접그래프를 구성하였다[12].

관측치인 점 클래스를 X라 하고 철도 시설물 객체 클래스를 Y라고 하면, CRF 모델의 일반적인 수식은 다음과 같이 나타낼 수 있다.

$$p(Y \mid X) = \frac{1}{Z(X)} \exp\left(\sum_{i \in S} A_i(X, y_i) + \sum_{i \in S} \sum_{j \in N_i} I_{ij}(X, y_i, y_j)\right) \quad (1)$$

위 수식에서 i와 j는 해당 점과 그의 주변 점들을 나타내는 색인이고 S와 N는 각각의 총 점수이다. Z(X)는 분할함수(Partition Function)이며 A(X,y)와 I(X,y)는 각각 연계(Association)와 상호(Interaction) 퍼텐셜을 나타낸다. P(Y|X)는 사후 가설(Posterior Probability)이다.

연계 퍼텐셜, A_i,은 각 객체 클래스가 얼마나 정확하게 해당 포인트에 할당 되었는지를 정량적으로 측정하고 점들 간의 관계는 무시된다. 이 항목은 다음 식에서 주어진 특징벡터에서 각 객체 클래스와 점들 사이의 조건 확률(Conditional Probability)로 나타낼 수 있다. 여기서, 조건 확률은 GMM-EM(Gaussian Mixture Model – Expectation and Maximization)를 통해 계산된다[9].

$$A_i(X, y_i) = \log(P(y_i|X)) \quad (2)$$

상호 퍼텐셜, I_{ij},는 해당 점이 주변 점들에 부여된 객체 클래스와의 상관관계를 정량적으로 측정한다[13].인접 그래프 모델에서 두 점 i와 j가 연결되어 에지가 형성되면 I_{ij}는 무게 벡터, w와 각 에지에서 계산되는 상호 퍼텐셜 u를 이용하여 다음과 같이 나타낼 수 있다.

$$I_{ij}(X, y_i = l, y_j = k) = w_{l,k} u_{ij}(X) \quad (3)$$

상호 퍼텐셜은 두 인접 점들이 같은 객체 클래스로 할당되는 경우를 선호하고 반대인 경우 벌점(Penality)이 부과 된다. 사용된 무게와 벌점의 정도는 학습데이터를 이용하여 파라미터 학습(Parameter Learning)을 통해 추정된다. 본 연구에서는 L-BFGS(Limited memory Broyden Fletcher Goldfarb Shanno)방법을 이용하여 파라미터 학습을 수행하였다[14].

마지막으로, 실험데이터에서 구성된 인접 그래프를 이용하여 각 점에 최적의 객체 클래스를 추정(Inference)하여 부여한다. 이를 위해 널리 사용되고 있는 LBP (Loopy belief propagation)을 사용하였다. LBP의 수행과 CRF 모델 파라미터 추정하는 더 자세한 설명은 Vishwanathan[15]을 참조하면 된다.

4. 실험 및 결과

본 연구에 사용된 MLS 데이터는 캐나다 Optech사의 Lynx M1 레이저를 장착한 MMS(Mobile Mapping System)을 화차위에 부착하여 50 - 70 km/h의 속도로 의왕과 천안 지역사이에 경부선을 따라 2012년 1월 6일 취득 되었다. <그림 3>와 같이 실험 대상 지역의 크기는 300m(세로)x250m(가로) 이고 1603671 레이저 포인트를 포함하고 있으며 평균점밀도는 철도선로 주변으로 300 점/m^2 이상을 나타낸다.

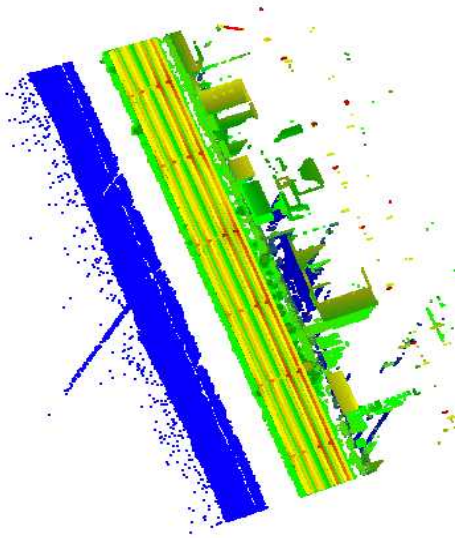

<그림 3> 모바일 레이저 스캐닝 데이터
<Fig. 3> Mobile laser scanning data set

제안된 방법의 성능을 분석하기 위해 객체 분류에 대한 오류를 오검출(Commission Error)과 미검출(Omission Error) 항목을 이용하여 <표 2>와 같이 분석하였다. 오검출은 실험데이터에서 분류된 점들의 객체 속성이 기준데이터에는 상이 하게 분류된 경우 발생한다. 이와 반대로, 미검출은 기준데이터의 점들의 객체 속성이 실험 데이터에는 다르게 분류된 경우 발생한다. 실험 데이터에서 철도 시설물들을 구성하는 주요 9개 객체들의 점들을 전체 점의 수로 나누어 비율을 계산 한 결과 가장 두드러진 객체는 노반(51.6%)이고, 반면에 절연체(0.6%)는 가장 낮은 비율을 나타내었다. 따라서 비율이 낮은 객체 일수록 분류 오류에 대해 민감하게 반응 하였다. 오검출에서는 객체 크기가 작은 객체인 철주와 연결되어 있는 고압선(15.7%)과 절연체(14.4%)에서 가장 큰 분류 오류를 나타내었다. 미검출에서는 절연체(52.2%) 뿐만 아니라 레일(27.9%), 철로(15.3%), 철주(14.4%), 수목(13.4%)에서도 비교적 큰 분류 오류를 나타내었다. 여기서, 오류 값들은 각 객체에서 해당 부분을 100%로 가정하여 계산되었다. 본 연구에서 실험결과 제안된 방법이 오검출보다 미검출에서 더 큰 오류을 나타냄에 따라 향후 맥락 분류자의 상호 포텐셜 부분을 개선시킴으로써 미검출 분류 오류를 줄일 수 있는 여지가 있다고 판단된다. 결과적으로, 오검출과 미검출 오류를 모두 고려하여 전체 분류 정확도는 94.3%로 높게 산출되었다.

<표 2> 오검출과 미검출 오류
<Table 2> Commission and Omission Errors

Object	Portion (%)	Commission Error (%)	Omission Error (%)
Terrain	51.6	8.0	0.9
Railway Track	5.4	9.9	27.9
Railway Bed	11.1	3.9	15.3
Platform	17.2	0.29	0
Barrier	3.7	2.0	1.4
Vegetation	6.0	1.8	13.4
Power Line	3.0	15.7	1.6
Electric Post	1.5	8.5	14.4
Attachments	0.6	14.4	52.2

<그림 4>은 실험데이터에서 모바일 레이저 점들을 선정된 9개의 철도 시설물로 분류한 최종결과를 각기 다른 색을 이용하여 표현하였다.

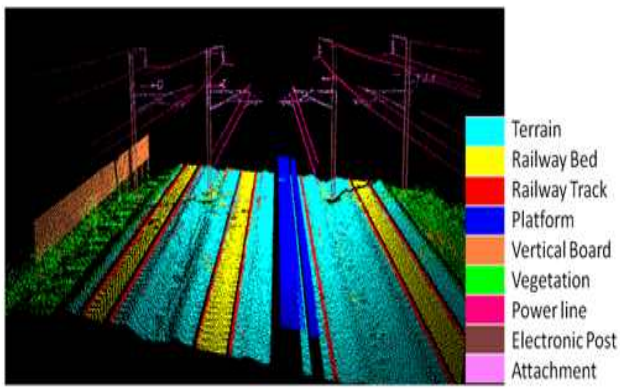

<그림 4> 9개 철도시설물 분류 결과
<Fig. 4> Classification results

5. 결론 및 향후연구

본 연구는 모바일 레이저 스캐닝 데이터로부터 CRF 모델을 기반으로 9개 주요 철도시설물 객체들을 추출하였다. 철도 시설물들의 탐지 정확도를 높이기 위해 4가지 다른 기하학적 레벨에서 각 점과 그의 주변을 조사하여 가능한 맥락특징들을 추출하고 두드러진 특징들만을 선정하여 CRF 모델 파라미터를 추정하는데 사용되었다. 또한, 객체들 간의 공간적인 인접관계를 규정하기위해 인접그래프를 구성하여 객체 서로간의 맥락정보들이 고려되었다. 하지만, 점 밀도가 철도 중앙 벡터라인으로부터 멀어질수록 급격히 낮아지고, 각 포인트의 intensity 값이 보정이 되어 있지 않은 점은 객체 분류정확도에 영향을 주었다고 판단된다. 따라서 데이터 취득 시 레이저 스캐너 운용 및 데이터에 대한 보정이 선행되어야 한다. 추가로, 제안된 방법이 근거리 인접 점들에 대해서만 맥락관계를 규정함에 따라 CRF 모델이 다소 데이터의 노이즈에 민감하여 특히 작은 객체들에 대해서 더 큰 분류오류가 발생하였다. 향후 연구 방향으로는 점들 간에 추가적인 공간적 맥락정보인 장거리 의존성(long distance dependency)와 고차원 의존성(higher order dependency)을 고려하여 CRF 모델이 노이즈에 대한 민감도를 감소시켜 객체들의 분류 정확도를 향상 시킬 수 있는 연구가 필요하다고 판단된다.

References

1] M. Neubert, R. Hecht, C. Gedrange, M. Trommler, H. Herold, T. Kruger, F. Brimmer, “Extraction of Railroad Objects from Very High Resolution Helicopter-borne LiDAR and Ortho-image Data”, International Archives of Photogrammetry, Remote Sensing and Spatial Information Sciences, Vol. 38, No. 4, pp. 25-30, 2008.

[2] B. Beger, C. Gedrange, R. Hecht, M. Neubert, “Data Fusion of Extremely High Resolution Aerial Imagery and LiDAR Data for Automated Railroad Centre Line Recontruction”, ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 66, No. 6, pp. 40-51, 2011.

[3] J. Yoon, M. Sagong, J. Lee, K. Lee, “Feature Extraction of a Concrete Tunnel Liner from 3D Laser Scanning Data”, NDT&E International, Vol. 42, No. 2, pp. 97-105, 2009.

[4] S. Pu, M. Rutzinger, G. Vosselman, S. Oude Elberink, “Recognizing Basic Structures from Mobile Laser Scanning Data for Road Inventory Studies”, ISPRS Journal of Photogrammetry and Remote Sensing, Vol. 66 No. 6, pp. 28-39, 2011.

[5] A. Golovinskiy, V. G. Kim, T. Funkhouser, “Shape-based Recognition of 3D Point Clouds in Urban Environments”, Computer Vision, pp. 1-8, 2009.

[6] K. Ishikawa, F. Tonomura, Y. Amano, T. Hashizume, “Recognition of Road Objects from 3D Mobile Mapping Data”, International Journal of CAD/CAM, Vol. 13, No. 2, pp. 41-48, 2013.

[7] J. Siegemund, D. Pfeiffer, U. Franke, W. Forstner, “Curb Reconstruction using Conditional Random Fields”, 2010 IEEE Intelligent Vehicles Symposium, pp. 203-210, 2010.

[8] H. B. Kim, G. Sohn, “3D Classification of Power-line Scene from Airborne Laser Scanning Data using Random Forest”, International Archives of Photogrammetry and Remote Sensing, Vol. 38, No. 3A, pp. 126-132, 2010.

[9] G. Sohn, I. Dowman, “A Model-based Approach for Reconstructing Terrain Surface from Airborne LiDAR Data”, Photogrammetric Record, Vol. 22, No. 119, pp. 170-193, 2008.

[10] N. Chehata, L. Guo, C. Mallet, “Airborne LiDAR Feature Selection for Urban Classification Using Random Forests”, International Archives of Photogrammetry and Remote Sensing, Vol. 38,

No. 3, pp. 207-212, 2009.
[11] E. H. Lim, S. David, "3D Terrestrial LiDAR Classifications with Super-voxels and Multi-scale Conditional Random Fields", Computer-Aided Design, Vol. 41, No.10, pp. 701-710, 2009.
[12] C. Luo, G. Sohn, "Line-based Classification of Terrestrial Laser Scanning Data using Conditional Random Field", International Archives of Photogrammetry and Remote Sensing, Vol. 40, No. 7, pp. 155-160, 2013.
[13] S. Kumar, M. Hebert, "Discriminative Random Fields", International Journal of Computer Vision, Vol. 68, No.2, pp. 179-201, 2006.
[14] D. C. Liu, J. Nocedal, "On the Limited Memory BFGS method for Large Scale Optimization", Mathematical Programming, Vol. 45, No. 1-3, pp. 503-528, 1989.
[15] S. V. N. Vishwanathan, N. N. Schraudolph, M. W. Schmidt, K. P. Murphy, "Accelerated Training of Conditional Random Fields with Stochastic Gradient Methods", 23rd International Conference on Machine Learning, pp. 969-976, 2006.

Luo Chao

- York University, Geomatics Engineering
- 박사과정 재학 중
- 관심분야 : 객체분류

좌 윤 석 (Yoon Seok Jwa)

- York University, Geomatics Engineering
- 포닥 연구원
- 관심분야 : 철도시설물 및 도시 모델링

손 건 호 (Gun Ho Sohn)

- York University, Geomatics Engineering
- 부교수
- 관심분야 : 증강 현실, BIM, 도시 모델링

원 종 운 (Jong Un Won)

- 정회원
- 한국철도기술연구원 선임연구원
- 관심분야 : 영상신호처리, 사물인터넷

이 석 (Suk Lee)

- 정회원
- 한국철도기술연구원 선임연구원
- 관심분야 :

논 문 접 수 일 : 2014년 03월 10일
1 차 수 정 완 료 일 : 2014년 03월 31일
2 차 수 정 완 료 일 : 2014년 04월 09일
게 재 확 정 일 : 2014년 04월 11일