

논문 2024-13-28

# 도로교통량 조사를 위한 12종 차종 분류 방법

## (Vehicle Type Classification Method for Road Traffic Surveys)

강 미 선, 김 찬 호, 김 병 근\*  
(Mi-Seon Kang, Chan-Ho Kim, Pyong-Kun Kim)

Abstract : This paper proposes a novel method for effectively classifying 12 vehicle types required for road traffic surveys by utilizing deep learning techniques. In particular, it focuses on the trailer vehicle types, classified as types 8 to 12, which have been challenging in previous research due to data scarcity. A zero-shot learning approach, Grounding DINO, is employed to extract key features that can distinguish these trailer types, addressing the data imbalance issue. This method enables accurate classification of the underrepresented vehicle types, leading to efficient classification across all 12 types. To the best of the authors' knowledge, this is the first attempt to classify 12 vehicle types required for road traffic surveys using publicly available video data.

Keywords : Deep learning, Vehicle classification, Zero-shot learning, Grounding DINO, Traffic

### I. 서 론

도로교통량 조사는 특정 위치에서 차량의 통행량을 시간대, 차량 유형, 이동 방향 등에 따라 관측하여 도로의 성과 수용 능력을 평가하는 필수적인 과정이다. 이러한 조사는 교통 정책 수립, 도로 설계 및 유지보수 계획, 혼잡 완화 전략 등 다양한 교통 관리 분야에서 핵심적인 역할을 한다. 전통적으로, 차량의 종류를 분류하기 위해 육안 관찰이나 다양한 차량 감지 장치를 활용해 왔지만, 이 방법들은 높은 오류 발생 가능성과 낮은 효율성이라는 한계를 가지고 있다. 육안 관찰의 경우, 관찰자의 주관적인 판단에 따라 정확도가 떨어질 수 있으며, 특히 교통량이 많거나 관찰 조건이 열악할 경우 오류의 가능성이 더욱 커진다. 차량 감지 장치를 사용하는 방법도 설치와 유지 관리에 많은 비용이 들고, 감지기의 성능에 따라 정확도가 크게 좌우되기 때문에 신뢰성을 보장하기 어렵다. 또한, 이러한 전통적인 방법들은 새로운 교통 패턴이나 차량 유형이 등장할 경우 신속하게 대응하기 어려워, 실시간으로 변화하는 교통 상황을 정확히 반영하지 못하는 문제점이 있다. 이로 인해 도로교통량 조사의 정확성과 효율성을 향상시키기 위한 새로운 기술적 접근이 요구되고 있다.

최근 몇 년간 딥러닝 기술의 발전으로 인해 이미지 분류와 객체 인식을 활용한 차량 분류 기법이 각광받고 있지만, 이러한 방법을 효과적으로 적용하려면 대규모의 데이터가 필수적이다. 특히 12종으로 세분화된 차량 중 트레일러와 같은 8종에서 12종에 해당하는 몇몇 차종은 실제 도로에서

의 적은 통행량으로 인해 데이터 수집이 부족하다는 문제가 있다. 데이터 부족 문제는 단순한 학습 데이터의 양적 부족을 넘어서, 딥러닝 모델의 일반화 능력에도 부정적인 영향을 미치며, 특정 차종에 대한 분류 정확도를 심각하게 저하시킬 수 있다. 이러한 데이터의 불균형이 딥러닝 모델의 학습 과정에 큰 장애물이 된다는 점은 널리 알려져 있다 [1, 2]. 또한, 데이터 불균형 문제는 과적합 (overfitting)을 유발할 수 있으며, 이는 모델이 학습 데이터에는 적합하지만 실제 환경에서는 성능이 저하되는 원인이 될 수 있다.

본 논문에서는 도로교통량 조사에서 사용되는 12종의 차량 분류 문제를 해결하기 위한 새로운 딥러닝 기반 접근법을 제시한다. 특히 데이터 확보가 어려운 8종에서 12종에 속하는 트레일러 차량의 분류에 중점을 두어 연구를 진행한다. 일반적으로 학습 데이터가 충분한 승용차, 버스, 트럭과 같은 클래스는 기존의 딥러닝 분류 기법을 적용하여 분류하고, 상대적으로 데이터가 부족한 트레일러 클래스는 특정 특징을 추출하는 방법을 통해 분류를 수행한다. 또한, 트레일러 클래스의 학습 데이터 양이 모델 성능에 미치는 영향을 분석하기 위해, 데이터의 양에 따른 성능 차이를 비교한다. 제안된 방법은 기존의 문제점을 극복하며, 트레일러 차량의 정확한 분류를 가능하게 할 뿐만 아니라 트레일러 차종 데이터의 수집 어려움도 완화할 수 있을 것으로 기대 된다.

### II. 관련 연구

#### 1. 차종 분류 관련 연구

차종별 교통량 데이터는 도로 계획, 설계, 관리, 교통 흐름 분석 및 도로 행정 업무에서 중요한 기초 자료로 활용되며, 이는 도로법에 따라 체계적으로 수집된다. 차종 분류 기준은 시대와 연구 분야에 따라 달라졌는데, 그림 1에서 보

\*Corresponding Author (iros@etri.re.kr)

Received: Aug. 28, 2024, Revised: Sep. 10, 2024, Accepted: Sep. 24, 2024.

M. S. Kang, P. K. Kim: ETRI

C. H. Kim: Kyungpook National University

\* 본 논문은 한국전자통신연구원 연구운영지원사업의 일환으로 수행되었음. [24ZD1120, 대경권 지역산업 기반 ICT 융합기술 고도화 지원사업]

Classification Criteria	Representative Vehicle Structure and Axle Layout	Vehicle Definition	Example Vehicles
Axles: 2 Unit: 1		Class 1 (2 Axles): Vehicles with less than 16 seats, compact cars, mini trucks, and 2-axle vehicles	Compact cars, small vans, Chevrolet Spark, Renault, Mini Cooper, etc.
Axles: 2 Unit: 1		Class 2 (2 Axles): Vehicles with 16 or more seats, compact cars, mini trucks, bus-type vehicles	School buses, tourist buses, city buses, large vans, airport buses, etc.
Axles: 2 Unit: 1		Class 3 (2 Axles): Cargo trucks with up to 1.25-ton payload capacity	Small trucks, delivery trucks, vehicles with under 2.5 tons of payload
Axles: 2 Unit: 1		Class 4 (2 Axles): Cargo trucks with over 2.5-ton payload capacity	Medium-sized trucks, 2-axle trucks, fire trucks, mixer trucks
Axles: 3 Unit: 1		Class 5 (3 Axles): Cargo trucks with 3 axles	Large trucks, 5-ton dump trucks, cargo transporters
Axles: 4 Unit: 1		Class 6 (4 Axles): Cargo trucks with 4 axles	Mixer trucks, dump trucks, large cargo trucks
Axles: 5 Unit: 1		Class 7 (5 Axles): Cargo trucks with 5 axles	Large dump trucks, large cargo vehicles
Axles: 4 Unit: 2		Class 8 (2-unit, 4 Axles): Semi-trailer trucks with 4 axles	Semi-trailers, large tankers, flatbed trucks
Axles: 4 Unit: 2		Class 9 (2-unit, 4 Axles): Full-trailer trucks with 4 axles	Full trailers, cargo transporters
Axles: 5 Unit: 2		Class 10 (2-unit, 5 Axles): Semi-trailer trucks with 5 axles	Large semi-trailers, large cargo tankers
Axles: 5 Unit: 2		Class 11 (2-unit, 5 Axles): Full-trailer trucks with 5 axles	Full trailers, large cargo transporters
Axles: 6 Unit: 2		Class 12 (2-unit, 6 Axles): Semi-trailer trucks with 6 axles	Extra-large semi-trailers, large tankers

그림 1. 12종 차종 분류표  
Fig. 1. Vehicle Type Classes

는 것처럼 현재는 2006년에 도입된 12종 분류 기준이 널리 사용되고 있다 [3]. 기존의 차량 분류 연구는 주로 센서 기술을 활용하여 이루어졌으며, 차량 분류의 핵심 요소인 축수를 측정하기 위해 다양한 센서가 사용되었다. 또한, 차량의 길이와 높이를 측정하여 분류하는 방법도 연구되어 왔다 [4]. 그러나 이러한 접근법은 센서 설치 및 유지 관리 비용이 많이 들고, 정확성에 한계가 있어 널리 채택되기 어려웠다. 또한 비매설식 차량 방법인 차량 제원 데이터베이스와 번호판 자동인식 기술을 이용하여 도로 교통량 조사를 개선하는 방법도 있으나, 다차로에는 차량 번호판 인식이 어렵고 보이지 않는 경우가 많아서 차종 분류가 어렵다 [5].

2. 딥러닝 관련 연구

최근 연구들은 딥러닝 기술의 발전이 차종 분류의 정확성을 크게 향상시킬 수 있음을 입증하고 있다. 특히, 합성곱 신경망 (CNN)을 활용한 연구들은 기존의 전통적인 기계 학습 방법에 비해 월등히 높은 성능을 보여주며, 영상 기반 차종 분류에서 중요한 돌파구를 마련했다. 예를 들어, YOLO [6, 7] 기반의 도로교통량 자동 수집 모델은 승용차, 버스, 트럭 등 6가지 차종을 주간 영상에서 약 95%의 정확도로 분류하는 뛰어난 결과를 보여주었다 [1]. 이러한 모델들은 차종 분류 후 검증 과정을 통해 정확도를 더욱 높였으며, 이로 인해 시간 및 인력 비용을 크게 절감할 수 있었다 [8]. 다중 뷰 감

시 카메라 이미지에서 차량 유형을 자동으로 분류하는 모델은 딥러닝을 사용하여 97.84%까지 성능을 향상시켰다 [9]. 또한 Grounding DINO 모델은 transformer 기반 구조와 제로-샷 객체 검출 능력을 결합하여, 추가적인 학습 없이도 COCO 데이터셋에서 뛰어난 성능을 발휘하는 것으로 평가받고 있다 [10]. 이러한 발전은 딥러닝 모델이 차종 분류의 정확도를 높이는 데 있어 지속적으로 진화하고 있음을 나타내며, 특히 차량 외형 데이터를 이용한 새로운 접근법들이 실질적인 응용 가능성을 갖추고 있음을 보여준다. 나아가, 최근에는 더 나은 모델의 일반화 능력을 확보하기 위해 다양한 데이터 증강 기법이 도입되어, 현실적인 환경에서의 성능을 더욱 강화하려는 연구가 활발히 진행되고 있다.

III. 본 론

본 연구는 8 ~ 12종에 해당하는 트레일러 차종의 데이터 부족으로 인한 영상 기반 차종 분류의 어려움을 두 가지 문제로 나누어 해결하고자 한다. 먼저, 데이터가 충분히 확보된 승용차 및 트럭 (1 ~ 7종)은 기존의 영상 기반 분류 방법을 적용하여 처리한다. 반면, 데이터가 부족한 트레일러 차종 (8 ~ 12종)은 다른 접근법을 적용한다. 이 접근법은 바퀴 위치 정보를 활용하여 트레일러의 차종을 결정하는 방식으로, 입력된 차량 영상에서 승용차와 트럭 (1 ~ 7종)은 기존 방법을 사용하여 분류하고, 트레일러 (8 ~ 12종)는 두 가지 트레일러 카테고리로 먼저 분류한 후, 바퀴의 특징 정보를 추가로 추출하여 세부적으로 분류한다. 이때 Grounding DINO 방법을 적용하여 바퀴 위치 정보를 효과적으로 활용한다. 또한, Grounding DINO 방식을 사용하지 않고, 기존의 영상 기반 분류 방법만을 적용할 경우 성능이 어떻게 달라지는지를 측정하여, 8 ~ 12종에 해당하는 데이터 확보의 중요성을 실험 결과로 입증한다. 연구의 전체적인 프로세스는 그림 2에 나타난 바와 같다.

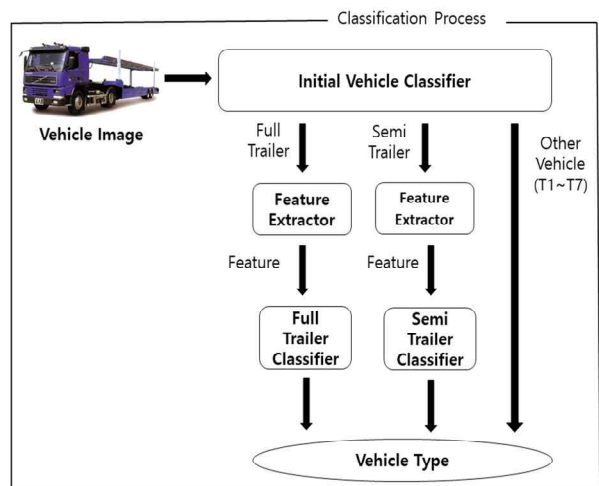


그림 2. 제안한 차량 분류 프로세스  
Fig. 2. Proposed process



그림 3. 트레일러 차량의 소분류 및 대분류  
Fig. 3. Subcategories and Categories of Trailer Vehicles

1. 데이터셋

본 연구에서는 한국건설기술연구원에서 제공하는 AI 학습용 도로교통량 데이터를 활용하였다 [11]. 데이터의 라벨링은 도로교통량 조사 지침에 따라 1종부터 12종까지를 각 T1에서 T12로 명명하였다 [12]. 데이터가 부족한 8종에서 12종까지의 데이터는 인터넷에서 수집한 데이터를 일부 활용하였다. 전체 데이터셋은 모델 학습 및 성능 평가를 위해 7:1:2 비율로 훈련, 검증, 테스트 데이터로 나누어 사용하였다. 또한, 초기 차량 분류 단계에서 데이터가 부족한 트레일러 차량에 그림 3과 같이 8종, 10종, 12종을 "Semi", 9종과 11종을 "Full"로 분류하여 9개 카테고리 형식으로 재정의하여 활용하였다.

2. ResNet 기반 초기 차량 분류

본 연구에서는 파이토치 [13]의 사전 학습된 ResNet-50 모델을 이용해 9개의 클래스 (트레일러 클래스를 Semi와 Full로 분류)를 대상으로 차량 분류에 대한 fine-tuning을 진행하였다. 이를 위해 모델의 마지막에 새로운 선형 분류층을 추가한 후, 다른 층들의 가중치는 고정하고 추가된 분류층만 학습하였다. 그 후, 학습된 가중치를 기반으로 전체 모델을 다시 학습하여 초기 차량 분류기로 활용하였다.

3. Grounding DINO를 이용한 특징 추출

트레일러 클래스의 세부 분류를 위해 학습 데이터가 부족한 상황을 해결하고자, 제로-샷 객체 검출 모델인 Grounding DINO [10]를 도입하였다. 이 모델을 활용하여 바퀴를 주요 분류 기준으로 검출한 후, 검출된 바퀴의 개수와 위치 정보를 추출하였다. 바퀴의 위치는 바운딩 박스의 중점을 기준으로 하였으며, 중점의 좌표를 상대 좌표로 변환하였다. 이후, 바퀴의 개수와 변환된 중점 좌표를 활용하여 트레일러의 세부 분류기를 학습하였다.

4. AutoML을 사용한 트레일러 분류

본 연구에서는 트레일러를 분류하기 위한 두 가지 접근법을 제안한다: 바퀴 수만을 이용한 규칙 기반 방식과 바퀴 수와 위치를 함께 사용하는 기계 학습 방식이다. 기계 학습

방식의 경우, Pycaret [14]이라는 AutoML 라이브러리를 활용하여 모델을 학습시키고 성능을 평가하였다. 두 방식의 성능을 비교하여 가장 적합한 트레일러 분류기를 선정하였으며, 정확도를 주요 성능 평가 지표로 사용하였다. 또한, 세미 트레일러와 풀 트레일러 각각에 대해 최적의 분류기를 별도로 선택하였다.

IV. 실험 결과

본 연구에서는 그림 2에 나타난 차량 분류 프로세스를 기반으로 차량 분류 실험을 수행하였다. 또한, 8종에서 12종에 해당하는 데이터 양에 따라 ResNet을 사용한 실험도 추가적으로 진행하여, 데이터 양에 따라서 성능이 어떻게 달라지는지 분석하였다.

1. 실험 환경 및 데이터셋

본 연구에서는 표 1과 표 2의 데이터를 통합하여 표 3의 데이터를 생성하였다. 그리고 표 4에서처럼 8종에서 12종을 Semi, Full로 나누어 차량 9개에 대한 분류 프로세스를 진행하였다.

표 1. 한국건설기술연구원 데이터  
Table 1. Korea Institute of Civil Engineering and Building Technology (KICT) data

T1	T2	T3	T4	T5	T6	T7	T8	T9	T10	T11	T12
41,495	1,174	7,599	3,500	3,589	1,871	1,021	4	2	8	3	5

표 2. 인터넷 수집 데이터 (8종 ~ 12종)  
Table 2. Data collected on the internet (8 ~ 12 types)

T8	T9	T10	T11	T12
164	205	276	232	123

표 3. 차량 12종에 대한 훈련, 검증, 테스트 데이터  
Table 3. Training, validation, and test data for 12 vehicle classes

Vehicle classes	Train	Validation	Test
T1	700	100	200
T2	700	100	200
T3	700	100	200
T4	700	100	200
T5	700	100	200
T6	700	100	200
T7	700	100	200
T8	117	16	35
T9	144	20	43
T10	198	28	58
T11	161	23	47
T12	86	12	25

표 4. 9개 분류에 대한 훈련, 검증, 테스트 데이터  
Table 4. Training, validation, and test data for 9 vehicle classes

Vehicle classes	Train	Validation	Test
T1	700	100	200
T2	700	100	200
T3	700	100	200
T4	700	100	200
T5	700	100	200
T6	700	100	200
T7	700	100	200
Semi	401	56	118
Full	305	43	90

2. ResNet을 활용한 초기 차량 분류기 학습 결과

ResNet-50의 하이퍼파라미터를 다음과 같이 설정하여 실험을 진행하였다. Max Epoch은 100으로, Optimizer는 Adam, Loss Function은 Cross Entropy로 설정하여 fine-tuning을 수행하였다. 정확도 (Accuracy)는 모델이 예측한 값 중에서 얼마나 많은 경우에 정답을 맞췄는지를 나타낸다. 즉, 전체 데이터에서 올바르게 분류된 데이터의 비율을 계산한다. 여기서 올바른 분류는 모델이 긍정 또는 부정으로 예측한 결과가 실제 값과 일치하는 경우를 말한다. 예를 들어, 차량이 승용차인 경우 모델이 승용차로 정확하게 예측하거나, 차량이 승용차가 아닌 경우에도 모델이 이를 정확히 예측한 경우가 포함된다.

F1-Score는 정밀도 (Precision)와 재현율 (Recall)의 조화 평균으로, 주로 데이터가 불균형한 상황에서 성능 평가에 적합한 지표이다. 정밀도는 모델이 양성으로 예측한 항목 중 실제로 양성인 데이터의 비율을 의미하며, 재현율은 실제로 양성인 데이터 중에서 모델이 정확하게 양성으로 예측한 비율을 뜻한다. F1-Score는 이 두 가지 비율의 균형을 평가하여, 모델이 잘못된 양성 예측과 잘못된 음성 예측 모두에 대해 얼마나 잘 대응했는지를 종합적으로 나타낸다.

표 4의 데이터를 활용해 백분은 고정하고, 분류층만 학습한 결과, 학습 과정에서 91번째 epoch에서 검증 성능 (F1-Score) 80.48%로 가장 높은 성능을 기록하였으며, 이때의 모델 가중치를 저장하였다. 이후, 저장된 가중치를 초기 값으로 사용하여 백분을 포함한 ResNet-50 모델 전체를 학습시켰다. 이 과정에서 67번째 epoch에서 검증 성능이 96.62%로 최고치를 기록하였고, 해당 모델을 초기 차량 분류기로 선정하였다. 마지막으로, 이 모델을 테스트 데이터에 적용한 결과는 그림 4와 같다. 차종별 데이터 불균형으로 인해, 승용 및 버스 클래스의 정확도는 높고 상대적으로 트럭의 정확도가 낮다. 세미 트레일러와 풀 트레일러에서는 각각 99.15%와 95.56%의 정확도를 기록하였다.

3. Grounding DINO를 적용한 특징 추출 결과

Semi와 Full 클래스의 바퀴를 검출하기 위해 Grounding

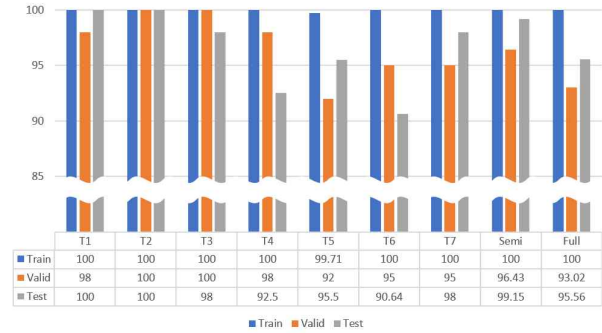


그림 4. 12종 차종 실험 결과  
Fig. 4. Experimental results for 12 vehicle classes



그림 5. 트레일러 바퀴 검출 사례  
Fig. 5. The examples of wheel detection

DINO 모델을 활용하였다. 이를 통해 검출된 바퀴의 수와 각 바퀴의 위치 정보를 추출할 수 있었다. 그림 5는 8종에서 12종까지의 차량에서 바퀴를 검출한 사례를 보여준다. 트레일러 바퀴에 대한 별도의 학습이 없었음에도 불구하고, 바퀴 외형의 유사성 덕분에 효과적인 바퀴 검출이 가능하였다. 이러한 검출 결과를 바탕으로, 훈련 집합, 검증 집합, 테스트 집합에서 바퀴의 정보를 추출하였으며, 훈련 집합에서 추출된 바퀴 정보는 기계 학습 모델의 학습에 사용되었다. 또한, 검출된 바퀴의 위치 정보는 세부적인 분류 작업에서 중요한 요소로 작용하였다. 이와 같은 바퀴 검출과 위치 정보 추출 과정은 트레일러 분류의 정확도를 높이는 데 크게 기여하였다. 특히, 바퀴 위치 정보를 활용한 접근법은 복잡한 도로 환경에서도 일관된 성능을 보였으며, 데이터의 질적 향상을 통해 모델의 신뢰성을 높였다.

4. AutoML를 이용한 트레일러 분류 실험 결과

도로 교통량 조사 지침에 따르면, 세미 트레일러는 바퀴가 4개일 경우 8종, 5개일 경우 T10, 6개 이상일 경우 12종으로 분류되며, 풀 트레일러는 바퀴가 4개일 경우 9종, 5개일 경우 11종으로 분류된다. 이 분류 기준을 토대로, 본 연구에서는 바퀴 수를 기반으로 한 규칙 기반 접근법과 바퀴 수와 위치 정보를 학습하는 기계 학습 접근법을 통해 트레일러 분류 실험을 진행하였다. 규칙 기반 접근법은 구현이 간단하고 직관적이라는 장점이 있지만, 다양한 조건에서의 정확도가 떨어지는 경향이 있었다. 반면, 기계 학습 접근법은 더 복잡한 패턴을 학습하고 적용할 수 있어 더 높은 정

표 5. 규칙 기반 방식을 이용한 실험 결과의 정확도

Table 5. Accuracy of experimental results using rule-based approach

	T8	T9	T10	T11	T12
Train	56.41%	64.58%	63.4%	70.81%	50.62%
Valid	43.75%	65.00%	69.23%	56.52%	83.33%



그림 6. 트레일러 바퀴 검출의 잘못된 사례  
Fig. 6. Examples of incorrect trailer wheel detection

확도를 보여주었다. 이를 통해 도로교통량 조사에 있어 최적의 트레일러 분류 방법을 제안하였다.

4.1 규칙기반의 실험 결과

표 5는 규칙 기반 접근법을 사용한 실험 결과를 보여주고 있으며, 학습 및 검증 단계에서 좋은 성능을 얻지 못한 이유를 설명하고 있다.

그림 6에서 확인할 수 있듯이, 다른 차량의 바퀴가 함께 검출되는 경우, 규칙에서 벗어난 데이터에 대한 정확도가 크게 떨어졌다. 이러한 문제는 규칙 기반 방식의 한계로 작용하여, 특히 복잡한 도로 환경에서 더욱 두드러지게 나타났다. 따라서, 바퀴 위치 정보를 추가로 고려한 기계 학습 접근법이 필요함을 시사한다.

4.2 바퀴 수 및 바퀴 위치를 고려한 실험 결과

바퀴 수와 바퀴 위치를 고려한 실험 결과는 그림 7과 그림 8에 제시되어 있다. AutoML 라이브러리를 활용한 학습 결과, 세미 트레일러 분류에서는 Extra Trees Classifier가 교차 검증 평균 정확도 77.14%로 가장 우수한 성능을 보였으며, 풀 트레일러 분류에서는 Gradient Boosting Classifier가 88.77%로 가장 뛰어난 성능을 나타냈다. 이에 따라, 세미 트레일러 분류기는 Extra Trees Classifier로, 풀 트레일러 분류기는 Gradient Boosting Classifier로 선정하여 성능 검증을 진행하였다. 바퀴의 수와 위치 정보는 트레일러의 구조적 특징을 반영하는 중요한 요소로 사용되었으며, 기계학습 모델의 입력 변수로서 바퀴의 수와 위치 정보를 사용하여 트레일러 분류기를 학습시켰다. 이 입력 정보는 각 트레일러 유형의 특성을 정확하게 반영하는 주요 기준이 되었으

	Model	Accuracy	AUC	Recall	Prec.
et	Extra Trees Classifier	0.7714	0.9063	0.7714	0.7793
catboost	CatBoost Classifier	0.7643	0.8851	0.7643	0.7707
gbc	Gradient Boosting Classifier	0.7571	0.8934	0.7571	0.7591
rf	Random Forest Classifier	0.7536	0.8919	0.7536	0.7625
xgboost	Extreme Gradient Boosting	0.7464	0.8783	0.7464	0.7493
ada	Ada Boost Classifier	0.7250	0.8192	0.7250	0.7363
lda	Linear Discriminant Analysis	0.6821	0.7900	0.6821	0.6829
knn	K Neighbors Classifier	0.6786	0.8000	0.6786	0.6836
ridge	Ridge Classifier	0.6750	0.0000	0.6750	0.6762
lr	Logistic Regression	0.6679	0.7844	0.6679	0.6687

그림 7. 세미 트레일러 분류 실험 결과  
Fig. 7. Experimental results of Semi-trailer classification

	Model	Accuracy	AUC	Recall	Prec.
gbc	Gradient Boosting Classifier	0.8831	0.9254	0.8831	0.8851
lr	Logistic Regression	0.8784	0.8642	0.8784	0.8806
knn	K Neighbors Classifier	0.8783	0.8980	0.8783	0.8810
rf	Random Forest Classifier	0.8783	0.9455	0.8783	0.8799
et	Extra Trees Classifier	0.8783	0.9387	0.8783	0.8813
catboost	CatBoost Classifier	0.8736	0.9408	0.8736	0.8761
ridge	Ridge Classifier	0.8691	0.0000	0.8691	0.8721
xgboost	Extreme Gradient Boosting	0.8690	0.9202	0.8690	0.8736
lda	Linear Discriminant Analysis	0.8645	0.8306	0.8645	0.8665
ada	Ada Boost Classifier	0.8456	0.8534	0.8456	0.8493
dt	Decision Tree Classifier	0.8269	0.8249	0.8269	0.8343

그림 8. 기계학습기반풀트레일러 분류 실험 결과  
Fig. 8. Experimental results of full-trailer classification

며, 기계학습을 통해 트레일러를 효과적으로 구분할 수 있었다.

4.3 트레일러 분류 실험 결과 요약

규칙기반 방식과 기계학습 기반 방식 중 더 우수한 성능을 보인 바퀴 수와 위치 정보를 학습한 기계 학습 기반 트레일러 분류기를 최종적으로 선택하였다. 이 과정에서 바퀴 수와 위치 정보가 트레일러 분류에 중요한 특징으로 작용했으며, 모델의 성능을 크게 향상시켰다. 그림 9는 최종 선정된 트레일러 분류기를 이용하여 성능 평가를 진행한 결과를 보여준다. 훈련 데이터와 검증 데이터에 대한 성능 평가 결과, 훈련 정확도는 100.00%, 검증 정확도는 평균 81.17%로 나타났다. 테스트 데이터에 대한 성능 평가 결과는 73.91%의 성능을 보였다. 훈련데이터의 정확도가 100%임에도 불구하고 낮은 성능을 보인다는 것은 제안된 기법이 훈련 데이

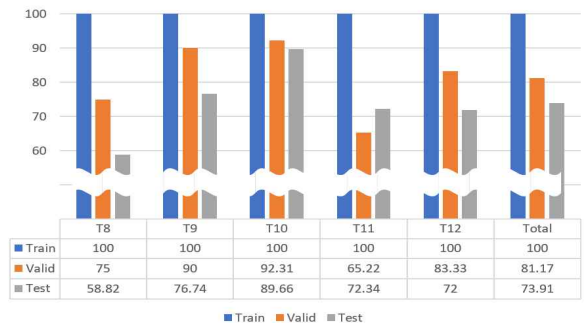


그림 9. 기계학습 모델을 이용한 트레일러 분류 실험 결과  
Fig. 9. Experimental results of trailer classification using machine learning models




그림 10. 전체 12종 차종 실험 결과

Fig. 10. Experimental results of classification for all 12 vehicle classes

터에 대한 적응력이 높음을 보여주며, 학습된 모델이 새로운 데이터에 대한 일반화 성능이 부족할 수 있음을 시사한다. 따라서, 향후 별도로 데이터에 대한 추가 검증이 필요함을 시사하며, 검증 정확도를 향상시키기 위한 추가적인 데이터 확보 및 모델 개선이 필요하다고 판단된다.

5. 전체 12종에 대한 실험 결과

최종적으로 12종 전체를 대상으로 한 분류 결과는 그림 10에 제시되어 있다. 차종 간 데이터 불균형으로 인해 승용차와 버스 클래스의 정확도는 높은 반면, 트럭 클래스는 상대적으로 낮은 정확도를 보였다. 특히 트레일러의 경우 정확도가 가장 낮았지만, 학습 데이터의 수가 적다는 점을 고려할 때 이 성능은 충분히 만족할 만한 수준이라고 평가할 수 있다. 최종적으로는 93.84%의 높은 정확도를 달성한 것을 확인할 수 있다. 이는 모델이 일부 데이터가 부족한 클래스에서도 어느 정도의 일반화 능력을 유지했음을 의미한다. 또한, 이러한 결과는 추가 데이터 수집 및 학습 데이터의 균형 조정이 모델 성능 개선에 중요한 역할을 할 수 있음을 시사한다.

6. 8종에서 12종 데이터 양에 따른 성능 결과

본 논문에서는 추가로 8종에서 12종에 해당하는 데이터를 기존의 ResNet 기반 방식으로 실험하여, 데이터 양에 따른 성능 변화를 분석하였다. 이 실험은 제안된 방식이 아닌 기존 방식으로 접근했을 때 데이터 양에 따른 결과가 어떻게 달라지는지를 확인하기 위함이다. 표 3의 데이터를 사용하여 8종에서 12종까지의 데이터를 각각 100%, 50%, 20%로 나누어 실험을 진행하였다.

그림 11은 이러한 데이터 양에 따른 실험 결과를 보여준다. X축은 사용된 데이터 양을 나타내며, 각각의 실험에서 데이터를 100%, 50%, 20%로 줄여가며 분석한 결과를 표현한다. Y축은 데이터 양에 따른 모델의 정확도를 나타내는 성능 지표로, 각 데이터 양에서 모델이 얼마나 정확하게 분류를 수행했는지를 퍼센트로 표시하고 있다. 그림 9에서 확인할 수 있듯이, 데이터 양이 줄어들수록 성능이 점진적으로 감소하는 경향을 보였다. 특히 8종에서 12종까지의 데이




그림 11. 8종에서 12종 데이터 양에 따른 실험 결과

Fig. 11. Experimental results based on the data volume for classes 8 to 12

터가 100% 사용될 때는 높은 성능을 유지했으나, 50%로 감소시켰을 때 성능 저하가 눈에 띄게 나타났다. 20%의 데이터를 사용한 경우, 성능 저하는 더욱 심각해졌으며, 특정 클래스에서는 분류 정확도가 크게 떨어졌다.

이 실험은 데이터 양이 모델 성능에 큰 영향을 미친다는 중요한 사실을 보여준다. 데이터가 많을수록 모델은 더 높은 정확도를 유지할 수 있지만, 데이터가 부족하면 성능이 저하되며, 이는 딥러닝 모델에서 특히 두드러진다. 따라서, 이 실험 결과는 충분한 데이터 확보의 중요성을 강조하며, 데이터가 제한된 상황에서 성능을 향상시키기 위한 방법이 필요함을 보여준다. 이는 본 논문에서 제안된 방식이 기존 ResNet 방식보다 데이터 효율성이 높을 가능성을 제시하며, 데이터 양이 제한된 경우에도 안정적인 성능을 기대할 수 있는 방법론으로 발전할 수 있음을 보인다.

V. 결론

본 논문에서는 CCTV 영상만을 사용하여 도로교통량 조사를 위한 12종의 차종 분류 방법을 제안하였다. 특히, 데이터 부족 문제를 해결하기 위해 Grounding DINO를 도입하여 바퀴 특징 정보를 추출함으로써 8종에서 12종에 해당하는 트레일러 클래스를 효과적으로 판별하였으며, 최종적으로 93.84%의 높은 정확도를 달성하였다. 제안된 방법은 ResNet-50을 초기 차량 분류기로 활용하여 1종에서 7종까지의 차량을 분류한 후, Grounding DINO를 통해 트레일러를 추가적으로 분류하는 2단계 접근방법이다.

실험 결과, 데이터 양이 모델 성능에 미치는 영향이 크다는 점이 확인되었으며, 특히 데이터가 충분하지 않을 경우 성능 저하가 발생할 수 있음을 보여주었다. 이러한 데이터가 제한된 환경에서도 제안된 방법은 비교적 높은 성능을 유지할 수 있어, 도로교통량 조사를 위한 차종 분류에 유용

하게 활용될 수 있을 것으로 기대된다.

그러나 이 논문에는 몇 가지 한계점이 있다. 바퀴를 올바르게 검출하지 못하는 경우에는 차량의 특징을 정확하게 추출하기 어려워지며, 이로 인해 분류 성능이 크게 저하될 수 있다. 이러한 한계를 극복하기 위해서는 실제 환경에서 카메라의 설치 위치를 조정하여 바퀴가 더욱 명확하게 보이도록 설정하는 것이 필요할 수 있다. 따라서, 제안된 방법은 이러한 제한적인 조건에서 더 높은 적용 가능성을 가질 것으로 예상된다.

추후 연구에서는 추가적인 12종 차종 분류 방법을 다른 데이터셋에 적용하여 테스트하고, 성능을 더욱 개선하는 방향으로 진행될 예정이다. 이를 통해 실제 도로 환경에서의 적용 가능성을 높이고, 다양한 환경에서도 안정적인 성능을 보이는 차종 분류 모델을 개발할 수 있을 것이다. 더 나아가, 도로환경 변화에 따른 다양한 차량 종류와 외부 요인들을 고려한 실험이 이루어질 필요가 있다. 이는 장기적으로 도로 안전성과 교통 관리 효율성을 동시에 향상 시킬 수 있는 방안을 제시할 것이다.

따라서 이 연구는 도로교통량 조사의 자동화 및 실시간 차종 분류 시스템 개발을 위한 중요한 기초 연구로 자리매김할 수 있을 것이다.

### References

[1] J. H. Park, B. G. Kim, M. S. Kang, "A Study on the Performance Improvement of Vehicle Types Classification," Proceedings of the Korean Institute of Communications and Information Sciences Conference, pp. 967-968, 2021.

[2] J. M. Johnson, T. M. Khoshgoftaar, "Survey on Deep Learning with Class Imbalance." Journal of Big Data, Vol. 6, No. 1, pp. 1-54, 2019.

[3] Y. T. Sohn, M. S. Do, Y. H. Yoon, "A Study on the Improvement of Vehicle Classification Criteria for Road Traffic Volume Survey," Journal of the Korean Society of Transportation, Vol. 19, No. 3, pp. 153-165, 2001.

[4] J. S. Oh, K. C. Jang, M. S. Kim, "Vehicle Classification Plan for Two-Axle Vehicles Using Vehicle Shape Data," Journal of Korean Intelligent Transport Systems Society, Vol. 10, No. 5, pp. 47-52, 2011.

[5] J. M. Kim, D. S. Oh. "A Study on Road Traffic Volume Survey Using Vehicle Specification DB." J. Korea Inst. Intell. Transp. Syst., Vol. 22, No. 2, 2023, pp. 93-104.

[6] J. Redmon, S. Divvala, R. Girshick, A. Farhadi, "You

only Look Once: Unified, Real-time Object Detection." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. pp. 779-788, 2016.

[7] J. Redmon, A. Farhadi, "YOLO9000: Better, Faster, Stronger." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. pp. 7263-7271, 2017.

[8] M. S. Kang, P. K. Kim, K. T. Lim, Y. Z. Cho, "Method for Obtaining Better Traffic Survey Data" Electronics, Vol. 10, No. 7, pp. 833, 2021.

[9] P. K. Kim, K. T. Lim, "Vehicle Type Classification Using Bagging and Convolutional Neural Network on Multi View Surveillance Image." Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 41-46, 2017.

[10] S. Liu, Z. Zeng, T. Ren, F. Li, H. Zhang, J. Yang, C. Li, J. Yang, H. Su, J. Zhu, L. Zhang, "Grounding DINO: Marrying DINO with Grounded Pre-training for Open-set Object Detection," arXiv preprint arXiv:2303.05499, 2023.

[11] [http://www.road.re.kr/pds/request\\_info.asp](http://www.road.re.kr/pds/request_info.asp)

[12] Ministry of Land, Infrastructure and Transport, "Road Traffic Volume Survey Guidelines" [Effective April 1, 2023], Ministry of Land, Infrastructure and Transport Decree No. 362, March 24, 2023, partial revision.

[13] <https://pytorch.org/>

[14] <https://pycaret.org/>

### Mi-Seon Kang ( 강 미 선 )



2010 Electronics, Electrical, and Computer Engineering, Kyungpook National University (B.S.)  
 2012 Electronics, Electrical, and Computer Engineering, Kyungpook National University (M.S.)

2022 Electronics and Electrical Engineering, Kyungpook National University (Ph.D.)

Career:

2012.09. ~ Current: Senior Researcher, Electronics and Telecommunications Research Institute (ETRI)

Field of Interests: Development of AI-driven technologies for quality inspection, defect detection, illegal activity monitoring, traffic analysis, and infrastructure management

Email: tams37@etri.re.kr

**Pyong-Kun Kim (김 병 군)**

1997 Electrical Engineering, Seoul National University (B.S.)

1999 Electrical Engineering, Seoul National University (M.S.)

## Career:

2002.05. ~ Current: Electronics and Telecommunications Research Institute (Principal Researcher)

Field of Interests: Industrial Automation by AI technology

Email: iros@etri.re.kr

**Chan-Ho Kim (김 찬 호)**

2024 Computer Science and Engineering, Kyungpook National University (B.S.)

## Career:

2023.07. ~ 2023.12 Undergraduate Researcher, Vision and Intelligent Systems Lab, Kyungpook National University

2024.01. ~ 2024.02 Research Intern, Electronics and Telecommunications Research Institute (ETRI)

Field of Interests: Artificial Intelligence, Computer Vision, Domain Adaption, Smart City

Email: coolho123@knu.ac.kr