

YOLO 기반 도로 파손 및 차량 탐지 성능 분석 연구

Performance Analysis of YOLO-Based Road Damage and Vehicle Detection

최재명¹

Jae Myeong Choi¹

요약

본 연구에서는 도로 시설물의 생애주기비용(LCC) 관리를 위하여 도로 파손 및 차량 데이터를 수집하여 분석하였다. 또한, 차량탐지는 YOLOv8n 모델을 MIO-TCD 데이터셋으로 학습시켰으며, mAP@0.5 기준 82.2%의 정확도를 달성하였다. 포트홀 탐지를 위해서는 RDD2022 데이터셋을 활용하였으며, 일부 YOLO 모델의 성능 비교를 수행하였다. 성능 비교 결과, YOLOv5n 모델이 가장 안정적이고 높은 mAP@0.5 (0.271)를 보였다. 또한, 도로 파손 클래스를 망상 균열, 가로, 세로 등 8개 유형으로 세분화하고, 라벨링 기준을 정립하여 데이터 고도화를 수행하였다. 구현한 시스템은 탐지된 차량 데이터를 기반으로 ESAL을 자동으로 계산하고 도로 포장의 피로도를 예측하여 예방적 유지보수 계획 수립에 활용할 수 있을 것이다. 결론적으로, 본 연구는 기존의 방식에서 벗어난 능동적인 교통 데이터 수집 방식과 효율성이 입증된 포트홀 탐지 모델을 성공적으로 도출하였으며, 이는 향후 지능형 도로 관리 시스템의 완성도를 획기적으로 높이는 데 크게 기여할 수 있을 것이다.

핵심어 : YOLO, 차량 탐지, 도로 파손, 생애주기 비용, MIO-TCD

Abstract

In this study, road damage and vehicle data were collected and analyzed for the management of the Life Cycle Cost (LCC) of road facilities. Additionally, for vehicle detection, the YOLOv8n model was trained with the MIO-TCD dataset, achieving an accuracy of 82.2% based on mAP@0.5. For pothole detection, the RDD2022 dataset was utilized, and a performance comparison of some YOLO models was conducted. As a result of the performance comparison, the YOLOv5n model showed the most stable and highest mAP@0.5 (0.271). Furthermore, road damage classes were subdivided into 8 types, including crazing cracks, transverse, and longitudinal cracks, and data refinement was performed by establishing labeling criteria. The implemented system automatically calculates ESAL based on the detected vehicle data and predicts the fatigue of the road pavement, which can be utilized for establishing preventive maintenance plans. Conclusively, this study successfully derived an active traffic data collection method that deviates from conventional methods and an efficiently proven pothole detection model, which will greatly contribute to significantly enhancing the completeness of future intelligent road management systems.

¹ Department Computer Engineering, Mokwon University, Seoul, Korea [Assistant Professor]
e-mail: jmchoi@mokwon.ac.kr

* 이 논문은 2025년도 정부(산업통상자원부)의 재원으로 한국산업기술진흥원의 지원을 받아 수행된 연구임 (P0024164, 2025년 지역혁신클러스터육성).

Received(November 27, 2025), Review Result(1st: December 9, 2025), Accepted(December 12, 2025), Published(December 31, 2025)



© 2025 The Authors. Published by NCISS.
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

Keyword : YOLO, Vehicle Detection, Road Damage, Life Cycle Cost, MIO-TCO

1. 서론

생애주기 비용(LCC, Life Cycle Cost) 분석은 시설물의 초기 투자부터 운영, 유지관리, 폐기에 이르는 전 생애에 걸쳐 발생하는 모든 비용을 현재 가치로 환산하여 경제성을 평가하는 기법이다 [1]. 이러한 도로 생애주기 전반의 비용을 효율적으로 관리하기 위해서는 각 단계에서 정확한 교통 데이터가 필수적인 기반 요소로 작용한다. 과거에는 수동적인 방법을 통해 제한적인 교통량 데이터만을 수집하여 막대한 예산이 소요되고 범위가 한정적이라는 한계가 있었다.

본 연구에서는 이러한 한계를 극복하기 위하여 도시 전역에 설치되어 있는 CCTV 인프라를 활용하고, YOLOv8과 같은 실시간 객체 탐지 모델을 적용하여 차량탐지 및 차종 분류를 수행하는 시스템을 구현한다 [2]. 또한, 도로 안전 및 유지보수의 핵심적인 요소인 도로 파손(포트홀, 크랙)에 대하여 일부 YOLO 모델 버전별 성능을 비교 연구한다 [3][4]. 본 연구는 기존의 수동적이고 단편적인 교통 데이터의 수집 방식을 개선하고, 능동적인 방식으로 전환할 수 있는 토대를 마련한다.

2. 연구 내용


2.1 도로 파손 데이터 고도화 및 라벨링 기준 정립


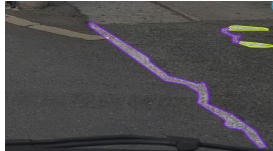







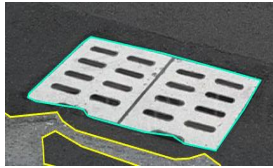


도로 파손 데이터 고도화 작업을 통해 기존 6개 파손 유형(사람, 맨홀, 하수구, 차량, 포트홀, 크랙)을 기반으로 하되, 크랙 유형을 세부 형태에 따라 세로 균열(Longitudinal), 가로 균열(Transverse), 망상 균열(Crazing)의 클래스로 재분류하여 총 8개의 클래스를 기준으로 라벨링을 수행했다 [5].

[표 1]은 본 연구에서 정립한 도로 파손 라벨링의 세부 기준을 보여준다. 또한, 대각선 형태의 균열에 대해서는 균열의 비율을 기준으로 주 방향을 판단하여 분류하는 애매 사례 대응 규칙을 정립했다.

[표 1] 8개의 클래스 정의 및 판별 기준

[Table 1] Definition and Discrimination Criteria for the Eight Classes

분류 색상	클래스 명	시각적 정의(판별 기준)	이미지
■	Crack_Crazing (망상 균열)	<ul style="list-style-type: none"> • 그물망 형태로 다수의 균열이 얽혀 표면 전체가 네트워크처럼 분포된 상태. • 개별 균열이 서로 연결되어 독립된 선형 균열로 분리하기 어려운 경우 적용. • 균열의 크기가 일정하지 않고, 비교적 넓은 영역을 차지하는 특징이 있음. 	

	Crack Longitudinal (세로 균열)	<ul style="list-style-type: none"> • 주로 도로 주행 방향(세로)과 평행하게 이어지는 선형 균열. • 길이가 폭보다 매우 길며, 한 방향으로 연속적인 패턴을 형성함. 	
	Crack Transverse (가로 균열)	<ul style="list-style-type: none"> • 도로 주행 방향과 수직으로 발생하는 균열. • 차로 폭을 가로지르는 선명한 단절 형태로 나타나는 경우가 많음. 	
	human (사람)	<ul style="list-style-type: none"> • 도로 위/차도 옆에 보이는 사람 보행자. • 얼굴이 보이지 않더라도 신체 일부만 인지 가능하면 라벨링 진행. • 안전조끼, 작업복 착용 여부와 무관하며, 사람의 실루엣 기준으로 라벨. 	
	manhole (맨홀)	<ul style="list-style-type: none"> • 원형 또는 사각형의 맨홀 덮개로, 도로면에 고정된 구조물 전체를 포함하여 라벨링. 	
	pothole (포트홀)	<ul style="list-style-type: none"> • 도로 표면의 움푹 파여 윤곽이 명확하게 드러나는 손상. • 내부에 물이 고여있어도 깊이 차이가 확인되는 경우 포트홀로 판단. • 경계가 불명확하거나 단순 표면 탈색만 있는 경우는 제외하고 라벨링 진행. 	
	sewer (하수구)	<ul style="list-style-type: none"> • 도로 가장자리 또는 측면에 설치된 배수 구조물로, 격자판·배수구 형태 포함. • 덮개 일부가 가려져 있더라도 식별되면 라벨링. 덮개가 덮여있는 경우 50% 이상 식별 가능할 때만 라벨링 진행. 	
	vehicle (차량)	<ul style="list-style-type: none"> • 도로 위 이동 또는 정차한 차량 전체. • 자동차, 버스, 트럭, 화물차, 오토바이 모두 포함 • 차량 일부만 보이더라도 인지가 가능할 경우를 모두 포함하여 라벨링. 	

2.2 차량 탐지 및 차종 분류 모델 학습 (YOLOv8n)

차량 탐지 및 분류를 위해 YOLOv8n 경량 모델을 MIO-TCD 데이터셋 [6] 기반으로 학습했다. 이 데이터셋은 차량 탐지 및 분류를 위해 공개된 대규모 위치추적 데이터셋이다.

- 모델 : YOLOv8n (경량 모델)
- 데이터셋 : MIO-TCD


- 분류 차종 : 11개 클래스 (articulated_truck, bicycle, bus, car, motorcycle, non-motorized_vehicle, pedestrian, pickup_truck, single-unit_truck, work_van, background)
- 학습 설정: epochs 300회, batch size 32.

학습 결과, mAP@0.5 기준 82.2%의 성능을 달성했으며, 실시간 처리 성능 확보를 위해 FP16 inference, Batch 모드 처리, ROI 제한 등의 모델 최적화 기법을 적용했다. [그림 1]은 차량 탐지 및 차종 분류 모델에 대한 학습 샘플 결과를 나타낸다. [그림 2]는 YOLOv8n 모델의 학습 결과로 도출된 성능 지표(Precision-Recall Curve 등)를 보여준다.



[그림 1] 차량 탐지 및 차종 분류 모델에 대한 학습 샘플 결과

[Fig. 1] Training Sample Results for the Vehicle Detection and Classification Model



[그림 2] YOLOv8n 학습 결과 성능 지표 (Precision-Recall Curve)

[Fig. 2] Performance Metric (Precision-Recall Curve) of the YOLOv8n Training Results

2.3 포트홀 탐지 YOLO 모델 버전별 성능 비교

RDD2022 데이터셋(일본 데이터) [7]을 활용하여 포트홀 객체 탐지에 대한 YOLOv5n, v5s, v8n, v10n 모델들의 성능을 비교했다.

- 데이터셋 : RDD2022 일본 데이터 (train 8,914개, valid 1,754개, test 1,762개).
- 학습 설정 : 103 epochs, 20 patience, batch 16 size.
- 성능평가 결과는 [표 2]에 제시되었다.

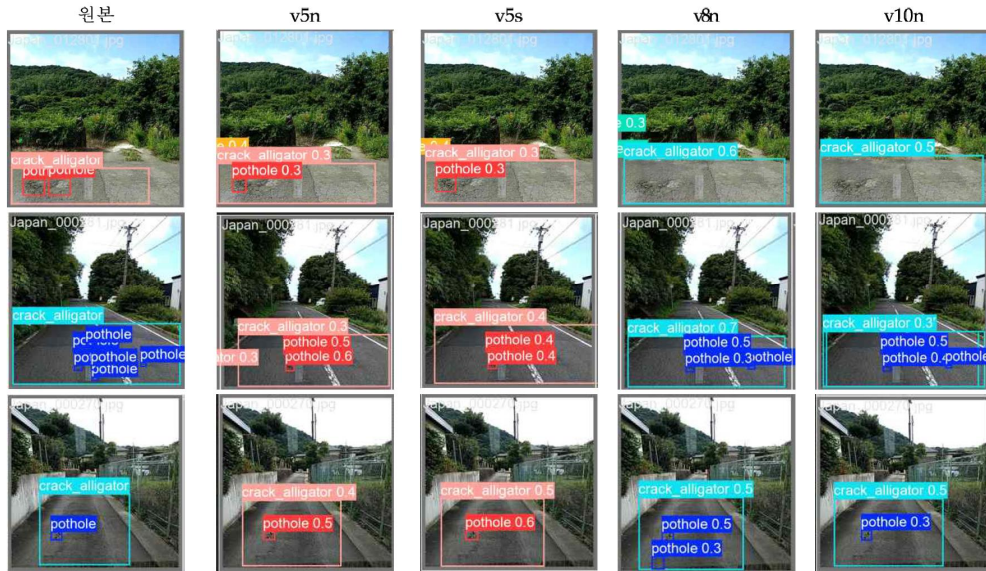
[표 2] YOLO 모델 버전별 포트홀 탐지 성능 비교

[Table 2] Comparison of Pothole Detection Performance by YOLO Model Versions

YOLO	Precision	Recall	mAP@0.5	mAP@0.95
v5n	0.305	0.518	0.271	0.118
v5s	0.307	0.506	0.260	0.110
v8n	0.281	0.414	0.235	0.103
v10n	0.301	0.378	0.244	0.111

비교 결과, YOLOv5n이 균열 및 그림자에 대한 민감도가 낮아 박스 배치가 안정적이며, 다른 모델들(v8n, v10n)에서 관찰되는 얇은 선형 크랙 및 포트홀 경계 혼동 현상이 적었다. [그림 3]은 각

YOLO 모델의 실제 탐지 결과를 시각적으로 비교한 예시를 보여준다. 따라서 포트홀 탐지에 있어서 YOLOv5n이 가장 안정적이며 빠른 추론 속도로 실시간 탐지를 수행할 수 있는 모델로 도출되었다 [4].



[그림 3] YOLO 모델별 포트홀 탐지 결과 비교
 [Fig. 3] Comparison of Pothole Detection Results by YOLO Model Versions

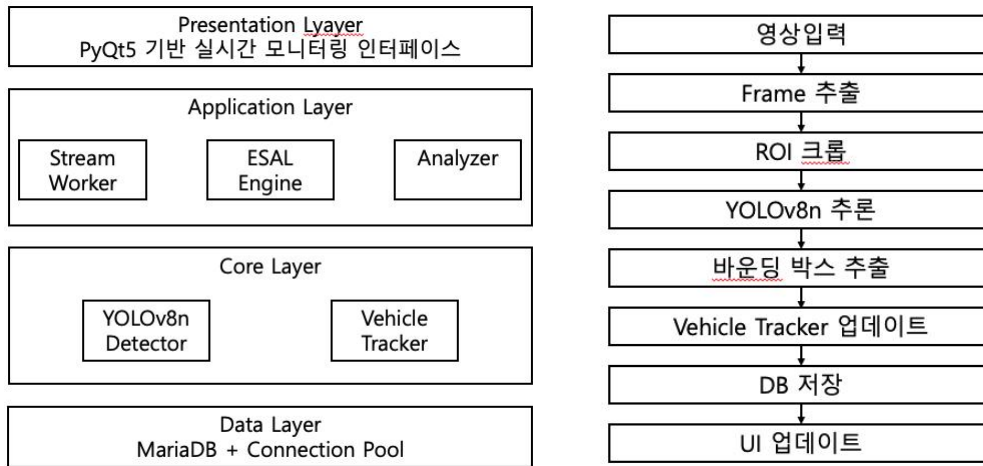
3. 구현 시스템 및 활용 방안

3.1 실시간 차량 탐지 시스템 아키텍처

실시간 차량 탐지 시스템은 YOLOv8n Detector와 Euclidean Distance 기반 Vehicle Tracker를 핵심으로 하는 모듈식 아키텍처로 구현되었다. [그림 4]는 실시간 차량 탐지 처리 플로우 차트와 실시간 차량 탐지 아키텍처를 나타낸다.

- 처리 플로우 : 영상입력 → Frame 추출 → ROI 크롭 → YOLOv8n 추론 → 바운딩 박스 추출 → Vehicle Tracker 업데이트 → DB 저장 및 UI 업데이트.
- ESAL 엔진 : 차량 종류별 ESAL 계수(Car 0.0002, Bus 0.8, Truck 1.5 등)를 적용하여 누적 ESAL을 산출하며, 이를 기반으로 도로 상태를 5단계(양호-예방보수-표면보수-중간보수-전면보수)로 분류하는 평가 기준을 수립했다 [5].
- 데이터 저장 : MariaDB 기반으로 탐지 시간, 이미지 경로, 클래스명, 정확도, bbox 정보 등을

포함하는 탐지 결과를 일 평균 약 500만 건 저장 가능한 구조로 설계했다.



실시간 차량 탐지 아키텍처

실시간 차량 탐지 처리 플로우 차트

[그림 4] 실시간 차량 탐지 아키텍처 및 처리 플로우 차트

[Fig. 4] Architecture and Processing Flow Chart for Real-time Vehicle Detection

3.2 기대효과 및 활용

본 연구를 통해 학습된 YOLO 모델은 다음과 같은 다양한 활용 가치를 지닌다. 첫째, 축적된 시간대별 및 차종별 교통량 데이터를 기반으로 교통 수요를 예측하고, 도로포장의 구조 설계 등을 지원 할 수 있다. 둘째, 실시간 교통량 분석을 통해 교통 혼잡을 완화하고, 사고나 돌발 상황 발생 시 신속하게 감지하여 대응 시간을 단축시킬 수 있다. 셋째, 트럭과 같은 대형 차량의 통행 빈도를 파악하여 도로의 피로도를 예측하고, 예방적 유지보수 계획을 수립함으로써 도로의 수명을 연장하고 관리 비용을 절감할 수 있다.

4. 결론

본 연구에서는 도로 시설물의 생애주기비용 관리를 위한 지능형 데이터 수집 시스템을 제안하였다. YOLOv8n 기반의 차량 탐지 모델은 MIO-TCD 데이터셋에서 mAP@0.5 기준 82.2%의 정확도를 달성하여 실제 교통 환경에서의 적용 가능성을 입증하였다. 또한 포트홀 탐지에 대하여 일부 YOLO 모델 버전별 비교를 통해 YOLOv5n이 가장 안정적인 성능을 보임을 확인하였다. 이는 기존의 수동적이고 단편적인 교통 데이터 수집방식을 능동적인 방식으로 전환할 수 있는 토대를 마련

했다는 점에서 의미가 크다.

그러나 본 연구는 제한된 데이터셋을 활용하여 학습을 수행하여 다양한 기상 환경 및 조도 변화에 대한 모델의 강건성 검증에는 다소 미흡하다. 또한, 차량 탐지에 비해 상대적으로 낮은 크랙 탐지 정확도를 향상시키기 위한 모델 경량화 및 최적화 연구가 추가적으로 요구된다.

향후 연구에서는 다양한 도로 환경 및 기상 조건에서의 주행 데이터를 확보하여 모델의 범용성을 강화하고, 수집된 객체 정보를 기반으로 ESAL 자동 산출 및 도로 피로도 예측 알고리즘을 도식화하여 실제 도로 관리 시스템과 연동할 수 있도록 할 예정이다.

References

- [1] Y. S. Bae, S. Lee, W. T. Kwon, J. M. Jeon, "A Study on the Database for Analyzing Life Cycle Cost of Road Facilities in Seoul", *Journal of the Korean Society of Hazard Mitigation*, vol. 14, no. 3, January 2014, pp. 99-105, doi: 10.9798/KOSHAM.2014.14.3.99.
- [2] Y. J. Jeong, S. Y. Park, H. R. Cho, J. H. Yeon, "Impact Assessment and Development Strategy of the Seoul C-ITS Pilot Project", The Seoul Institute, Seoul, Republic of Korea, 2024-PR-75, September 2025, [Online]. Available: <https://www.si.re.kr/bbs/view.do?key=2024100039&pstSn=2510270002>.
- [3] M. Yaseen, "What is YOLOv8: An In-Depth Exploration of the Internal Features of the Next-Generation Object Detector", arXiv:2408.15857v1, August 2024, doi: 10.48550/arXiv.2408.15857.
- [4] C. K. Woo, I. S. Kim, J. M. Choi, Y. H. Kim, "Implementation of YOLOv8-based Road Damage Area Detection Algorithm", *Proceedings of the 2023 Korean Digital Contents Society Fall Conference*, Suwon, Korea, November 9-10, 2023, pp. 11-12.
- [5] C. G. Lim, J. M. Choi, "CCTV Image-Based Vehicle Detection Using YOLO for Road Life Cycle Cost Design", *Proceedings of the 2025 Korean Digital Contents Society Fall Conference*, Suwon, Korea, November 6-7, 2025, pp. 136-138.
- [6] Z. Luo, et al., "MIO-TCD: A New Benchmark Dataset for Vehicle Classification and Localization", *IEEE Transactions on Image Processing*, vol. 27, no. 10, June 2018, pp. 5129-5141, doi: 10.1109/TIP.2018.2848705.
- [7] Deeksha Arya, et al., "RDD2022: A multi-national image dataset for automatic Road Damage Detection", arXiv:2209.08538v1, September 2022, doi: 10.48550/arXiv.2209.08538.