

# 도로 교통량 조사를 위한 차종 분류 모델의 성능 향상 연구

박재화, 김병근\*, 강미선\*  
경북대학교, \*한국전자통신연구원

pjh31833@etri.re.kr, \*{iros, tams37}@etri.re.kr

## A Study on the Performance Improvement of Vehicle Types Classification

Jae Hwa Park, Pyong-Kun Kim\*, Mi-Seon Kang\*  
Kyungpook National Univ., \*ETRI

### 요 약

본 논문은 도로 교통량 자동화 조사에 사용되는 차종 분류 모델의 신뢰도 향상을 위해 기존의 데이터를 분석, 가공하여 차종 분류 모델의 성능에 영향을 미치는 요소를 분석하고 성능을 향상시킬 방안을 제안하였다. 제안한 방법은 추가적인 검증이나 수집에 비용을 들이지 않고 최소한의 비용으로 모델의 성능을 높일 수 있을 것으로 기대된다.

### I. 서 론

도로 교통량 조사는 도로의 특정 조사 구간에 미치는 교통량의 특성을 파악하여 도로·포장의 설계 등 도로·교통 관련 정책 및 연구 등에 활용될 수 있도록 교통량을 차종별, 방향별, 시간대별로 집계하여 기록하는 것을 의미한다. 현재 도로 교통량 자료는 도로의 계획 및 설계, 도로 운영 등에 폭넓게 이용되고 있다[1]. 기존에는 CCTV 영상을 사람이 육안으로 관찰하면서 차량의 대수와 종류를 헤아렸으나 최근 딥러닝 분야의 검출, 추적 기술의 발전과 더불어 이동 객체를 자동으로 추적하는 기술에 대한 연구가 활발히 진행 중이다. 이를 바탕으로 딥러닝 기술을 사용하여 도로 교통량 조사를 자동화하려는 연구가 진행되었으며, 본 문서는 이 중에서 차량 종류를 판별하는 모델의 성능 향상에 대한 연구 결과를 기술한다.

국내 도로 교통량 정보는 도로를 이용하는 차량의 통과 대수를 차종별, 방향별 및 시간대별로 관측하여 수집한다. 특히 차종별 교통량 자료는 교량 설계 시 설계하중을 산출하거나 화물운송에 관한 정책방향 제시와 전략 수립에 활용할 화물통행수요를 분석함에 반드시 필요한 정보이다. 그런데 현재 우리나라의 차종별 교통량 자료 수집에는 두 가지 문제점이 있다. 첫째는 자료의 정확성이 보장되지 않는다는 점이다. 차량의 진행 방향과 대수는 일반인도 용이하게 구분할 수 있어, 기존 육안 관측 방법에서 정확하게 측정된 것이 비해, 빠르게 이동 중인 차량의 차종 구분은 매우 어려운 작업이라고 할 수 있다. 특히 트럭은 차축 배열뿐만 아니라 적재함의 길이, 너비에 따라 그 종류가 구분되어 전문가가 아니면 구분이 힘들다. 또한 교통량 자료는 실제 주행 차량을 촬영한 동영상으로부터 수집하게 되는데 영상에서의 기하학적 변환, 광도 변환으로 인한 정보 손실 때문에 그림 1 과 같이 전문가라 할지라도 구분이 어려운 경우가

많다. 두 번째 문제점은 휴먼에러를 최소화하기 위해 검증 과정에서 소요되는 막대한 비용이다. 정확한 차종 구분을 위해 다량의 데이터를 해석하고 검증에는 많은 시간과 비용을 필요로 한다.



(a) 2.5 톤(4 종)



(b) 18 톤(6 종)

그림 1 유사한 외양의 화물 차량

본 논문에서는 도로 교통량 조사의 자동화에 수반되는 차종 구분의 성능을 향상시키기 위해 딥러닝 기반의 차종 분류 모델의 성능을 향상시킬 방안을 제시한다. 이는 도로 교통량 조사 자동화의 정확도에 크게 기여할 뿐만 아니라 검증 과정에 수반되는 시간적, 자원적인 비용을 크게 줄여줄 수 있을 것이다.

### II. 본론

차종은 도로 교통량 조사에서 기본적으로 사용되는 6 종 분류표에 따라 분류한다. 승용차, 택시, 승합차는 1 종, 소형버스는 2 종, 대형, 관광버스는 3 종, 소형 화물차량(2.5 톤 미만)은 4 종, 중형 화물차량(8.5 톤 이하)은 5 종, 대형 화물차량(8.5 톤 초과)은 6 종으로 분류된다. 데이터셋은 1 종부터 6 종까지 각각 t1 부터 t6 으로 정의하였고, 실행 시간을 고려하여 pytorch[2]에서 제공하는 사전학습된 ResNet18[3] 모델을 사용한다.

현 데이터는 표 1 과 같이 클래스별로 성능이 균일하지 않으며 t5 클래스에서 가장 낮기 때문에 t5 데이터를 추가적으로 확보해야 할 필요가 있다. 그러나 실제 주행 차량의 데이터를 확보하는 것은 어려움이 많을 뿐만 아니라 교통 CCTV 영상은 보안 때문에 좋은 화질이나 충분한 양의 데이터를 구하기 어렵다. 게다가 도로의 특성에 따라 수집하고자 하는 5, 6 중 차량의 교통량이 희소할 수 있다. 일례로 실험을 위해 확보한 2 시간 30 분짜리 일반 시내도로로 교통 CCTV 영상에서 5 중 차량은 단 5 대만을 확보할 수 있었다. 그리고 차종분류는 전문지식을 필요로 하기 때문에 전문가가 아닌 경우 어렵게 확보한 데이터임에도 그 신뢰성이 떨어진다. 또한 하나의 도로에 대한 하나의 CCTV 영상 데이터는 차량을 다양한 각도에서 바라볼 수 없어 차량 형태의 기하학적 다양성을 잃어버린다.

이러한 문제점을 해결하기 위해 본문에서는 현 데이터를 가공하여 클래스별 분류 불균형 해소 및 성능 향상을 목적으로 t5, t6 클래스에 대해 데이터를 수집하였다. 이 과정에서 다른 클래스의 데이터가 추가되는 경우 과적합으로 인해 성능이 하락할 수 있으므로, 이를 방지하기 위해 데이터를 불러오는 함수를 직접 작성하여 원하는 클래스의 이미지만 추가할 수 있도록 하였다. 문제가 되는 클래스의 차량은 중, 대형 차량이기 때문에 실제 영상에서는 소형 차량이나 다른 객체가 같이 겹쳐서 나타나는 경우가 많다. 이를 제거하기 위해 Darknet YOLO 모듈[4]을 사용하여 개별 객체를 검출한 후에, 가장 큰 객체를 학습하고자 하는 객체라 가정하여 sharpening 처리하고 이외에 탐지되는 객체는 blur 처리하여 이미지의 outlier 를 제거하였다. 이 이미지를 detection dataset 이라 정의하고, 추가적으로 생성모델인 DCGAN[5]으로 생성한 가짜데이터를 학습데이터에 추가하는 실험을 진행했다. 그림 2 는 추가한 데이터의 예시이다.

표 1 기존 클래스별 데이터 분포와 검증 정확도

	train	test	accuracy(%)
t1	31312	17165	99
t2	820	119	92
t3	7794	393	95
t4	13142	2379	95
t5	3682	546	68
t6	9995	888	88



그림 2 클래스 t5 에 추가한 데이터 예

실험결과는 표 2 와 같다. 표에서 Pytorch transform 은 pytorch 라이브러리에서 제공하는 Data Augmentation 을 사용한 결과이다. Detection 은 Darknet YOLO 모듈을 사용한 결과이며, DCGAN 은 DCGAN 방법을 사용한 결과이다. 검증 정확도는 시험용 데이터를 클래스 구분없이 검증했을 거울의 결과이며, 평균 정확도는 클래스별로 정확도를 구한 뒤에 평균한 결과이다. Detection 과 DCGAN 방법 모두 실제 데이터를 추가한 경우와 유사한 성능향상을 보였으며, 두 가지 방법 모두 적용한 경우가 가장 좋은 성능을 나타내었다.

표 2 데이터 확대 방법에 따른 정확도

데이터 확대 방법 (클래스별 데이터 추가 수)	검증정확도(%)	평균정확도(%)
pytorch transforms	97.48	89.50
detection	97.83	91.33
DCGAN (0, 22, 0, 0, 74, 16)	97.77	91.17
detection + DCGAN	97.92	91.67
실제 조사한 데이터 추가 (40, 172, 147, 175, 1060, 648)	97.83	91.17

### III. 결론

딥러닝에서 충분한 양의 데이터는 매우 중요하다. 그러나 현실에서 정제된 데이터를 양껏 수집하기에는 시간과 비용상 한계에 부딪히게 되며 의료계 등 전문분야나 데이터의 보안이 중요시되는 분야에서는 그 문제가 더욱 심각하다. 이러한 문제를 해결하기 위해 제한된 데이터로 보다 높은 성능을 내기 위한 여러 가지 방법들이 제시되었다. 본 논문에서는 이러한 시도의 일환으로 실제 데이터 없이 기존 데이터의 변환 또는 가상 데이터를 사용하여 도로 교통량 조사에 사용되는 차종 분류 모델의 성능을 높이는 방법을 제안하였다. 제안된 방법을 사용하여, 데이터셋 구축을 최소화하면서 높은 성능을 보이는 차종 판별기를 개발할 수 있었다. 추후에는 생성모델에 대한 추가적인 연구를 통해 학습 데이터 다양성 증가를 확보하여 분류모델의 성능 향상을 도모할 계획이다.

### ACKNOWLEDGMENT

본 연구는 한국전자통신연구원 주요사업의 일환으로

수행되었음[21ZD1120, 대경권 지역산업 기반 ICT 융합기술

고도화 지원사업]

### 참 고 문 헌

- [1] 국토교통부, "도로 교통량 조사지침", 제 116 호, 2015.
- [2] <https://pytorch.org/>
- [3] He, Kaiming, et al. "Deep residual learning for image recognition." Proceedings of the IEEE conference on computer vision and pattern recognition. 2016.
- [4] Redmon, Joseph, and Ali Farhadi. "YOLO9000: better, faster, stronger." Proceedings of the IEEE conference on computer vision and pattern recognition. 2017.
- [5] Radford, Alec, Luke Metz, and Soumith Chintala. "Unsupervised representation learning with deep convolutional generative adversarial networks." arXiv preprint arXiv:1511.06434 (2015).