

실주행 영상 자료 기반의 교통안전표지 인식 거리 산출 연구

박재홍^{1*}, 윤덕근²

¹한국건설기술연구원 도로교통연구본부, ²한국건설기술연구원 연구전략기획본부

A Study on Estimation of Perception Distance using the Image Data on the Arterial Road

Jaehong Park^{1*}, Duk Geun Yun²

¹Department of Highway & Transportation Research, Korea Institute of Civil Engineering
and Building Technology

²Research Strategic Planning Department, Korea Institute of Civil Engineering and Building Technology

요약 본 연구에서는 자율주행차의 주행 안전성을 확보하기 위한 방법으로, 도로시설물 중에서 교통안전표지를 대상으로 선정하고, 교통안전표지의 형태 및 내용의 인식 성능을 향상시킬 수 있는 모델 개발 연구를 수행하였다. 카메라가 부착된 차량을 이용하여 국도의 영상 정보를 수집했으며, 영상에 존재하는 교통안전표지를 인식하고 정확도를 분석하였다. 교통안전표지가 존재하는 3,215개의 영상 자료 중에서, 차량의 주행 안전성과 직접적으로 관련된 17개를 분석 대상으로 선정하였다. 모델 개발에 사용된 전체 영상 자료를 학습 데이터(80%), 평가 데이터(20%)로 구분하여 분석했으며, You Only Look Once (YOLO)v5 모델을 교통안전표지의 인식 모델로 사용하였다. 분석 결과, 차량과 교통안전표지와의 거리가 25m 이하에서는 mean Average Precision (mAP)는 89.4로 나타났으며, 차량과 교통안전표지의 거리가 25m 이상이 되면 mAP는 급격히 감소하여 약 33m 부근에서는 약 0.73으로 mAP가 낮아지는 것으로 분석되었다. 본 연구의 결과는 높은 자율주행 성능의 기술 수준을 확보하는 상황에서, 자율주행차의 인식 성능을 검증하는 연구에 활용될 것으로 기대된다.

Abstract Accurate perception of surroundings is a key component of autonomous vehicles to ensure efficient and safe navigation. Traffic safety signs are road facilities that have to be recognized with high precision. In this study, an algorithm was developed to improve the recognition of the shape and content of traffic signs. The accuracy of traffic sign recognition was verified using data collected after conducting a field survey using a camera-equipped vehicle along an arterial road. A total of 3,215 images of traffic safety signs in different locations were analyzed, and the signs were visually identified. To develop a model for road sign recognition, the data were analyzed by dividing the total dataset into 80% training data and 20% validation data. The widely used "You Only Look Once" (YOLO)v5 image recognition technique was employed. As a result of the analysis, the mean Average Precision (mAP) was 89.4 when the distance between the vehicle and the traffic safety sign was 25 m or less. When the distance was more than 25 m, the mAP rapidly decreased at around 33 m. The research was limited to analyzing the accuracy of recognizing the shape and content of traffic signs. The results are expected to be applied in autonomous vehicles in the future when a high level of autonomous driving performance is needed.

Keywords : Traffic Sign, YOLOv5, Image Data, Autonomous Vehicle, Camera

본 연구는 국토교통부/국토교통과학기술진흥원의 연구비 지원(No. 22AMDP-C160881-02, 자율협력주행을 위한 미래도로 설계 및 실증 기술 개발)에 의해 수행되었습니다.

*Corresponding Author : Jaehong Park(Korea Institute of Civil Engineering and Building Technology)
email: jhpark@kict.re.kr

Received October 14, 2022

Revised November 28, 2022

Accepted December 7, 2022

Published December 31, 2022

1. 서론

자율주행차는 운전자 또는 승객의 조작 없이 자동차 스스로 운행이 가능한 자동차로써, 자율주행시스템의 기술 수준을 고려하여 5단계(또는 6단계)로 구분하고 있다. 최근에는 4단계의 기술 수준이 확보된 자율주행차를 개발하는 연구가 수행되고 있으며, 기술 수준이 고도화될수록 자율주행차의 주행에 필요한 기술의 종류와 개수가 다양하게 요구된다. 특히, 도로에 존재하는 도로시설물을 인식하는 기술은 자율주행차의 주행 안전성 확보 측면에서 필수적으로 보유되어야 하는 기술이다. 일반적으로 차량에 부착된 카메라, LiDAR(Light Detection and Ranging), 레이더 등의 센서를 이용하여 도로 시설물 정보를 취득하며, 취득된 정보를 분석하여 도로시설물을 인식하거나, 도로시설물과의 이격 거리 등을 산출한다. 특히, 이격 거리는 차량의 정지에 필요한 거리와 관련성이 높으며, 운전자가 주행하는 경우에는 인지반응시간(운전자가 물체를 인지하여 적절한 행동을 수행하는데 소요되는 시간)과 주행 속도 등을 이용하여 산출한다[1]. 그러나, 자율주행시스템과 운전자의 인지반응시간에는 차이가 존재하며, 자율주행차의 실제 인지반응시간을 정확하게 측정하는데 한계가 존재한다. 따라서, 자율주행차의 센서에서 취득한 정보를 이용한 경우, 도로시설물의 인식에 필요한 거리를 산출하는 연구가 필요하다.

본 연구에서는 자율주행차가 도로시설물을 인식하는데 필요한 거리를 산출하는 방법으로써, 교통안전표지를 대상으로 연구를 수행하였다. 차량 시뮬레이션에 자율주행에 사용되는 영상 센서를 부착하여 자동차의 형태를 구성하여, 카메라 위치에 따른 카메라의 검지 영역을 분석하였다. 또한, 실제 도로를 주행하면서 취득한 영상 자료를 분석하여, 교통안전표지의 인식 정확도를 확보에 필요한 거리를 산출하였다. 특히, 차량의 주행 안전성과 직접적으로 관련된 17개의 교통안전표지를 인식 대상으로 선정하였다. 센서에서 취득한 전체 영상 자료를 학습 데이터(80%)와 평가 데이터(20%)로 구분하였으며, 영상 인식 기술로 많이 활용되는 You Only Look Once (YOLOv5)을 사용하여 분석하였다. 또한, Mean Average Precision(mAP)을 이용하여 인식 성능을 검토하였으며, 교통안전표지의 외부 형태 및 내용을 인식하는 것으로 연구의 범위를 한정하였다.

본 연구의 결과는 자율주행차의 기능 중에서 영상 센서의 인식 성능을 검증하는 기초 연구에 활용될 수 있을 것으로 기대된다.

2. 기존 연구 고찰

영상 자료에서 객체의 위치 및 인식을 동시에 할 수 있는 기법은 One Stage 알고리즘과 Two Stage 알고리즘으로 크게 구분할 수 있다. One Stage 알고리즘에는 YOLO, RetinaNet, Single Shot MultiBox Detector (SSD)가 대표적이며, 상대적으로 속도가 빠른 장점을 가지고 있으나, 객체의 크기가 작을 경우 잘 찾지 못한다는 단점이 존재한다. 특히, 객체를 탐지하는 모델 중에서 YOLOv5는 모델의 레이어 및 레이어 채널 수에 따라 모델 유형이 구분되며, 모델의 크기가 커질수록 Mean Average Precision (mAP)이 증가하지만, 속도는 감소하는 것으로 나타난다. Two Stage 알고리즘에는 Regions with Convolutional Neuron Networks features (R-CNN), Faster R-CNN, Mask R-CNN이 대표적이며, One-Stage에 비해 구조가 복잡하고 속도가 느리다는 단점이 있으나, 객체의 크기가 작을 경우의 인식률도 높은 경향을 나타낸다[2]. 또한, 기존 연구에서는 주성분 분석(Principal Component Analysis, PCA)과 선형판별분석(Linear Discriminant Analysis, LDA)[3], 오류역전판 학습 알고리즘[4], Japanese Puzzle 알고리즘[5], RANSAC 기반의 표지판 추적 알고리즘[6]을 사용하여 교통안전표지를 인식하였다. 또한, 도로 주행 이미지로부터 선형 정보와 색상 정보를 이용하여 표지판 영역을 추출했으며[7], 카메라 렌즈(광각, 망원)를 구분하여 교통안전표지를 인식하였다[8]. 일반적인 주간 상황이 아닌 야간, 눈, 비, 안개 등의 열악한 상황에서의 교통안전표지 인식을 위한 연구와 고속도로 주행 중 촬영한 영상을 이용하여 교통 표지판을 인식한 뒤 추가적으로 표지판에 표시된 문자를 인식하는 연구를 수행하였다[9,10]. Hashemi 등은 이미지 인식을 위한 Convolutional networks의 새로운 정규화 기법을 제안했으며[11], Zohou 등은 무작위 신경망을 기반으로 클러스터링 매핑 기능을 사용함으로써, 교통안전표지 인식을 위한 새로운 학습 프레임워크를 제시하였다[12]. 또한, 교통 표지의 인식에는 Deep Convolutional Neural Network (CNN), Deep Neural Network, 유전 알고리즘을 사용하여 교통 표지의 인식 성능을 분석하여 연구를 수행하였다[13-15].

기존 연구에서는 도로 표지판 자체 또는 표지의 내용을 인식하는데 초점을 맞추어 모델링 하는 연구를 수행하거나, 정확도를 향상시키는데 중점을 두고 연구가 수행되었다. 본 연구에서는 영상 장비를 이용한 표지 인식

방법의 정확도를 확보하는 기존 연구에서 교통안전표지와 영상 센서의 거리에 따른 인식 정확도를 분석하는 연구를 수행하였다. 특히, 거리에 따른 인식 정확도를 분석함으로써, 영상 센서를 이용하여 주변 시설의 정보를 인식하는 차량에게 요구되는 거리를 제시하였다는 점에서 본 연구의 차별성이 존재한다.

3. 분석 개요

3.1 영상 센서의 인식 영역

본 연구에서는 차량에 부착된 카메라의 설치 위치에 따라 도로시설물이 검지되는 영역을 검토하였다. 특히, 도로에 설치된 많은 시설물 중에서 본 연구에서는 교통안전표지를 인식 대상으로 선정하였으므로, 차량이 주행하면서 취득되는 영상 중에서 교통안전표지 데이터가 가장 많이 확보될 수 있는 설치 위치를 검토하였다. 차량 주행 방향을 기준으로 상·하·좌·우를 구분하여 9개의 카메라를 설치하였으며, 설치된 위치에 따라 영상에 존재하는 교통안전표지의 형태를 검토하였다. Fig. 1에는 차량에 부착된 카메라에서 취득된 영상 자료를 사례를 제시하였다.



Fig. 1. Image data of the road facilities

3.2 교통안전표지 인식용 데이터 구축

실제 도로를 주행하면서 취득한 영상 자료를 사용하여 분석에 사용했으며, 본 연구에서는 Manta G-125C 카메라를 사용하였다. 카메라의 해상도(Pixel)는 1,936×1,456, 영상 데이터를 취득하는 간격은 30FPS(Frame Per Second)로 설정하였다. 또한, Charge-Coupled

Device(CCD) Progressive 방식을 사용하고 있으며, IEEE 802.3 1,000 base T의 인터페이스를 사용함으로써 영상 자료의 손실이 없도록 하였다. 시뮬레이션에서 사전 분석된 결과를 이용하여, 수평 방향으로는 차체의 중심, 수직 방향으로는 1,000mm의 높이에 카메라를 설치하였다. 빛의 양에 따라 영상에서 인식되는 정확도 차이가 많이 발생하므로, 오전과 오후 시간대에 데이터를 취득하여 데이터의 다양성을 확보하였다. 또한, 카메라에서 취득된 영상 자료 중에서, 교통안전표지의 형태의 훼손·마모·오염된 표지를 제외하고, 교통안전표지의 상태가 영상 인식에 적합하다고 판단되는 유효 데이터 3,215개를 선정하였다. 본 연구에서 분석 대상으로 선정된 교통안전표지의 영상 정보를 Table 1에 제시하였다.

Table 1. The number of image data for machine learning

Image	Total Data						
	784		213		117		98
	242		188		111		98
	230		183		106		93
	228		173		104		87
	160	-	-	-	-	Total	3,215

3.3 교통안전표지 인식 거리 산출 방안

영상 센서에서 인식되는 교통안전표지의 인식 거리 및 정확도를 분석하기 위하여, 전체 유효 데이터의 80%를 학습 데이터, 20%를 평가 데이터로 구축하였다. 교통안전표지 인식에는 YOLOv5를 사용했으며, YOLOv5에 데이터를 활용하기 위하여 1,936×1,456 해상도의 이미지를 640×640 해상도로 조정하였다. 또한, 영상 데이터에서 교통안전표지를 특정하기 위하여 17개의 교통안전표지 객체에 바운딩 박스를 설정하였다. 각각의 학습 방법은 교통안전표지의 인식을 위해 자동차 분야에서 많이 적용되는 알고리즘을 사용하였다. 영상 센서가 교통안전표지판에서 떨어진 거리를 측정하는 방법으로써 도로의 차선을 이용하였으며, Fig. 2에는 거리에 따른 교통안전표지의 크기 변화 사례를 제시하였다.

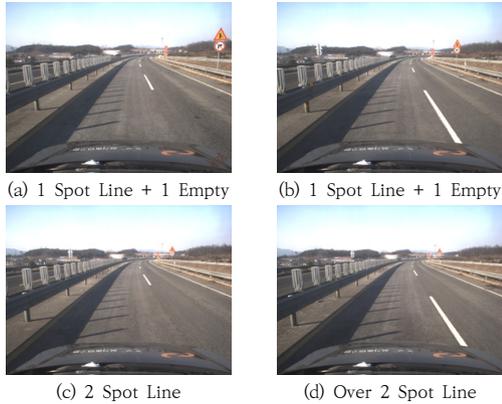


Fig. 2. The example of the road sign size variation by distance

교통안전표지와 차량이 가장 근접한 이미지에서 차량과 표지판의 거리는 약 8 m로 산출되었다. 교통안전표지 판로부터 이미지 프레임이 증가할 때마다 거리를 가산하였다. 차량 평균 주행 속도는 90km/h이며, 초당 15 frame으로 이미지를 촬영하였다. 따라서, 한 프레임당 이동한 차량이 이동한 거리는 1.67m/frame이며, 카메라와 교통안전표지의 최근접거리를 기준으로 프레임 순번에 따라 이동 거리를 산출하는 식을 Eq. (1)에 제시하였다.

$$L_i = (N_{total} - N_{i+1}) \times 1.67m/frame + L_o \quad (1)$$

Where,

- L_i 표지판에 가장 근접한 프레임으로부터 i번째 프레임의 표지판과 촬영 카메라 간 수평거리 (m)
- N_{total} 표지판을 촬영한 전체 프레임의 수
- N_i 표지판을 촬영한 프레임 순번 (0, 1, 2, ... , i)
- L_o 표지판에 가장 근접한 프레임에서 표지판과 촬영 카메라 간 수평거리 ($L_o = 8$ m)

4. 분석 결과

4.1 교통안전표지 인식

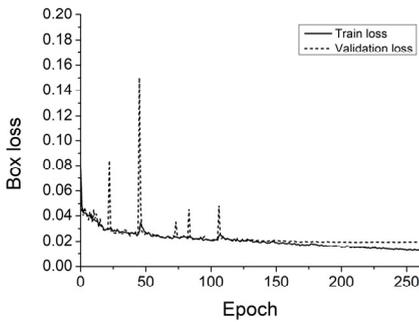
교통안전표지의 이미지를 사용하여 모델을 학습하였으며, epoch 300까지 32의 batch size로 학습하였다. 640×640 해상도로 조정된 영상 데이터에서 색상(Hue, H)은 0.015, 채도(Saturation, S)는 0.7, 명도(Value, V)는 0.4까지 변화시켰다. Translate 0.1, Scale 0.5,

좌우 반전율은 0.5로 변화시켰으며, Mosaic 기법을 적용하여 데이터의 개수를 증강(Data Augmentation)을 수행하였다. 특히, Adaptive Moment Assesment (ADAM)를 사용하여 가중치를 최적화 시켰으며, 초기 학습률은 0.001, 최종 학습률은 0.01로 설정하였다. ADAM의 모멘텀은 0.9, 가중치 감소(Weight decay)는 0.005로 설정하였다. 모델 학습을 위한 손실 함수는 경계 손실(Box loss), 분류 손실(Classification loss), 객체 손실(Objectness loss)을 사용하였다. Intersection over Union(IoU) 점수가 0.5 이상이 경우, 참값으로 판단하였으며, mean average precision(mAP)을 계산하여 가장 높은 mAP를 보이는 epoch에서 최종 모델을 선정하였다. Fig. 3(a), (b), (c), (d)에는 각각 경계 손실, 분류 손실, 객체 손실, 전체 손실을 제시하였다. 경계 손실은 예측된 경계 상자 위치와 크기에서 발생하는 오차를 측정하며, 분류 손실은 검지된 객체에서 발생한 각 셀의 분류 손실에 대한 오차 제곱을 나타낸다. 마지막으로 객체 손실은 상자에서 객체가 탐지되었을 경우 신뢰성에 대한 손실을 측정한다. YOLO에서는 3가지 손실의 합산을 이용하여 모델 학습을 진행한다. 각각의 손실은 125 epochs에서 모두 수렴하며, 큰 폭의 진동(Oscillation)이 발생하지 않는 양상을 나타내었다. 또한, 125 epochs 이후에는 학습 손실(Train loss)과 검증 손실(Validation loss)의 차이가 상당히 줄어들어 과적합이 크게 발생하지 않았다. 전체 손실에 가장 큰 영향을 미친 손실은 분류 손실이며, 경계 손실, 객체 손실 순으로 전체 손실의 변화에 영향을 미치는 것으로 분석되었다. 또한, 손실의 변화가 발생하지 않은 260 epochs에서 학습을 종료하였다.

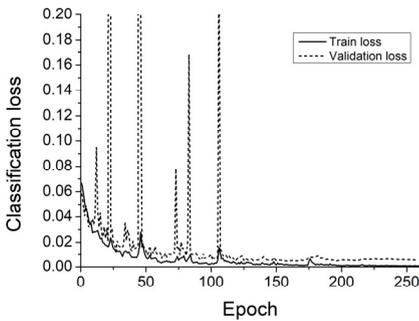
4.2 교통안전표지 인식 모델 예측 결과 및 분석

IoU 점수가 0.5 이상인 경우를 참(True)으로 판정했을 경우, 최대 mAP는 160 epoch에서 0.927로 나타났다. 정밀도와 재현율은 각각 0.944와 0.831로 재현율에 비하여 높은 정밀도를 지닌 델로 확인되었다. 또한, 전체 17종류 중에서 test를 위한 이미지로 총 13종의 도로 표지판이 사용되었으며, 10종이 0.95이상의 높은 mAP를 보이는 것으로 분석되었다. 322, 226, 308로 class name을 표기한 3종을 각각 횡단보도 표지, 서행(천천히) 표지, 직진 및 우회전 표지로서 다른 표지판에 비하여 복잡한 그림으로 구성된 경우였다. 거리가 가까울수록 높은 mAP를 보이며, 거리가 증가할수록 점점 감소하여 약 25m의 거리에서 0.85로 mAP를 나타내었다. 차

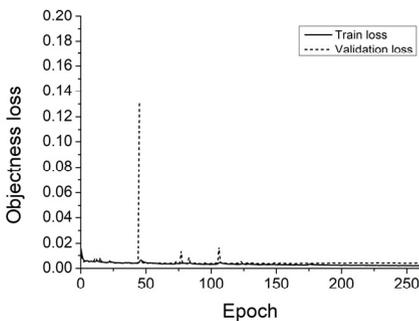
량과 표지판의 거리가 25m 이상이 되면 mAP는 급격히 감소하여 33m 부근에서는 약 0.73으로 mAP가 낮아지는 것으로 분석되었다. 거리가 멀어지게 되면 탐지하는 객체가 차지하는 픽셀 영역이 감소하고, 큰 물체를 감지해내는데 용이한 YOLO 계열의 모델에서 탐지에 한계가 존재하는 것으로 분석되었다. Fig. 4(a)는 모델 학습에 따른 mAP 변화, Fig. 4(b)는 17종으로 분류한 도로 표지판의 종류에 따른 mAP 변화, Fig. 4(c)는 운행 중인 차량과 표지판의 거리에 따른 mAP의 변화를 제시하였다.



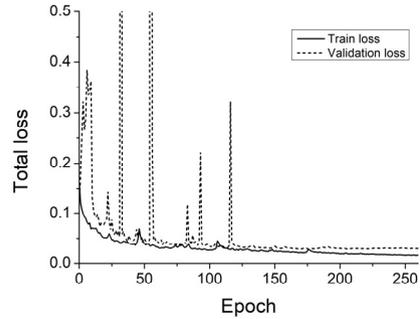
(a) Box loss variation each epoch



(b) Classification loss variation each epoch

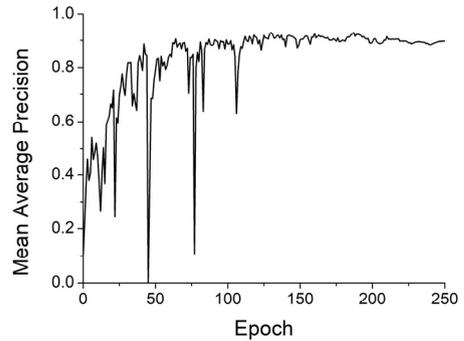


(c) Objectness loss variation each epoch

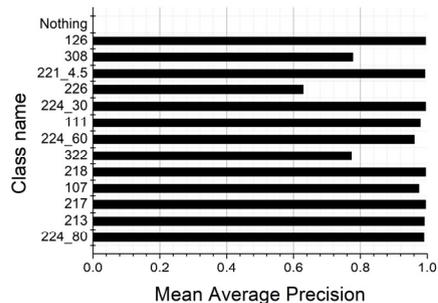


(d) Objectiveness loss variation each epoch

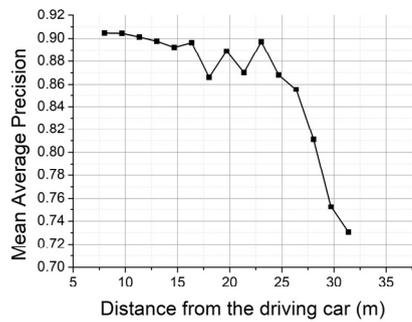
Fig. 3. Model training result



(a) mAP versus epoch



(b) mAP versus class name



(c) mAP versus class name

Fig. 4. Analysis result

5. 결론 및 향후 연구과제

본 연구에서는 교통안전표지의 인식 정확도를 확보할 수 있는 거리를 산출하기 위한 연구를 수행하였다. 분석 결과, 차량과 교통안전표지와의 거리가 25m 이하에서는 mAP의 평균이 89.4로 나타났으며, 25m 이상이 되면 mAP는 급격히 감소하여 약 33 m 부근에서는 약 0.73으로 mAP가 낮아지는 것으로 분석되었다. 이러한 결과는 YOLOv5를 사용한 영상 센서의 물체 인식 최소 임계 거리를 제시하였다는 점에서 연구의 의의가 있으며, 본 연구에서의 연구 결과를 발전시키기 위한 향후 연구 과제는 다음과 같다.

첫째, 영상 센서를 이용하여 교통안전표지를 인식하고, 인식률이 낮아지는 임계 거리를 제시하였다. 그러나, 차량이 주행하면서 취득한 영상을 사용하였고, 주행 차선을 이용하여 거리를 측정함으로써 측정 오차가 존재한다. 향후 연구에는 측량 센서(Global Positioning System, GPS)를 이용하여 교통안전표지와 차량과의 거리를 정밀하게 산출할 필요성이 있다. 둘째, 본 연구에서는 YOLOv5를 사용하여 교통안전표지를 인식하고, 인식 정확도를 산출하였다. 알고리즘에 따라 인식 정확도의 차이가 발생할 수 있으며, 주석 방법 및 학습, 평가 데이터의 비율에 따라 인식 정확도의 차이가 발생할 수 있다. 따라서, 향후 연구에서는 모델별 성능을 비교하여 제시해야 하며, 알고리즘의 속성 변화에 따른 인식 성능 변화도 분석해야 한다. 셋째, 본 연구에서는 교통안전표지판과 카메라의 거리를 고려하여 교통안전표지의 인지 정확도 변화를 분석하고 임계 거리를 도출하였다. 영상 장비의 경우, 도로 환경, 빛 노출 등에 민감하게 변화하며, 영상 장비의 성능에도 많은 영향을 받는다. 따라서, 향후 연구에서는 인식에 사용되는 영상 장비, 도로 환경 등의 조건을 다양화하여 인지 성능을 분석할 수 있어야 한다.

본 연구의 결과는 자율주행차의 기능 중에서 영상 센서의 인식 성능을 검증하는 기초 연구에 활용될 수 있을 것으로 기대된다.

References

- [1] Ministry of Land, Infrastructure and Transport, The rule and guideline for road facilities, 2022.
- [2] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, *You Only Look Once: Unified, Real-Time Object Detection*, IEEE CVPR Las Vegas, NV, pp.779-788, 2016.
- [3] M. J., Kwon, *Study of Traffic Sign Auto-Recognition*, Korea Academia-Industrial cooperation Society, No.09, pp.5,446-5,451, 2014. DOI: <https://doi.org/10.5762/KAIS.2014.15.9.5446>
- [4] G. W. Bang, D. W. Kang, and W. H. Cho, *Traffic Sign Recognition Using Color Information and Error Back Propagation Algorithm*, Korea Information Processing Society, Vol.14, No.7, pp.809-818, 2007. DOI: <https://doi.org/10.3745/KIPSTD.2007.14-D.7.809>
- [5] Y. S. Shon, *A Recognition of Traffic Safety Signs Using Japanese Puzzle*, International Journal of Fuzzy Logic and Intelligent Systems, Vol18., No.3, pp.416-421, 2008. DOI: <https://doi.org/10.5391/JKIS.2008.18.3.416>
- [6] S. U. Kim, and J. W. Lee, *Traffic Sign Recognition, and Tracking Using RANSAC-Based Motion Estimation for Autonomous Vehicles*, Journal of Institute of Control, Robotics and Systems, Vol.22, No.2, pp.110-116, 2006. DOI: <https://doi.org/10.5302/J.ICROS.2016.15.0191>
- [7] G. Kim, H. G. Sohn, S. K. Lee, and Y. S. Song, *Automatic Detection of Road Sign from Color Imagery for GIS Database*, Korea Society of Civil Engineers, Vol.25, No.3D, pp.471-475, 2005.
- [8] K. H. Nam, and C. S. Bae, *An Vision System for Traffic Sign Recognition*, Journal of the Korea Institute Of Information and Communication Engineering, Vol.8, No.2, pp.471-476, 2004.
- [9] Y. B. Jo, W. S. Na, S. J. Eom, and Y. Jeong, *Traffic Sign Recognition using SVM and Decision Tree for Poor Driving Environment*, Institute of Korean Electrical and Electronics Engineers, vol.18, no.4, pp.485-494, 2014. DOI: <https://doi.org/10.7471/ikeee.2014.18.4.485>
- [10] C. Im, and D. Kim, *Real-Time Traffic Information and Road Sign Recognitions of Circumstance on Expressway for Vehicles in C-ITS Environments*, Journal of the Institute of Electronics and Information Engineers, Vol. 54, pp.55-69, 2017. DOI: <https://doi.org/10.5573/iee.2017.54.1.055>
- [11] A. S. Hashemi, S. Mozaffari, and S. Alirezaee, *Improving adversarial robustness of traffic sign image recognition networks*, Displays, Vol.74, pp.1-9, 2022. DOI: <https://doi.org/10.1016/j.displa.2022.102277>
- [12] S. Zohou, C. Deng, Z. Piao, and B. Zhao, *Few-shot traffic sign recognition with clustering inductive bias and random neural network*, Pattern Recognition, Vol.100, pp.1-9, 2020. DOI: <https://doi.org/10.1016/j.patcog.2019.107160>
- [13] D. A. Alghmgham, G. Latif, J. Alghazo, and L. Alzubaidi, *Autonomous Traffic Sign (ATSR) Detection and Recognition using Deep CNN*, Procedia Computer Science, Vol.163, pp.266-274, 2019. DOI: <https://doi.org/10.1016/j.procs.2019.12.108>

- [14] A. Arcos-García, J. A. Álvarez-García, and L. M. Soria-Morillo, *Deep neural network for traffic sign recognition systems: An analysis of spatial transformers and stochastic optimization methods*, Neural Networks, Vol.99, pp.158-165, 2018.
DOI: <https://doi.org/10.1016/j.neunet.2018.01.005>
- [15] A. de la Escalera, J.M. Armingol, and M. Meta, *Traffic sign recognition and analysis for intelligent vehicles*, Image and Vision Computing, Vol 21, No.3, pp.247-258. 2003.
DOI: [https://doi.org/10.1016/S0262-8856\(02\)00156-7](https://doi.org/10.1016/S0262-8856(02)00156-7)
-

박 재 흥(Jaehong Park)

[정회원]



- 2021년 2월 : 한양대학교 교통공학
학과 (교통공학박사)
- 2011년 1월 ~ 현재 : 한국건설기
술연구원 수석연구원

<관심분야>

교통 안전, 도로 설계, 자율 주행

윤 덕 근(Duk Geun Yun)

[정회원]



- 2009년 2월 : 명지대학교 교통공
학과 (교통공학박사)
- 2001년 1월 ~ 현재 : 한국건설기
술연구원 연구위원

<관심분야>

교통 안전, 도로 관리, 도로 설계, 자율 주행