

가상 환경에서의 딥러닝 기반 폐색영역 검출을 위한 데이터베이스 구축 Construction of Database for Deep Learning-based Occlusion Area Detection in the Virtual Environment

김경수¹ · 이재인^{1*} · 곽석우^{1*} · 강원울² · 신대영³ · 황성호^{1*}

Kyeong Su Kim¹, Jae In Lee¹, Seok Woo Gwak¹, Won Yul Kang², Dae Young Shin³
and Sung Ho Hwang^{1*}

Received: 23 May. 2022, Accepted: 17 Aug. 2022

Key Words : Virtual Environment(가상환경), Database(데이터베이스), Deep Learning(딥러닝), Object Detection(객체 인식), Image Segmentation(이미지 세그멘테이션), Occlusion Area(폐색 영역), RDBMS(관계형 데이터베이스 관리 시스템)

Abstract: This paper proposes a method for constructing and verifying datasets used in deep learning technology, to prevent safety accidents in automated construction machinery or autonomous vehicles. Although open datasets for developing image recognition technologies are challenging to meet requirements desired by users, this study proposes the interface of virtual simulators to facilitate the creation of training datasets desired by users. The pixel-level training image dataset was verified by creating scenarios, including various road types and objects in a virtual environment. Detecting an object from an image may interfere with the accurate path determination due to occlusion areas covered by another object. Thus, we construct a database, for developing an occlusion area detection algorithm in a virtual environment. Additionally, we present the possibility of its use as a deep learning dataset to calculate a grid map, that enables path search considering occlusion areas. Custom datasets are built using the RDBMS system.

1. 서 론

최근 무인 이동체에 사용되는 센서 기술의 발달과 주행 환경 인식의 필요성이 높아지면서 카메라와 라이다 센서를 기반으로 주변에 위험도 높은 장애물을 검지하는 연구들이 활발히 개발되고 있다.¹⁻⁵⁾ 특히 기존의 Rule-based 알고리즘으로 해결하기 어

려웠던 인식 문제를 실시간성을 확보한 딥러닝 모델을 사용해 해결함으로써 그 활용도가 매우 높아지고 있다. 이미지 인식과 관련한 알고리즘이 개발되고 관련 프레임워크들이 최적화되면서 관련 대회 및 연구들이 지속적으로 진행되고 있다. 이를 통해 높은 인식률과 실시간성을 보장하는 딥러닝 모델들이 자율주행 자동차와 건설 기계 등에 적용되고 있고 더욱 악조건에서 진행되는 실험에서도 높은 성과를 보이고 있다.

딥러닝 기반의 인식 알고리즘이 개발되면서 모델 학습에 활용되는 데이터 셋의 중요성이 커졌다. 현재 여러 기관에서 오픈 데이터 셋을 배포하고 있지만 대부분의 데이터 셋은 시내 주행환경이 모사되어 있고 날씨와 센서의 위치 등이 다양하지 않아서 실제로 오픈 데이터 셋으로 학습한 딥러닝 모델들은 다양한 환경에서 동일한 수준의 인식률을 보장하지 못

* Corresponding author: hsh0818@skku.edu

1 Department of Mechanical Engineering, Sungkyunkwan University, Suwon 16419, Korea

2 Institute of Vehicle Engineering, Seoul 06640, Korea

3 Korea Institute of Industrial Technology, Cheonan 31056, Korea

Copyright © 2022, KSFC

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.

한다. 이러한 제한된 데이터 셋은 비정형 도로, 학습되지 않은 물체가 많은 건설 환경, 다른 나라의 특징적인 객체들을 인식하기 위한 학습 데이터 셋으로 활용하기 힘들다. 더 정확한 인식 시스템을 개발할 때는 물체와의 충돌을 방지해야 하며, 복잡한 주변 환경 특성을 반영한 센서 사각지대에 대한 처리가 중요하다. 전방 물체에 의해 가려지는 폐색 영역 (occlusion area)이 생기게 되고, 이것은 주행 및 작업 가능 영역에 대한 정확한 판단을 방해하여 안전사고로 이어질 수 있다. 따라서 실제 환경을 모사한 가상 환경에서 여러 시나리오를 제작하여 딥러닝 모델의 학습 데이터로 활용할 수 있는 데이터베이스를 구축하는 것이 필요하다.

따라서 본 논문에서는 실제 한국형 도로와 복잡한 건설 환경을 모사할 수 있는 가상 시뮬레이션을 구성하였고 폐색 영역 처리를 위한 학습용 데이터 셋을 검증하고 구축하기 위해 여러 시나리오에서 데이터를 획득하였다. 검증할 학습용 데이터 셋으로는 Semantic Segmentation 모델을 위한 전방 이미지와 폐색 영역 검출 모델을 위한 높은 위치에서 취득한 드론 이미지로 구성된다. 전방 픽셀 단위로 객체를 검출한 GT (ground truth) 이미지를 드론 이미지로 바꾸기 위해서 Cam2BEV 모델을 사용하였다. 또 Semantic Segmentation 데이터 셋을 검증하기 위해서 BiSeNet 모델을 사용하였다. 최종적으로 가상 환경에서의 폐색 영역에 대한 맞춤형 데이터 셋을 구축함으로써, 실제 복잡한 주행 환경이나 건설 환경에서 대응할 수 있는 딥러닝 모델 학습 데이터 셋을 구축하고자 한다.

2. 가상 환경 구성

2.1 시뮬레이션 구성

딥러닝 모델에 사용할 이미지 데이터를 추출하기 위해 가상 환경을 구축하였다. 가상 환경을 제작하기 위해 맵 데이터는 openCRG 및 openDRIVE를 이용하




Fig. 1 Road and graphic for Cheongna city



Fig. 2 Image dataset from VTD simulator




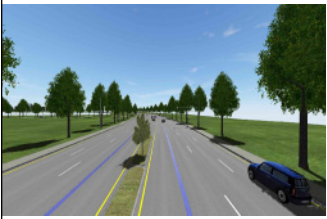
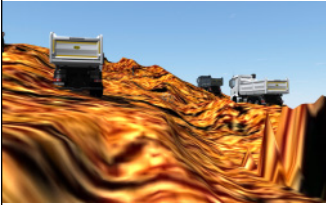
Fig. 3 Data acquisition for construction site

여 제작되었고 실제 도로를 모사하여 VTD (virtual test drive) 시뮬레이터를 사용하였다.

추가적으로 건설 공사 현장의 지도 정보를 얻기 위해 작업환경의 도로 데이터를 라이다를 활용하여 수집하였다. 라이다를 통해 얻은 데이터를 LAS 파일로 저장 후 공사 현장의 노면 데이터를 만들기 위한 CRG 포맷으로 변환하였다. 가상 환경에서 구축된 지도는 Fig. 3과 같으며, 비정형 도로 인식을 위해 현장 이미지와 유사한 텍스처를 입혀 추출하였다.

청라국제도시에서 실제로 운행 중인 이중굴절버스의 노선에 따라 주행하는 시나리오와 굴착기의 현장 거동 시나리오를 제작하여 다양한 구도의 센서 데이터를 얻었다. 픽셀 단위 주행 가능 영역 검출과 폐색 영역 검출을 위한 학습 데이터 셋을 추출하기 위해서 차량, 건물, 건설 장비 등을 배치하였다.

Table 1 Driving scenario

Number	Road type	Objects	Scenario specification	Image
Scenario 1	City, Normal	Car Tree Traffic sign	Ego vehicle : Route tracking Objects : Autonomous mode	
Scenario 2	Construction site, Normal	Excavator Truck Pedestrian	Ego vehicle : Route tracking Objects : Stop Pedestrian: Stop	

2.2 데이터 셋 추출

VTD 시뮬레이터에서 실제 청라국제도시를 모사한 시내 주행 시나리오와 건설 현장을 모사한 공사장 주행 시나리오를 생성하여 전방 이미지와 탑뷰 이미지를 추출하였다. 원본 이미지 파일과 가상 환경에서 구별할 수 있는 클래스에 각각 다른 색깔을 입힌 GT 이미지를 추출하였다. 가상 환경에서 구축한 데이터 셋을 검증하기 위해서 오픈 데이터 셋으로만 학습한 모델과 VTD에서 얻은 데이터 셋을 추가로 학습한 모델의 성능을 비교하였다. 하지만 굴착기, 버스 정류장 등 기존의 오픈 데이터 셋인 Cityscapes에서 포함하지 않는 클래스는 따로 추가하여 학습을 진행했고 중복되는 라벨은 Cityscapes의 형태를 도입하여 정확한 비교가 가능하도록 하였다. 또한 시나리오 주행 노선은 학습, 검증, 테스트 용도를 구별하여 진행했고 학습용 데이터와 검증용 데이터 셋의 비율은 85:15이다.

2.2.1 픽셀 단위 인식을 위한 데이터 셋

차도와 인도를 구분하고 공사 현장에 존재하는 비정형 도로와 다양한 형태의 객체를 정확하게 검출하기 위해서 Semantic Segmentation 모델의 학습용 데이터 셋을 취득하였다. Fig. 4와 같이 시내 주행과 건설 현장 주행 시나리오를 구분하여 이미지 데이터를 취득하였고 Segmentation 모델을 위한 입력 데이터는 원본 이미지와 GT 이미지를 학습에 용이한 형태로 변형한 그레이 스케일의 이미지로 구성하였다.

VTD에서 구축하는 학습용 데이터 셋이 기존의 모델 인식률에 주는 영향력과 적합성을 판단하기 위해

서 오픈 데이터 셋으로만 학습한 Segmentation 모델 가중치와 VTD 데이터를 추가 학습한 모델 가중치를 비교하였다. 청라국제도시를 모사한 가상 환경에서 얻은 이미지 데이터에는 오픈 데이터 셋인 Cityscapes에서 구분하지 않은 클래스(버스 정류장)를 기타 영역으로 분류하여 구분하도록 하였다.




Fig. 4 Process of training dataset from VTD

2.2.2 폐색 영역 인식을 위한 데이터 셋

인식된 객체가 시야의 일부를 가리기 때문에 생기는 음영지역은 정확한 경로 판단을 방해한다. 따라서 각각의 객체의 크기와 모양을 딥러닝 모델을 통해 학습하여 가려진 부분을 폐색 영역으로 구분한다면 더 정확한 주변 환경 인식을 가능하게 한다. 이를 위해 uNetXST 모델을 사용하여 센서의 제원에 맞는 시야각과 음영지역을 구분하는 드론 이미지를 생성하였다. 딥러닝 모델을 학습하기 위해서 센서의 파라미터, 전방 Segmentation 결과 이미지와 폐색 영역이 전처리된 탑뷰 GT 이미지가 사용된다. 가상 환경에서 전방 GT 이미지와 탑뷰 GT 이미지를 추출하고 카페




Fig. 5 Image transformation with top view



Fig. 6 Preprocessing of occlusion area

라 제원에 맞춰 시야각과 물체에 대한 폐색 영역을 회색으로 바꾸는 전처리를 수행했다. 가상 환경에서 폐색 영역 인식을 위한 학습용 데이터 셋을 검증하기 위해서 사용된 알고리즘은 Cam2BEV 이다. 학습용 데이터 셋 검증을 거친 데이터는 최종적으로 구축된 데이터베이스에 분류되었다.

가상 환경에서 얻을 수 있는 전방 Segmentation 검출 GT 이미지와 탐부 GT 이미지를 활용하여 폐색 영역 검출을 위한 데이터 셋을 얻었다. 탐부의 구도와 센서의 제원을 통해 탐부 이미지마다 폐색 영역을 회색으로 처리한 이미지를 생성하였고 이것을 폐색 영역 검출 알고리즘인 Cam2BEV 모델의 학습에 활용하였다.

3. 데이터베이스 검증

3.1 픽셀 단위 인식 검증

주행 환경을 고려해 실시간성이 확보된 Semantic Segmentation 알고리즘 중에 높은 인식률을 보이는 BiSeNet v2 모델을 사용하여 데이터를 검증하였다. 인식 과정에서 생기는 픽셀 단위의 노이즈는 강건한 경로 판단을 방해한다. 이를 해결하기 위해 픽셀 단위 인식 모델에는 다양한 데이터를 학습해야 하며 실차와 가상 환경의 이미지를 학습하여 결과적으로 가상 환경에서 더 높은 인식률을 보였다.




Fig. 7 (a) Original image, (b) Result by open datasets, (c) Result by VTD datasets

BiSeNet 딥러닝 모델을 사용하여 공사 현장에서 전방 이미지를 검출하여 시나리오 2번의 전방 데이터 셋을 검증하였다. 가상 환경에 구축된 공사 현장 이미지를 검출한 결과 사진을 통해 잘 학습됨을 확인할 수 있었다. 전방의 객체와 비정형 도로가 정확하게 구분되지 않고 뭉개지는 현상을 발견할 수 있지만 객체의 형태와 종류를 구별하여 사용할 수 있어 적합한 데이터 셋임을 검증하였다.




Fig. 8 (a) Front image, (b) Reference image, (c) Detected image

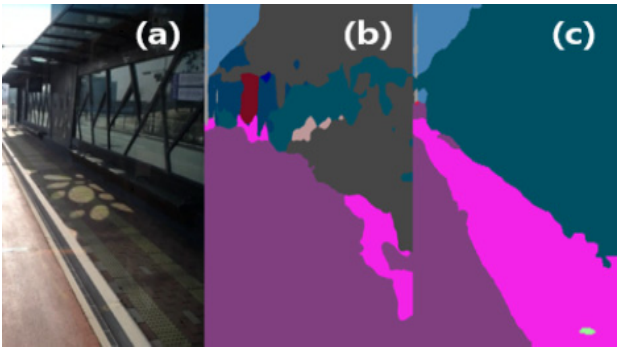


Fig. 9 (a) Bus stop image, (b) Result by open datasets, (c) Result by VTD datasets

추가적으로 Cityscapes 데이터만을 학습한 Segmentation 모델과 VTD에서 추출한 청라지구 데이터를 추가로 학습한 모델의 검출 차이를 확인하였다. 특히 Cityscapes에서는 제공되지 않는 버스 정류장, 한국형 노면 표시 등의 인식 개선을 확인하였다. 오픈 데이터 셋으로만 학습한 검출 결과에서는 버스 정류장을 건물과 기차와 같은 형태로 인식하였지만 VTD 데이터를 추가로 학습한 검출 결과에서는 버스 정류장을 비교적 정확하게 검출하는 것을 확인할 수 있었다. 이로써 오픈 데이터 셋과 가상 환경에서 구축한 데이터 셋을 통해 실제 주행 이미지에서 객체를 검출할 때 인식률을 향상됨을 확인했다. 또한 현재 제공되는 오픈 데이터 셋은 다양한 환경과 객체들을 포함하고 있지 않아서 실제 주행 환경에서 사용될 때 정확하게 객체를 검출하지 못할 수 있지만 가상 환경에서 제공되는 데이터 셋을 추가 학습한다면 인식 성능을 개선할 수 있음을 검증하였다.

가상 환경에 구축된 공사 현장 이미지 데이터를 Segmentation 딥러닝 모델을 사용하여 학습했고 가상 환경에서 잘 인식됨을 확인할 수 있었다. 추가적으로 가상 환경에서 얻은 데이터 셋을 기존의 오픈 데이터 셋인 Cityscapes로 학습한 가중치에 추가 학습하여 실제 환경에서 검출을 진행하였다. Fig. 10의 원본 이미지는 흔히 도시에서 볼 수 있는 아스팔트 도로가 아닌 비정형 도로로 구성된 이미지이다. 이것을 오픈 데이터 셋으로 검출하였을 때 비정형 도로의 형상을 잘 검출하지 못하고 공사 현장에 존재하는 여러 객체들을 구분하지 못하는 것을 알 수 있다. 따라서 가상 환경에서 얻은 데이터 셋을 추가 학습하여 검출했을 때 비정형 도로에 대한 인식률이 개선됨을 확인하여 데이터베이스를 검증하였다.

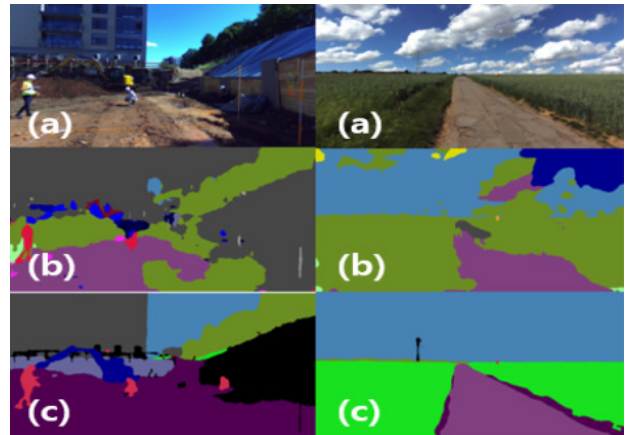


Fig. 10 (a) Original image, (b) Result by open datasets, (c) Result by VTD datasets

3.2 폐색 영역 인식 검증

전방의 물체 때문에 가려져 생기는 폐색 영역을 검출하기 위한 딥러닝 모델의 학습용 데이터 셋을 가상 환경을 통해 구축하였고 uNetXST 모델을 사용하여 데이터 셋의 유효성을 검증하였다. 본 연구에서 사용한 딥러닝 모델은 Semantic Segmentation의 결과 이미지를 탐부로 변환하여 각 클래스마다 다르게 학습된 모양과 크기를 시야각에 맞게 폐색 영역을 검출하게 된다. 건설 환경에서 구축한 데이터 셋을 딥러닝 모델을 학습하였고 Fig. 11에서 볼 수 있듯이 정답과 유사한 형태로 폐색 영역을 검출하였다. 이를 통해 정확한 폐색 영역을 구분하여 안전 감시 시스템을 강건하게 개발할 때 사용될 수 있다.




Fig. 11 (a) Top view reference image, (b) GT image with occlusion, (c) Detected image




Fig. 12 Result of dealing occlusion

시내 주행 검출 이미지에 폐색 영역 검출 알고리즘을 적용한 결과 탐부로 변환하면서 생기는 늘어지는 객체(파란색)가 본래의 크기에 맞게 보정되었고 객체 뒤로 생기는 영역을 회색으로 폐색 영역을 구분하면서 정확한 탐부 변환이 이루어졌다.

3.3 데이터베이스 활용

가상 환경에서 얻은 전방 이미지를 Segmentation 딥러닝 모델에 적용 가능함을 확인하였고 폐색 영역 검출 모델에도 학습용 데이터 셋으로 적절한지 검증하였다. 두가지 데이터 셋은 경로 판단을 돕기 위한 격자 지도 생성에 활용된다면 물체가 가려져 정확한 경로를 생성하기 힘든 문제를 해결할 수 있을 것이다.

검증된 학습용 데이터는 체계적이고 용이하게 관리하기 위해서 DBMS (database management system)을 개발하였다. MySQL을 활용하여 데이터베이스에 쉽

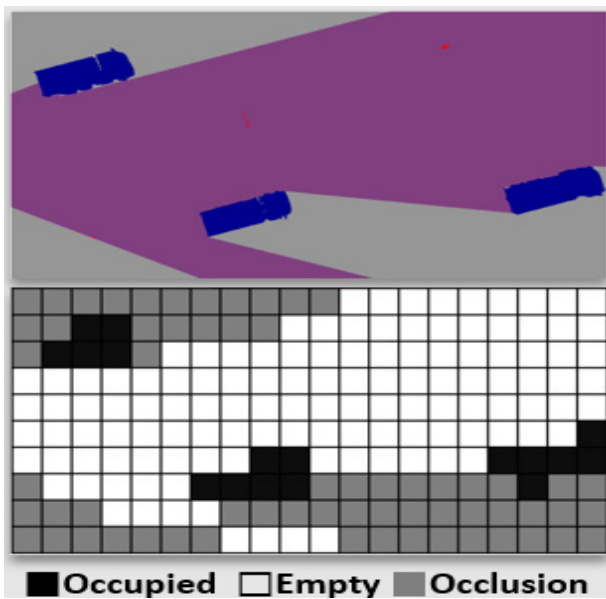


Fig. 13 Grid map with detection of occlusion




Fig. 14 Structure of DBMS

게 접근할 수 있는 웹 서버를 구축하였다. 웹 서버에서 사용자가 특정 데이터를 요구하면 스크립트 실행을 요청하여 사용자가 특정 데이터에 접근할 수 있도록 하였다. 본 연구에서는 가상 환경에서 제공되는 날씨, 센서의 제원 및 구도 등을 데이터 특징으로 구별하여 사용자가 원하는 형태의 데이터 셋을 얻을 수 있도록 구축하였다.

4. 결론

본 연구를 통해 픽셀 단위 인식 모델과 폐색 영역 인식 모델을 위한 학습용 데이터 셋을 가상 환경에서 제작하고 그 타당성을 검증하였다. 기존의 오픈 데이터 셋을 활용할 때 사용자는 본인의 환경과 다른 환경으로 구성된 학습 데이터를 딥러닝 모델에 활용되게 되고 이것은 인식을 저해 원인이 되었다. 특히 제공된 오픈 데이터 셋에는 없는 객체이거나 특수한 상황의 데이터를 검출하기에 충분한 학습을 진행할 수 없는 한계점이 있다.

가상 환경에서 진행되는 학습 데이터 셋 구축은 다양한 시나리오와 환경을 구성할 수 있고 가상 환경에서 제공되는 여러 정보들을 SQL 형식으로 사용자가 원하는 데이터를 쉽게 접근할 수 있게 데이터베이스를 구축하였다. 또한 기존의 실차 기반의 오픈 데이터 셋으로 구현하기 힘든 탐부 형식의 데이터 셋을 제공하면서 폐색 영역 검출을 위한 데이터 셋을 구축하고 그 타당성을 검증하였다. 구축한 데이터 셋은 가상 환경과 실제 주행 이미지를 통해 검증되었고 오픈 데이터 셋을 학습한 기존의 가중치에 추가로 구축된 데이터 셋을 학습시켜 인식 성능을 개선하였다. 추후 연구를 진행하면서 본 연구에서는 전방 이미지만 다루었지만 다양한 센서의 위치와 종류를 고려한 데이터베이스를 구축할 예정이다. 또한 전방 Segmentation 결과와 폐색 영역 검출 결과를 활용해 안전 감시 시스템과 자율주행 시스템의 안정성을 높이는 연구를 진행할 계획이다.

후 기

본 연구는 국토교통부/국토교통과학기술진흥원 교통물류연구사업의 연구비지원 (22TLRP-C152478-04) 과 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업의 연구결과로 수행된 결과물입니다. (IITP-2022-2018-0-01426)

이해관계(CONFLICT OF INTEREST)

저자는 이 논문과 관련하여 이해관계 충돌의 여지가 없음을 명시합니다.

References

- 1) H. J. Jang, et al. "A Study on the Construction of Deep Learning Dataset based on Virtual Lidar Sensor Point Cloud", Kookmin University, 2019.
- 2) S. J. Yoon et al. "Development of Autonomous Vehicle Learning Data Generation System", The Journal of The Korea Institute of Intelligent Transportation Systems, Vol.19, No.5 pp 162~177.
- 3) A. Krizhevsky, I. Sutskever and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks", Communication of ACM, Vol.60, Issue 6, pp.84-90, 2017.
- 4) K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-scale Image Recognition", International Conference on Learning Representations, 2015.
- 5) K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition", The IEEE Conference on Computer Vision and Pattern Recognition, pp.770-778, 2016.
- 6) J. I. Lee, G. S. Kwak, K. S. Kim, W. Y. Kang, D. Y. Shin, and S. H. Hwang, "Development of Virtual Simulator and Database for Deep Learning-based Object Detection", The Journal of Drive and Control, Vol.18, No.4, pp.9-18, 2021
- 7) C. Yu, C. Gao, J. Wang, G. Yu, C. Shen, and N. Sang, "BiSeNet V2: Bilateral Network with Guided Aggregation for Real-time Semantic Segmentation," arXiv:2004.02147, 2020.
- 8) L. Reiher, B. Lampe, and L. Eckstein, "A Sim2Real Deep Learning Approach for the Transformation of Images from Multiple Vehicle-Mounted Cameras to a Semantically Segmented Image in Bird's Eye View," arXiv:2005.04078, 2020.
- 9) M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Benenson, U. Franke, S. Roth, and B. Schiele, "The Cityscapes Dataset for Semantic Urban Scene Understanding," Proc. Conf. Computer Vision and Pattern Recognition, pp.3213~3223, 2016.
- 10) J. H. Kim, "Excavator Real Time Simulation and Application," The Journal of Drive and Control, Vol.17, No.3, pp.69-75, 2020.