

객체 인식 모델 기반 실시간 교통신호 정보 인식

Real-time traffic light information recognition based on object detection models

주은오* · 김민수**
Joo, eun-oh · Kim, Min-Soo

Abstract

Recently, there have been many studies on object recognition around the vehicle and recognition of traffic signs and traffic lights in autonomous driving. In particular, such the recognition of traffic lights is one of the core technologies in autonomous driving. Therefore, many studies for such the recognition of traffic lights have been performed, the studies based on various deep learning models have increased significantly in recent. In addition, as a high-quality AI training data set for voice, vision, and autonomous driving is released on AIHub, it makes it possible to develop a recognition model for traffic lights suitable for the domestic environment using the data set. In this study, we developed a recognition model for traffic lights that can be used in Korea using the AIHub's training data set. In particular, in order to improve the recognition performance, we used various models of YOLOv4 and YOLOv5, and performed our recognition experiments by defining various classes for the training data. In conclusion, we could see that YOLOv5 shows better performance in the recognition than YOLOv4 and could confirm the reason from the architecture comparison of the two models.

Keywords: Traffic Light Recognition, Autonomous Driving, Deep Learning, YOLO, Object Detection

1. 서론

최근 자율주행 기술이 발전함에 따라 4차산업의 핵심 분야로 자리 잡고 있다. 이러한 자율주행 기술에 있어 차량 주변 객체, 교통신호 인식은 자율주행 기술의 핵심 요소라고 할 수 있다. 이에 오랜 기간 동안 차량 주변 객체 인식과 신호 인식을 위한 연구가 진행됐으

며, 최근에는 인공지능 기술의 발전으로 머신러닝을 접목한 자율주행 연구가 증가하고 있다. 자율주행 차량에 사용되는 센서는 카메라, 레이더, 라이다 등이 있으며 이러한 센서로 수집한 차량 주변 정보와 머신러닝을 사용하여 다양한 연구가 진행되고 있다. 차량 주변의 객체를 인식하는 경우 카메라는 객체를 인식하고 라이다는 객체 인식과 거리 인식에 주로 사용되고

* 대전대학교 컴퓨터공학과 석사과정 Department of Computer Engineering, Daejeon University
(first author: seal59@naver.com)

** 대전대학교 컴퓨터공학과 교수 Department of Computer Engineering, Daejeon University (corresponding author: minsoo@dj.ac.kr)

있다(박상진 외 2021, 서흥덕·김의명 2020). 라이다로 수집한 거리정보와 카메라로 수집한 영상으로 학습데이터를 구축하여 단안 카메라로 객체의 거리를 구할 수도 있다(박상배·김정하 2020, 김현석 외 2018, 이동현·김학일 2020). 또한 라이다는 Point cloud를 통해 3차원 고정밀지도 구축, 측위(Localization) 기법, 주변 객체 인식 등 다양하게 사용할 수 있다(나유승 외 2020, 강준오·이용창 2019). 딥러닝을 사용하지 않은 신호등 인식 알고리즘의 경우 색상을 기반으로 한 알고리즘 또는 신호등의 불빛이 보이는 위치에 따른 알고리즘이 많이 존재한다. 색상기반의 알고리즘은 간단하지만, 날씨나 조도, 역광 등 주변 환경에 따라 카메라로 수집한 영상에서 신호등의 색깔에 변형이 일어나는 경우 오류가 발생하게 된다. 그러나 딥러닝 기반의 신호 인식 모델의 경우 이러한 단점은 다양하고 품질이 좋은 학습데이터가 확보되는 경우 극복 가능하며, 이에 따라 최근 딥러닝 모델 기반 신호등 인식 성능을 높이기 위한 연구가 크게 증가하고 있다.

본 연구에서는 다양한 객체 인식 모델 중에서 YOLOv4와 YOLOv5를 사용하여 차량 교통신호 인식 성능을 비교 및 분석하였다. 또한, 학습데이터 커스터마이징 및 교통신호 인식을 위한 효율적인 분류 클래스 구성을 통하여 교통신호 인식 성능을 향상시키고자 하였다. 구체적으로 학습데이터로는 객체별로 다양한 세부 정보들을 포함하고 있는 AIHub의 “신호등/도로표지판 인지 영상(수도권)”데이터를 사용하였으며, 커스터마이징을 통하여 효율적인 교통신호 인식이 가능한 학습데이터를 구성하였다. 아울러, 학습데이터의 속성 정보를 이용하여 교통신호 인식 모델을 구현하기 위한 클래스 구성을 다양하게 설정하여 인식 성능을 비교하여 보았다. 끝으로 YOLOv4와 YOLOv5의 모델을 이용하여 학습데이터 내에서 대부분 작은 객체로 표시되는 차량 교통신호등에 대한 인식 성능을 비교하였다.

본 논문의 구성은 다음과 같다. 2장에서는 차량 교

통신호를 인식하는 컴퓨터 비전 및 딥러닝 기반의 다양한 연구 동향을 살펴본다. 3장에서는 본 연구에서 사용한 학습데이터의 특징과 클래스 분류에 따른 교통신호 인식 성능 비교를 위한 클래스를 선정한다. 4장에서는 본 연구에서 사용한 YOLOv4와 YOLOv5의 아키텍처를 비교분석한다. 5장에서는 교통신호 인식 모델에 대한 정확도와 속도에 대한 성능을 비교한다. 끝으로 6장에서는 결론 및 향후 연구 방향에 대하여 제시한다.

2. 관련 연구

자율주행을 위한 핵심 연구로 차량 주변의 객체 인식 및 교통신호/표지판 인식 등이 활발히 수행되어 왔다. 초기에는 사람이 시각적 신호를 처리하는 방식을 모델링하여 컴퓨터가 모방하도록 하는 컴퓨터 비전 기반의 연구가 활발히 수행되어왔다. 최근에는 딥러닝 기술이 발전하면서 컴퓨터 비전 분야에 딥러닝을 적용한 연구가 크게 증가하고 있다.

컴퓨터 비전 기반 교통신호 인식과 관련하여 Tai Huu et al.(2016)은 클러스터링과 필터링을 통해 ROI (Region Of Interest)에서 블랍(Blob)을 추출하고 기하학적 조건에 따라 일부 블랍을 제거한 후 분류하여 신호를 인식하였다. 정택훈, 김정하(2017)는 RGB 색상 모델로부터 HSV, YCbCr 색상 모델로 변환하고 신호등 인식 과정에서 오인식이 발생할 수 있는 잡음을 제거하고 신호 점등 부 내부 영역을 보완하기 위해 모폴로지 침식 연산과 블랍 필터를 사용하여 신호등을 검출한 후 신호등의 점등 영역의 위치에 따라 신호를 분류하여 인식하였다. 이태우 외(2015)는 BoW(Bag of visual Words)방법을 개선한 DMCT(Dense MCT) 방법을 이용하여 특징 기술자(Descriptor)를 생성한 후, Fisher-Vector에 의해서 저차원 벡터로 변형하여 조명 변화가 심한 도로주행 영상에서 도로표지판 검출 및 인식 알고리즘을 제안하였다. 이동진 외(2016)



Figure 1. Sample images of training data used in traffic light detection.

는 LISA 데이터셋을 사용한 신호 인식 연구에서 HOG(Histogram of Oriented Gradient) 특징 추출 방법을 사용하는 것이 GoogleNet 보다 성능이 우수함을 제시하였다.

딥러닝 기반 신호 인식 연구와 관련하여 정찬영 외(2018)는 YOLO와 SSD보다 Faster R-CNN이 영상 안의 작은 객체 검출에 더 적합하다는 특징을 이용하여 Faster R-CNN 모델을 사용하여 신호를 분류하였다. Tai Huu et al.(2020)은 우선 YOLOv4 네트워크를 사용하여 신호등을 감지하고 분류하고, 이후 모양과 위치를 기반으로 YOLOv4의 부정확한 제안을 제거한 후 신호등 인식을 위해 네트워크 결과를 조정하여 신호등 정보를 인식하였다. Wang et al.(2022)은 교통신호를 인식하는데 YOLOv4를 사용하였으며 작은 물체에 대한 정밀도가 낮은 YOLOv4의 단점을 보완하기 위하여 얇은 특징 향상 메커니즘과 경계 상자 불확실성 예측 메커니즘을 사용하였다.

기존의 딥러닝을 사용한 교통신호 인식 연구는 기존의 객체 인식 모델을 그대로 적용하거나 모델을 일부 수정하여 성능을 높이는 방안을 제시하였다. 이에 비해, 본 연구는 AIHub 학습데이터를 활용하여 학습데이터를 커스터마이징하고 클래스 유형을 다양하게 구성하여 성능을 향상시켰다. 또한, 학습데이터 내에서 대부분 작은 크기를 차지하는 차량 신호등을 효율적이면서 실시간으로 인식하기 위하여 YOLO 기반의

다양한 모델을 적용하여 가장 좋은 방안을 제시하였다.

3. 학습데이터 및 클래스 구성

본 장에서는 차량 교통신호 인식을 위한 기존 학습데이터와 비교하여 본 연구에서 사용된 AIHub 학습데이터의 커스터마이징 방법과 특징에 대하여 살펴보고자 한다. 또한, 이러한 AIHub 학습데이터의 특징을 고려한 효율적인 신호등 인식 클래스 구성 방안에 대하여 제시하고자 한다.

3.1. 학습데이터 구성

교통신호 정보를 인식하기 위한 학습데이터는 주로 차량 전방에 장착한 카메라로 수집한 영상 이미지를 이용한다. 그러나, 이러한 환경에서 수집된 영상 이미지는 Figure 1과 같이 신호등이 영상 내에서 매우 작게 보이거나 명확히 보이지 않는 경우가 많다. 이에 딥러닝 기반 신호 인식에서는 작은 객체를 효율적으로 인식할 수 있는 모델 선정이 필요하다.

본 연구에서는 이러한 교통신호 인식을 위한 학습데이터로 AIHub에서 공개한 “신호등/도로표지판 인지 영상(수도권) 데이터셋”을 커스터마이징하여 사용하였다. 일반적으로 학습데이터 커스터마이징은 학습데이터 내에 포함된 객체의 속성 정보에 대한 추출, 누

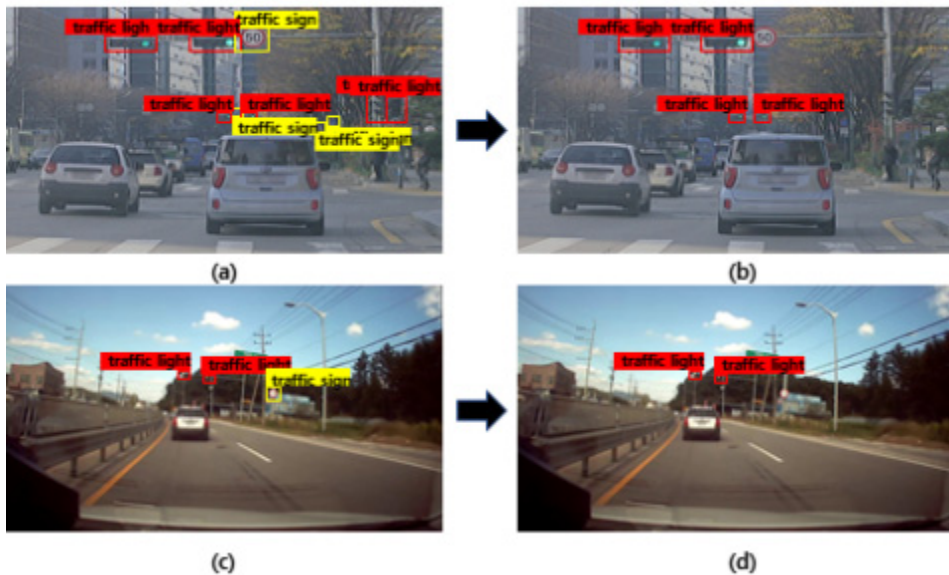


Figure 2. The customizing process of the training data (a), (c) source data (b), (d) customized data

락, 병합 등의 방법을 통해 다양하게 수행되며, 특히 학습을 수행하는데 필요한 객체에 대한 정보가 부족한 경우에는 정보 추가를 위하여 수작업이 요구되기도 한다. 그러나 AIHub “신호등/도로표지판 인지 영상(수도권) 데이터셋”은 신호등, 도로표지판 등의 각 객체에 대하여 다양한 분류 및 속성 관련 레이블 정보를 포함하고 있으므로, 이들 레이블 정보를 분석하여 도로표지판을 제외한 삼색등과 사색등의 신호등 관련 데이터셋만을 추출할 수 있는 모듈을 구현하여 자동화된 방식으로 커스터마이징 데이터를 추출하였다. 구체적으로 본 연구에서는 차량이 마주하는 삼색등 및 사색등의 차량 신호 인식을 목표로 하고 있으므로 AIHub에서 수집한 1,915,672장의 전체 데이터셋에서 일차적으로 차량 신호등 또는 차량 신호등과 도로표지판이 동시에 존재하는 400,592장의 이미지 데이터를 자동화된 방식으로 추출하였다. 이후, 400,592장의 이미지에서 속성 정보를 이용하여 차량 신호등 객체를 포함한 이미지만을 추출하여 커스터마이징된 학습 데이터를 구성하였다. 마지막으로 방대한 데이터로

인해 학습 시간이 크게 요구되는 문제로 인하여 데이터를 무작위로 약 1/10만큼 추출하여 학습데이터 26,862장과 검증데이터 11,057장을 이용하였다. Figure 2는 학습데이터의 커스터마이징 과정을 보여준다. Figure 2에서 보듯이, 본 연구에서는 차량 및 보행자 신호등, 도로 표지판 정보 등을 포함한 이미지 데이터로부터 차량 신호등 정보만 추출하여 학습데이터를 구성하였다. Table 1은 본 연구를 통하여 커스터마이징된 차량 신호 인식을 위한 학습데이터의 세부 구성을 보여준다. 학습데이터는 신호등 객체를 구분하기 위한 bounding box, 신호등 등수를 나타내는 light count, 신호등의 색상 및 방향 정보를 on/off로 나타내는 attribute로 구성되어 있다. 본 연구에서는 이러한 학습데이터 구성의 attribute 세부 정보를 이용하여 교통신호 정보 인식 모델을 구현하기 위한 클래스 구성을 다양하게 설정하였으며, 다음 절에서 이러한 클래스 구성 방안에 대하여 자세히 살펴보려고 한다.




Figure 3. Various kinds of traffic lights information in Korea

3.2. 클래스 구성

국내 차량 신호등 정보는 Figure 3의 정지, 경고, 직진, 직좌, 좌회전, 우회전 등과 같이 매우 다양하다. 신호등의 등수가 1개에서 5개까지 다양하며 같은 등수의 신호등에서도 화살표 종류가 많아 다양한 신호등 정보가 존재한다. 또한 시간이 지남에 따라서 유턴과 같은 신호등 정보도 등장하고 있어 객체인식 모델이 신호등 정보를 효율적으로 인식할 수 있도록 적절한 클래스 구성이 필요하다. 이에 본 연구에서는 차량 신호등에 대한 다양한 정보 유형과 확보된 학습데이터 종류 및 분량을 고려하여 딥러닝 모델의 객체인식 성능을 향상시킬 수 있는 클래스 구성방안을 제시하고자 한다. AIHub로부터 커스터마이징된 전체 학습데이터를 Table 1의 attribute에 따라 분류하였을 때 22종, light count와 attribute에 따라 분류하였을 때 87종의 신호 유형이 존재함을 알 수 있었으며 데이터 오류로 생성된 신호등 종류도 존재함을 알 수 있었다. 따라서 데이터 오류로 생성되지 않은 신호등을 구분하고 데이터 개수가 적은 클래스의 경우 오류에 의해 성능이 크게 변할 수 있어 데이터가 많은 클래스를 선별

Table 1. Configuration of the training data for traffic lights

Category	Value	Feature
Bounding box	minx, miny, maxx, maxy (coordinates)	Minimum bounding rectangle for the object
Light count	light count	Number of lights
Attribute	red (on/off) yellow (on/off) green (on/off) left arrow (on/off) other arrow (on/off)	Signal information

하여 사용하였다. 유형별 데이터 분량에 있어서 정지, 경고, 직진, 직좌, 좌회전의 5가지 유형을 제외하고는 학습을 수행하기에 이미지 영상의 수가 매우 부족함을 알 수 있었다. 이에 본 연구에서는 정확한 차량 신호 인식을 위하여 요구되는 학습데이터의 충분한 확보가 가능한 정지, 경고, 직진, 직좌, 좌회전의 5가지 유형을 신호 인식을 위한 클래스로 구성하였다. 또한, 삼색등과 사색등의 신호등에 대한 인식 성능의 차이를 비교하기 위하여 정지, 경고, 직진, 직좌, 좌회전의 5가지 클래스에 대하여 삼색등과 사색등으로 구분한 클래스를 추가로 구성하여 실험을 수행하였다.

Table 2는 본 연구에서 차량 신호 인식을 위하여 구성한 두 종류의 클래스를 보여준다. Table 2에서 클래스 유형 1은 신호등의 등수를 구분하지 않고 정지, 경고, 직진, 직좌, 좌회전의 5개 인식 클래스를 구성하고 있으며, 클래스 유형 2는 신호등의 등수를 삼색등과 사색등으로 구분하여 전체 8개 인식 클래스를 구성하고 있다. 전체 데이터 대비 정지, 직진 신호 레이블은 22,223개, 22,790개에 비하여 경고, 직좌, 좌회전 신호 레이블 수는 각각 1,975개, 3,711개, 2,292개로 크게 차이가 남을 확인할 수 있었다. 이에 본 연구에서는 기본적인 신호 인식 뿐만 아니라, 정지, 직진, 직좌, 경

Table 2. Class configuration methods for traffic light detection

Class type 1			Class type 2		
Light count	Class	count	Light count	Class	count
3 or 4	stop	22223	3	3_stop	9050
	warning	1975		3_warning	1093
	go	22790		3_go	16879
	go & left	3711	4	4_stop	13173
	left	2292		4_warning	882
		4_go		12911	
			4_go & left	3599	
			4_left	1956	

고 좌회전의 각 클래스별 학습데이터 개수 차이에 따른 인식률도 비교 분석하였다.

4. 객체 인식 모델 비교

본 장에서는 자율주행 차량에 탑재하여 교통신호 인식에 적합한 모델을 선정하고 모델의 아키텍처를 비교 분석한다.

4.1. 객체 인식 모델 선정

본 연구에서는 자율주행 차량에 탑재할 수 있으며, 국내외에서 활용 가능한 차량 신호 정보 인식 모델을 구현하였다. 이에 실시간 객체 인식 속도가 빠르며, 영상 내에서 신호등과 같은 작은 객체도 우수하게 인식할 수 있는 YOLO 모델을 이용하였다. 특히 빠른 객체 인식을 위하여 one-stage detector 모델 중에서 PANet(Path Aggregation Network)이 적용된 YOLOv4와 YOLOv5를 이용하여 차량 신호를 인식하였다. 또한 다양한 모델 크기에 따른 mAP와 FPS의 성능을 확인하기 위하여 YOLOv4, YOLOv4-tiny, YOLOv5-1, YOLOv5-n 모델을 사용하였다.

4.2. 객체 인식 모델 아키텍처

YOLOv4와 YOLOv5의 차량 신호 인식을 비교 분석하기 위하여 두 모델의 아키텍처를 비교 분석하였다. Figure 4와 Figure 5는 각각 YOLOv4와 YOLOv5의 아키텍처를 보여준다. Figure 4에서 YOLOv4는 backbone으로 CSPDarknet53을 사용하며 CSP(Cross Stage Partial)를 사용하는 것이 특징이다. 아울러 작은 객체와 큰 객체를 모두 잘 탐지하기 위해 PANet을 사용하며 Head는 YOLOv3의 Head를 사용하고 있다. Figure 5의 YOLOv5는 backbone으로 Modified CSP v5를 사용하며 C3를 사용하는 것이 특징이다. SPP(Spatial Pyramid Pooling)를 간략화한 SPPF(SPP-Fast)와 PANet을 사용하고 Head는 YOLOv3의 Head를 사용한다. Figure 6는 YOLOv4와 YOLOv5에 자주 사용되었던 CSP와 C3의 아키텍처를 보여준다. CSP는 내부에서 Channel 개수를 늘려서 사용하였으나 C3는 내부에서 Channel 개수를 줄여서 사용하여 계산속도를 증가시켰으며 Concat 이전의 Conv도 하나 제거하였다. Figure 4와 Figure 5를 보면 YOLOv4의 backbone에서 CSP만 사용한 것과는 다르게 YOLOv5 backbone에서는 Conv와 C3를 반복하여 사용하는 특징을 가지고 있다. SPPF는 커널 크

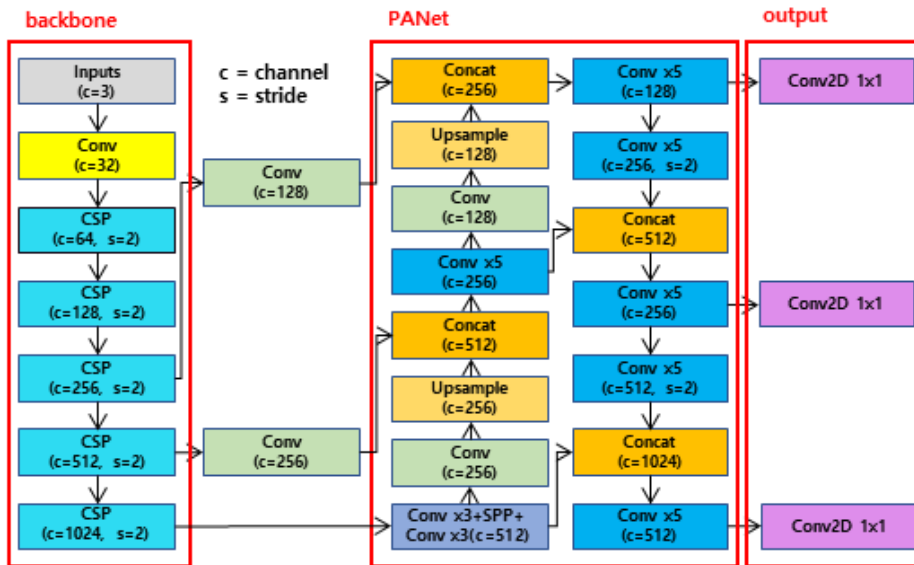


Figure 4. YOLOv4 architecture

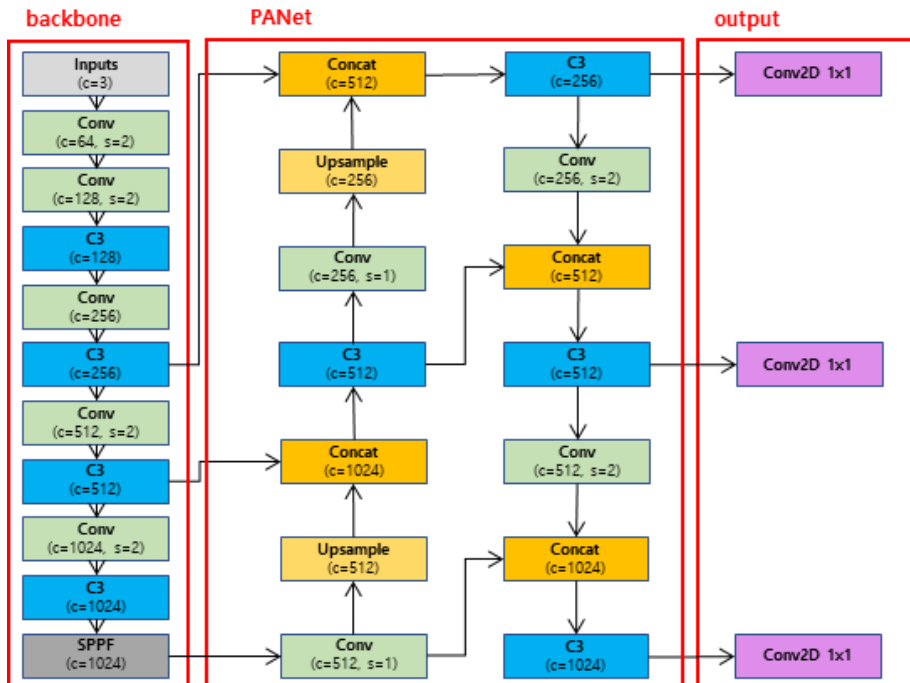


Figure 5. YOLOv5 architecture

기틀 5, 9, 13을 사용하는 SPP를 간략화하여 SPPF는 커널 크기를 5만 사용하여 속도를 높였다.

YOLOv4-tiny는 YOLOv4의 작은 모델이며 모델의 깊이와 넓이가 작다. 또한 YOLOv4에서 사용하는

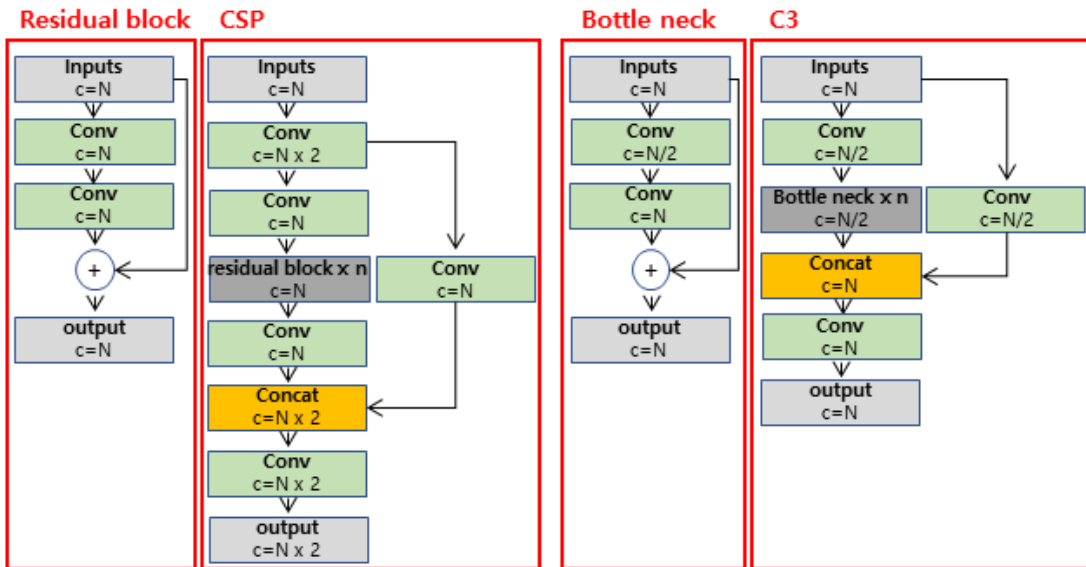


Figure 6. Architecture of bottle neck, CSP, C3

SPP, Residual block, PANet을 사용하지 않는다.

YOLOv5-n은 YOLOv5의 표준 모델인 YOLOv5-l을 기준으로 channel의 개수를 1/4로 줄이고 C3에서 반복하는 Bottle neck의 횟수를 1/3로 줄인 모델이다.

5. 실험결과 및 분석

본 차량 신호 인식 실험은 PyTorch YOLOv5 모델과 Darknet YOLOv4의 PyTorch 커스터마이징 모델을 이용하여 수행하였다. 학습데이터의 영상 크기는 640 x 640을 이용하였으며, batch size는 8GB의 GPU 메모리를 고려하여 모델 크기가 작은 YOLOv4-tiny와 YOLOv5-n은 16을, 모델 크기가 다소 큰 YOLOv4와 YOLOv5-l은 4와 8을 각각 적용하였다. 학습은 300 epoch 만큼 충분히 수행하였으며, 각 모델의 평가데이터에서 mAP가 가장 높은 결과를 상호 비교하였다. 첫째, Figure 7과 8은 3.2절에서 정의된 클래스 유형1과 2에서 제시된 직진 신호에 대한 YOLOv4와 YOLOv5의 차량 신호 인식 결과를 보여준




Figure 7. Detection examples of traffic light information of each model when class type 1 is applied (a) YOLOv4-tiny (b) YOLOv4 (c) YOLOv5-n (d) YOLOv5-l

다. Figure 7과 8을 보면, 직진 신호에 대한 YOLOv4-tiny, YOLOv4, YOLOv5-n, YOLOv5-l 모델의 mAP

Table 3. Performance(mAP) comparison of each model by class type

Class Type 1		Class Type 2	
model	mAP%	model	mAP%
YOLOv4-tiny	37.3	YOLOv4-tiny	35.7
YOLOv4	65.4	YOLOv4	63.5
YOLOv5-n	77.1	YOLOv5-n	74.6
YOLOv5-l	80.5	YOLOv5-l	78.0

가 각각 0.42, 0.77, 0.80, 0.81 수준과 0.5, 0.82, 0.8, 0.8 수준으로 YOLOv4-tiny를 제외한 모든 모델이 0.8 수준으로 비교적 우수한 인식률을 보여주고 있음을 알 수 있다. 또한, 직진 신호 인식 결과는 클래스 유형 1과 2가 인식률에서 큰 차이가 없음을 알 수 있다.

둘째, Table 3는 클래스 유형과 1과 2에 대한 YOLOv4와 YOLOv5 각 모델들의 차량 신호 인식 성능을 평균한 mAP 결과를 요약하여 보여주고 있다. Table 3에서 특히 YOLO-tiny 모델은 클래스 유형에 관계없이 37.3%와 35.7%로 상당히 좋지 않은 성능을 보여주고 있으며, 이외의 경우는 전반적으로 YOLOv5 모델의 mAP가 YOLOv4 보다 11~15% 정도의 우수함을 볼 수 있다. 클래스 유형별 mAP 비교에서는 모든 모델에서 클래스 유형 1이 유형 2에 비하여 2~3% 정도 우수함을 볼 수 있다. 이에 국내 환경에서 작은 크기를 차지하는 차량 신호를 효율적으로 인식하기 위해서는 YOLOv4 보다는 YOLOv5 모델이 적합하며, 신호등의 등수를 구분하지 않는 클래스 유형 1이 더욱 적합하다고 할 수 있다.

셋째, Figure 9는 본 연구에서 사용한 4가지 모델이 유형1을 학습한 모델의 학습과정을 보여준다. 세로축은 mAP, 가로축은 epoch를 의미한다. epoch를 기준으로 비교하였을 때 YOLOv5가 YOLOv4보다 학습 속도가 더 빨랐으며 YOLOv4와 YOLOv5 모두 큰 모델이 작은 모델보다 학습이 더 빨리 진행됨을 알 수 있었다.




Figure 8. Detection examples of traffic light information of each model when class type 2 is applied (a) YOLOv4-tiny (b) YOLOv4 (c) YOLOv5-n (d) YOLOv5-l

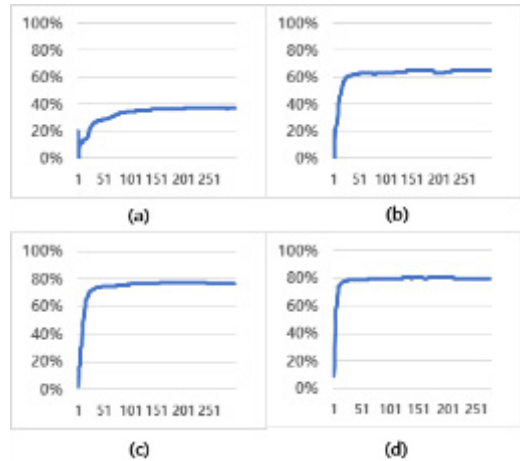


Figure 9. mAP of traffic light information of each model when class type 1 is applied (a) YOLOv4-tiny (b) YOLOv4 (c) YOLOv5-n (d) YOLOv5-l

셋째, 본 연구에서는 Table 2의 각 클래스별 학습데이터 개수의 차이에 따른 인식률 차이를 분석하기 위하여 YOLOv5-n 모델에 대하여 Figure 10과 같이 클

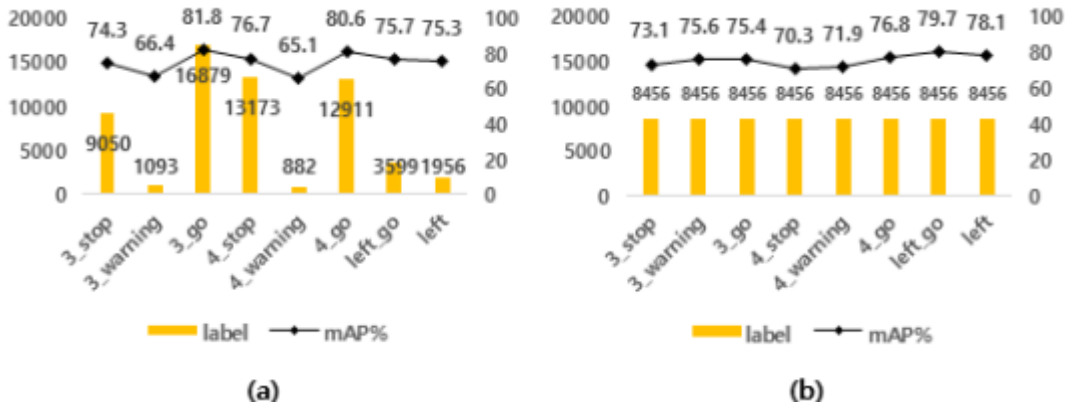


Figure 10. Performance (mAP) comparison by the number of training data for each class based on YOLOv5-n (a) Datasets with different numbers of data (b) Dataset with the same number of data

래스별 학습데이터 개수에 따른 mAP 성능을 조사하였다. Figure 10 (a)에서 삼색등과 사색등의 경고 신호의 경우, mAP가 각각 66.4%와 65.1%로 평균 mAP 74.6%에 비하여 다소 낮았으며 이러한 원인으로 데이터 개수가 부족하여 발생하는 문제로 예상하였다. 이에 Figure 10 (b)에서는 학습데이터 개수를 동일하게 맞추어 비교하였다. 3.1절에서 학습데이터 구축 과정에서 다른 400,592장의 이미지에서 학습데이터와 검증데이터로 나눈 후 데이터 개수가 가장 적은 4_warning의 개수만큼 다른 데이터들을 무작위로 선정하여 데이터셋을 구성하여 YOLOv5-n을 학습하였다. Figure 10 (a)와 비교하여 Figure 10 (b)에서 데이터 개수가 증가한 클래스는 성능이 증가하고 데이터 개수가 감소한 클래스는 성능이 감소한 것을 확인할 수 있었다. 이에 클래스별 학습데이터 개수에 따라 인식률이 비례함을 확인할 수 있었으며, 차량 신호등 인식에서 학습데이터가 일정 수준만 확보되는 경우, 각 클래스별 학습데이터 수의 차이는 전체적인 신호등 정보 인식 성능에 크게 영향을 미치지 않을 것으로 예측된다.

다섯째, 자율주행 차량에 대한 실시간 신호 정보 인식 모델 적용이 가능한지 파악하기 위하여 모델별 객

체 인식 속도를 비교하였다. Figure 11은 본 연구에서 사용된 GeForce RTX 3060Ti의 GPU 기준 각 모델의 객체 인식 FPS(Frames Per Second)결과를 보여준다. Figure 11에서 YOLOv4는 58.8fps, YOLOv4-tiny는 166.7fps, YOLOv5-l는 71.4fps, YOLOv5-n는 111.1fps로 모든 모델의 FPS가 30 이상으로 이들 모델을 실시간 차량에서 활용하는데 큰 문제가 없음을 볼 수 있다. 특히 모델 크기가 작은 YOLOv4-tiny와 YOLOv5-n 모델은 예상대로 성능이 더욱 우수함을 볼 수 있다. 이에 YOLOv4와 YOLOv5 모델에서 차량 신호 정보 인식률은 YOLOv5가 우수하며, 인식 속도는 두 모델 모두 실시간 적용이 가능함을 알 수 있다.

끝으로 두 모델을 비교하였을 때 YOLOv4보다 YOLOv5가 신호 정보 인식에 정확도와 속도면에서 우수한 성능을 보여 YOLOv4 보다 YOLOv5가 더 적합함을 알 수 있었다. 아키텍처를 비교하였을 때 YOLOv4의 backbone에서 사용된 CSP를 사용하기 보단 YOLOv5의 backbone에서 사용된 Conv와 C3를 사용하는 것이 더 최적화된 것으로 보이며 PANet에서도 YOLOv4처럼 Conv를 반복하여 사용하는 것 보단 YOLOv5와 같이 C3를 사용하는 것이 더 최적화된 것으로 보인다. 또한 SPP 대신에 SPPF를 사용해도 총

분히 좋은 성능을 낼 수 있음을 알 수 있었다.

6. 결론

본 연구에서는 AIHub에서 제공한 “신호등/도로표지판 인지 영상(수도권) 데이터셋”을 이용하여 차량 신호등 인식을 위한 학습데이터를 구축하고, 학습데이터의 특성을 이용하여 정지, 경고, 직진, 직좌, 좌회전의 5가지 경우에 대하여 삼색등과 사색등을 구분한 2가지의 클래스 유형도 구성하였다. 이후, 본 연구에서 사용한 YOLOv4와 YOLOv5모델의 아키텍처를 비교 분석하였다. 끝으로, 2가지 클래스 유형에 대하여 실시간 신호등 인식을 위하여 YOLOv4와 YOLOv5 모델을 적용하여 mAP와 FPS의 성능을 비교분석 하였다. 성능분석 결과, YOLOv5 모델의 mAP가 YOLOv4에 비하여 11~15% 정도 우수하였으며, 삼색등과 사색등을 구분하지 않는 클래스 유형 1이 유형 2에 비하여 2~3% 정도 우수한 성능을 보임을 알 수 있었다. 신호등 객체 인식 속도에서는 모든 모델이 30fps 이상으로 실시간 활용이 가능함을 알 수 있었으며 YOLOv5-n 모델을 사용하면 3060ti의 연산속도가 16.2TFLOPs인 것을 고려하여 약 4.3TFLOPs이상의 연산속도를 가진 장비를 사용하면 실시간 교통신호 인식이 가능할 것으로 보인다.

향후 연구로는 YOLOR과 DETR 계열의 모델을 추가로 분석하여 우수한 모델을 커스터마이징하며 차량 신호 정보 인식률을 개선하기 위한 방안을 찾고자 한다. 이외에도 차량 신호 인식과 관련하여 AIHub 데이터가 아니라 국내 데이터를 활용하여 실세계를 모사한 가상환경을 자율주행 시뮬레이터 CARLA에 구현하여 확보 가능한 학습데이터를 대상으로 인식률 및 인식 속도 성능을 분석하고 AIHub 데이터에서 발생했던 데이터 불균형 문제를 해결하여 더 많은 종류의 교통신호를 인식하고자 한다.




Figure 11. FPS for traffic light detection of each model

감사의 글

This research was supported by the Daejeon University Research Grants (2021)

참고문헌

References

- 강준오, 이용창. 2019. UAS와 지상 LiDAR 조합에 의한 수직 구조물의 3차원 공간정보 구축. *지적과 국토정보*. 49(2):57-66.
- Kang JO, Lee YC. 2019. Construction of 3D Spatial Information of Vertical Structure by Combining UAS and Terrestrial LiDAR. *Journal of Cadastre & Land InformatiX*. 49(2):57-66
- 김현석, 박민규, 손원일, 최혁두, 박성근. 2018. 단안카메라를 딥 러닝 네트워크 기반의 객체 검출 및 거리 추정. *한국지능시스템학회 논문지*. 28(3): 201-209.
- Kim HS, Park MG, Son WI, Choi HD, Park SK. 2018. Deep Learning based Object Detection and Distance Estimation using Mono Camera. *Journal of Korean Institute of Intelligent Systems*. 28(4):201-209
- 나유승, 김상권, 김영수, 박준용, 정지민, 조기춘, 이성진, 조성진, 선우명호, 오종민. 2020. 자율주행 자

- 동차를 위한 정밀도로지도 활용성 검증. 한국자동차공학회논문집 28(11):797-808
- Na YS, Kim SK, Kim YS, Park JY, Jeong JM, Jo KC, Lee SJ, Cho SJ, Sunwoo MH, Oh JM. 2020. HD Map Usability Verification for Autonomous Car. *Transaction of the Korean Society of Automotive Engineers*. 28(11):797-808
- 박상배, 김정하. 2020. 도심지 자율주행을 위한 머신러닝 기반의 실시간 다 객체 인식 방법. 제어로봇시스템학회 논문지. 26(6):199-505.
- Park SB, Kim JH. 2020. Machine-learning-based Real-Time Multi-object Recognition Method for Urban Autonomous Driving. *Journal of Institute of Control Robotics and Systems*. 26(6):499-505.
- 박상진, 조국, 임준혁, 김민찬. 2021. CCTV 영상을 활용한 동적 객체의 위치 추적 및 시각화 방안. 지적과 국토정보 51(1):53-63.
- Park SJ, Cho K, Im JH, Kim MC. 2021. Location Tracking and Visualization of Dynamic Objects using CCTV Images. *Journal of Cadastre & Land InformatiX*. 51(1):53-65.
- 서흥덕, 김의명. 2020. 포인트 클라우드에서 딥러닝을 이용한 객체 분류 및 변화 탐지. 지적과 국토정보 50(2):37-51.
- Seo HD, Kim EM. 2020. Object Classification and Change Detection in Point Clouds Using Deep Learning. *Journal of Cadastre & Land InformatiX*. 50(2):37-51.
- 이동진, 김재홍, 한승준, 최정단, 박정희. 2016. LISA 신호등 데이터 집합을 이용한 신호등 인식. 대한전자공학회 학술대회. 775-778.
- Lee DJ, Kim JH, Han SJ, Choi JD, Park CH. 2016. Traffic light recognition using the LISA traffic light dataset. Conference of The Institute of Electronics and Information Engineers. 775-778.
- 이동현, 김학일. 2020. 자율주행에서 카메라를 통한 객체 검출 및 추적과 라이다 융합. 한국자동차공학회 학술대회. 690-693.
- Lee DH, Kim HI. 2020. Object detection and tracking through cameras and LiDAR fusion in autonomous vehicle. Conference of The Korean Society Of Automotive Engineers. 690-693.
- 이태우, 임광용, 배건태, 변혜란, 최영우. 2015. 지능형 자동차를 위한 조명 변화에 강인한 도로표지판 검출 및 인식. 한국정보과학회논문지. 42(2):203-212
- Lee TW, Lim KY, Bae GT, Byun HR, Choi YW. 2015. An Illumination Invariant Traffic Sign Recognition in the Driving Environment for Intelligence Vehicles. *Korean Institute of Information Scientists and Engineers*. 42(2) 203-212.
- 정찬영, 이대규, 심현철. 2018. Faster R-CNN을 이용한 영상 기반 신호등 인식 시스템 연구. 한국자동차공학회 학술대회. 868-871.
- Jung CY, Lee DG, Shim HC. 2018. Vision-based Traffic Light Recognition System using Faster RCNN. Conference of The Korean Society Of Automotive Engineers. 868-871.
- 정택훈, 김정하. 2017. HSV/YCbCr 색상 모델과 형태적 특징 기반 교통신호등 인식. 한국자동차공학회 춘계학술대회. 547-551.
- Jung TH, Kim JH. 2017. Traffic Light Recognition based on HSV/YCbCr Color Model and Morphological Feature. Conference of The Korean Society Of Automotive Engineers. 547-551.

- 한국지능정보사회진흥원. 2022. AIHub[인터넷]. [https://aihub.or.kr/]. 2022년 4월19일 검색.
- Korea Intelligent Information Society Promotion Agency. 2022. AIHub[Internet]. [https://aihub.or.kr/]. Last accessed 19 April 2022.
- Evert Bos. 2019. Including traffic light recognition in general object detection with YOLOv2 [theses]. Delft University of Technology.
- Glenn Jocher 2020. YOLOv5[Internet]. [https://github.com/Tianxiaomo/pytorch-YOLOv4.git]. Last accessed 27 March 2022.
- Tianxiaomo. 2020. pytorch-YOLOv4[Internet]. [https://github.com/Tianxiaomo/pytorch-YOLOv4.git]. Last accessed 27 March 2022.
- Tai Huu - Phuong Tran, Cuong CP, Tien PN, Tin TD, Jeon JW. 2016. Real-Time Traffic Light Detection Using Color Density. IEEE International Conference on Consumer Electronics-Asia (ICCE-Asia). 26-28
- Tai Huu - Phuong Tran, Jeon JW. 2020, Accurate Real-Time Traffic Light Detection Using YOLOv4. IEEE International Conference on Consumer Electronics - Asia (ICCE-Asia). 1-3
- Wang Q, Zhang Qi, Liang X, Wang Y, Zhou C, Vladimir IM. 2022. Traffic Lights Detection and Recognition Method Based on the Improved YOLOv4 Algorithm. *sensors*. 22(1):200-219.

2022년 05월 04일 원고접수(Received)

2022년 05월 17일 1차심사(1st Reviewed)

2022년 06월 03일 2차심사(2nd Reviewed)

2022년 06월 22일 게재확정(Accepted)

초 록

최근 자율주행 기술에서 차량 주변 객체 인식과 교통표지판 및 차량 신호 인식을 위한 연구가 활발히 수행되고 있으며, 특히 차량 신호 인식은 자율주행 기술에 있어서 핵심 요소로 평가되고 있다. 이에 차량 신호 인식을 위한 다양한 연구가 진행되어 왔으며, 최근에는 딥러닝 기반 객체 인식 모델을 활용한 차량 신호 인식 연구가 크게 증가하고 있다. 또한 AIHub에서 음성, 비전, 자율주행 등을 위한 양질의 국내 인공지능 학습데이터 셋이 공개됨에 따라 이들 데이터를 활용한 국내 환경에 적합한 차량 신호 인식 모델의 개발도 가능하게 되었다. 이에 본 연구에서는 AIHub의 학습데이터와 객체 인식 모델 YOLO를 적용한 국내 차량 신호 인식 모델을 개발하였다. 특히 차량 신호의 인식 성능을 개선하기 위하여 YOLOv4와 YOLOv5의 다양한 모델을 적용하였으며 학습데이터의 클래스도 다양하게 분류하여 실험을 수행하였다. 결론적으로 YOLOv5가 YOLOv4보다 차량 신호 인식에 조금 더 적합함을 확인할 수 있었으며, 두 모델의 아키텍처 비교를 통하여 YOLOv5 성능이 우수한 이유를 확인할 수 있었다.

주요어 : 차량 신호 인식, 자율주행, 딥러닝, YOLO, 객체탐지