

# YOLOv11 기반 교통안전표지 검출 모델의 성능 비교

(Performance Comparison of YOLOv11-Based Traffic Signs Detection Models)

류지성\*, 송인국\*\*

(Ji Sung Ryu, In Kuk Song)

## 요약

최근 국내외 교통 인프라는 지능형 기술의 도입과 인공지능 기반 교통 시스템의 발전에 따라 지능형 교통 인프라 구축이 증대되고 있다. 특히 객체 검출 기술은 지능형 교통 시스템의 핵심 요소로 시스템의 안전성과 효율성 향상을 추구하고 있다. 본 연구에서는 교통안전표지 및 관련 시설물의 효율적 관리와 지능형 교통 시스템 적용 가능성을 검증하기 위하여 YOLOv11을 제안하고, 현재 모델인 YOLOv10과 성능을 비교·분석하였다. 보호구역 통합표지 기준에 따라 49종의 교통안전표지를 검출 대상으로 설정하고 다양한 이미지 데이터를 수집하여 총 41,270장의 데이터셋을 구축하고 모델의 검출 성능을 최적화하였다. 연구결과, 정확도 측면에서 소폭 향상된 성능을 보였으며, 추론 속도가 약 25% 개선되었다. 또한, 메모리 사용량은 약 14% 감소하고 연산량(FLOPs)은 약 28% 감소한 것으로 확인되었다. 따라서, YOLOv11 모델이 객체 검출 성능과 신뢰성 측면에서 더 우수한 성능을 보였으며, 이전 모델과 비교하여 정밀도와 재현율이 동시에 개선된 것으로 평가된다.

■ 중심어 : 객체 검출 ; 교통안전표지 검출 ; YOLO ; 지능형 교통 시스템

## Abstract

Recently, with the introduction of intelligent technology and the development of artificial intelligence-based transportation systems, the establishment of intelligent transportation infrastructure is increasing in domestic and abroad. Specifically, object detection technology is a key element of an intelligent transportation system and seeks to improve the safety and efficiency of the system. This study compared and analyzed the performance of the latest object detection models YOLOv10 and YOLOv11 to verify the efficient management of traffic safety facilities and the applicability of the intelligent transportation system. According to the protection zone integrated sign standard, 49 types of traffic safety signs were set as detection targets and various image data were collected to construct a total of 41,270 datasets. In addition, the quality of the dataset was improved and the model's detection performance was optimized through stepwise data expansion and repetitive learning. As a result of the experiment, it was found that the YOLOv11 model showed better performance in terms of object detection performance and reliability, and the precision and reproducibility were improved at the same time compared to the previous model.

■ keywords : Object detectio ; Traffic Signs Detection ; YOLO(You Only Look Once) ; Intelligent Transport System

## I. 서론

최근 국내외 교통 인프라는 자율주행 기술과 인공지능 기반 도로교통 시스템 등 지능형 기술의 도입으로 빠르게 발전하고 있다. 특히 혼잡한 교통 상황과 교통사고 문제를 해결하기 위한 대안으로 교통체계와 ICT 기술이 융합된 지능형

교통 시스템(Intelligent Transport System, ITS)이 주목받으면서 미래 도시 생태계를 구성하는 핵심 요소 중 하나로 자리 잡고 있다[1].

도로교통 환경에서는 차량, 통행, 주변 환경 등 다양한 요소의 상호작용으로 인해 대규모 데이터가 지속적으로 생성되고 있으며, 이러한 데이

\* 정회원, 단국대학교 일반대학원 경영학과

\*\* 정회원, 단국대학교 경영학과 경영정보전공 교수

접수일자 : 2026년 04월 10일

수정일자 : 2026년 04월 22일

게재확정일 : 2026년 04월 29일

교신저자 : 송인국 e-mail : iksong@dankook.ac.kr

터를 체계적으로 수집·분석·활용할 경우 교통안전 확보를 위한 위험 요소의 사전 예측·대응이 가능하다. 특히 교통 데이터 활용 체계는 다양한 데이터를 수집·저장·관리·분석할 수 있는 중앙화된 플랫폼 기반으로 운영되며, 안전한 교통 환경 조성을 위한 핵심 인프라로 인식되고 있다. 이러한 데이터 활용 체계는 데이터의 통합성과 일관된 접근성을 보장하여 분석 수행의 정합성과 정책적 의사결정의 신뢰성을 높이며, 스마트 시티와 같은 미래형 교통 시스템에서 도로·교통을 넘어 환경, 에너지, 경제적 효율성까지 종합적으로 고려할 수 있는 기반을 제공한다[2].

한편 교차로 및 주요 도로, 공공시설 인근에 다수 설치된 CCTV는 교통 상황 분석, 혼잡도 파악, 사고 감지 등 다양한 목적으로 활용되고 있으며, 국가 및 지자체 단위에서도 이러한 영상 정보를 기반으로 교통 데이터를 체계적으로 확보·활용하고 관련 인프라를 지속적으로 확대해 왔다. 이러한 환경에서 이미지 데이터 또는 CCTV 영상과 같은 시각 데이터를 실시간 객체 검출 기술과 연계할 경우, 교통량, 차량 흐름, 보행자 이동 등 다양한 교통정보를 정밀하고 자동화된 방식으로 수집·분석할 수 있다[3].

이처럼 지능형 교통 인프라의 고도화, ITS의 역할 확대, 데이터 중심의 교통관리 체계, 통합형 교통 데이터 플랫폼 등 지능형 교통 시스템 구축을 위해 다양한 4차 산업 기술이 활용되고 있다. 특히 실시간 영상 데이터 기반의 객체 검출 기술은 교통 상황을 정밀하게 인식·분석할 수 있는 핵심 기술로서 그 중요성이 점차 증대되고 있다. 또한, 도로의 차량, 보행자, 차량번호, 도로표지 등 다양한 객체를 실시간으로 검출하여 교통정보를 생성하고 이를 기반으로 교통 흐름 분석과 사고 대응 그리고 도로 설계·운영·유지관리 등 교통 상황 전반에 걸친 의사결정을 체계적으로 지원하는 핵심 기능을 수행한다. 따라서, 객체 검출 기술은 지능형 교통 시스템의 안전성과 효율성을 향상시키는 데 있어서 매우 중요한 역할

을 하고 있다[4].

본 연구에서는 교통안전표지 및 관련 시설물을 체계적으로 관리하고 이를 교통안전 시설 정보 시스템과 연계하여 지능형 교통 시스템을 지원하기 위해 딥러닝 기반 최신 객체 검출 모델인 YOLOv10과 YOLOv11의 성능을 비교·평가하였다. 또한, 보호구역 교통안전표지 검출에 특화된 학습 모델을 구축하여 보호구역 통합관리시스템에 활용 가능한 실질적인 학습 모델을 검증하였다는 점에서 기존 연구와 차별화된 특성을 갖는다.

본 연구에서는 보호구역 통합표지 및 표준안을 기준으로 객체 검출 범위를 설정하고 데이터 수집이 용이한 49종의 교통안전표지를 검출 대상으로 선정하였다. 또한, 부족한 이미지 데이터를 보완하기 위해 로드뷰 이미지와 AI 허브, 도시교통정보센터 등에서 제공하는 데이터를 수집·가공하여, 총 41,270장의 이미지 데이터셋을 구축하였고 이를 기반으로 연구를 수행하였다.

실험 결과, YOLOv11 객체 검출 모델은 YOLOv10 모델 대비 검출 정확도와 연산 효율성이 향상되었음을 확인하였다[5]. 특히 YOLOv11 모델은 C3k2 블록과 SPPF 등 최신 네트워크 구조를 적용하여 정교한 특징 표현과 빠른 처리 속도를 동시에 달성하도록 설계되었다[6]. 이를 통해 교통안전표지 및 관련 시설물을 실시간 효과적으로 검출할 수 있음을 확인하였고 이러한 YOLOv11 모델의 특성이 지능형 교통 시스템에 사용 가능한 높은 활용 가능성을 지니고 있음을 실증적으로 검증하였다.

본 연구는 단순한 객체 검출 모델 간 성능 비교를 넘어 실제 도로 환경을 반영한 데이터 기반 학습을 통해 연구의 실용성과 신뢰성을 높이고자 하였다. 이러한 접근은 향후 지능형 교통 시스템의 모니터링, 실시간 위험 감지, 시설물 관리 및 유지보수 등 다양한 영역에서의 활용 및 확장 가능성을 제시하며, 어린이·노인·장애인 등 교통약자 보호구역과 같이 보행자 안전이 중요한 환경에서 빈번히 활용될 것으로 기대된다.

## II. 관련 연구

### 1. 교통안전표지

도로교통법에서 안전표지는 “교통안전에 필요한 주의·규제·지시 등을 표시하는 표지판이나 도로의 바닥에 표시하는 기호·문자 또는 선 등”으로 정의된다. 교통안전표지는 노면 표시, 신호기 등 다양한 교통 안전시설물과 연계하여 설치되며, 교통사고 예방을 위해 규제, 지시 및 주의 의무 등의 정보를 도로 이용자에게 통일된 방식으로 전달하는 기능을 수행한다. 또한, 도로 상황, 노면 상태 및 통행 방법에 관한 정보를 제공함으로써 원활하고 안전한 교통 흐름을 유도하는 것을 목적으로 한다[7]. 표 1은 안전표지의 종류와 기능에 대하여 설명한다.

표 1. 안전표지의 종류와 기능

안전표지		
구분	종류	설명
본 표지	주의 표지	도로상태가 위험하거나 도로 또는 그 부근에 위험물이 있는 경우에 필요한 안전조치를 할 수 있도록 이를 도로 사용자에게 알리는 표지
	규제 표지	도로교통의 안전을 위하여 각종 제한·금지 등의 규제를 하는 경우에 이를 도로 사용자에게 알리는 표지
	지시 표지	도로의 통행방법·통행구분 등 도로교통의 안전을 위하여 필요한 지시를 하는 경우에 도로 사용자에게 따르도록 알리는 표지
보조 표지	보조 표지	주의표지·규제표지 또는 지시표지의 주기능을 보충하여 도로 사용자에게 알리는 표지
	노면 표지	도로교통의 안전을 위하여 각종 주의·규제·지시 등의 내용을 노면에 기호·문자 또는 선으로 도로 사용자에게 알리는 표지

경찰청 「교통안전표지 설치·관리 업무 편람」에 따르면, 교통안전표지는 본표지와 보조표지로 구분된다. 본표지는 단독으로 주의, 규제, 지시 등의 의미를 전달하는 기능을 가지며, 보조표지는 본표지와 함께 설치되어 그 내용을 부연하거나 보완하는 역할을 한다.

### 2. YOLO 모델

1단계 검출 방식의 대표적인 모델인 YOLO(You Only Look Once)는 객체 검출을 단일 회귀 문제(Single Regression Problem)로 재구성해 빠른 속도로

객체를 찾아낼 수 있는 실시간 성능을 달성한 획기적인 기술이며, 단일 인공 신경망 구조를 기반으로 이미 지 전체를 한 번에 처리하여 실시간 다수의 객체를 동시에 검출할 수 있는 특징을 갖는다. 특히 YOLO 모델은 높은 평균 정밀도를 유지하면서도 엔드 투 엔드(end-to-end) 학습과 실시간 처리가 가능한 객체 검출 모델이다. 그림 1은 Joseph Redmon이 설명한 YOLO의 동작 원리를 나타낸다.

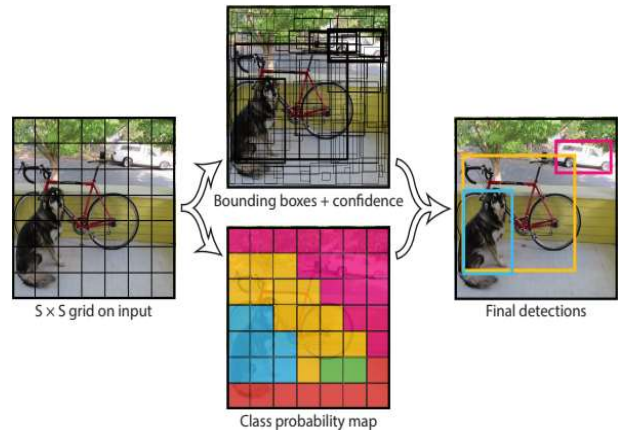


그림 1. Joseph Redmon이 설명한 YOLO의 동작 원리

YOLO의 동작 원리는 입력 이미지를 S×S 그리드로 분할하고 각 그리드 셀이 B개의 바운딩 박스와 해당 박스의 신뢰도 점수를 예측하는 방식으로 이루어진다. 이후 신뢰도 점수와 클래스 확률을 결합하여 각 바운딩 박스가 특정 클래스에 속할 확률을 산출하고 이를 기반으로 객체를 검출한다. 이러한 일련의 과정이 단일 단계에서 동시에 수행되므로 높은 처리 속도를 확보할 수 있다[8].

YOLOv10은 2024년 5월 공개된 객체 검출 모델로 NMS(Non-Maximum Suppression) 과정을 제거한 엔드 투 엔드 구조를 적용하여 추론 과정을 단순화하고 지연 시간을 최소화하였다. 또한, 효율적인 네트워크 설계를 기반으로 실시간 환경에서 빠르고 안정적인 성능을 제공하도록 설계되었다[9].

YOLOv11은 2024년 9월 공개된 객체 검출 모델로 기존 YOLOv8의 Backbone - Neck - Head 구조를 유지하면서 C3k2, SPPF, C2PSA 등 새로운 블록을 도입하여 고도화된 특징 추출 기능을 통합하였다. 파라미

터 최적화를 통해 적은 연산량으로 높은 정확도를 달성할 수 있도록 설계되었으며, 이전 버전에 비해 검출 정확도와 연산 효율성이 모두 향상된 특징을 보인다. 이러한 특징으로 인해 객체 검출, 인스턴스 분할, 포즈 추정 등 다양한 작업에서 우수한 성능을 나타내고 있으며, 자율 주행, 스마트 시티, 스마트 팩토리, 로봇, 의료 등 다양한 산업 분야에 적용 가능한 범용적 모델로 활용되고 있다[10]. 특히 개선된 네트워크 구조와 학습 전략을 통해 검출 정확도와 연산 효율성을 동시에 향상시킨 모델이며, 객체 검출, 분류, 세그멘테이션 등 다양한 작업을 통합적으로 지원할 수 있어서 실시간 환경에서의 활용성과 확장성을 강화하였다. 또한, 최신 네트워크 구조를 적용하여 정교한 특징 표현과 빠른 처리 속도를 동시에 달성하도록 설계되었다[11]. YOLOv10과 YOLOv11 모델의 주요 차이점은 표 2와 같다.

표 2. YOLOv10과 YOLOv11 모델의 주요 차이점

구분	YOLOv10	YOLOv11
기본 구조	NMS 제거 기반 end-to-end 구조	개선된 Backbone - Neck - Head 구조 기반 통합 아키텍처
추론 프로세스	NMS 없이 직접 예측 (후공정 최소화)	최적화된 추론 구조로 속도·정확도 균형 강화
학습 전략	end-to-end 학습 + NMS-free training	성능 향상을 위한 학습 전략 최적화
정확도 및 속도	매우 빠른 속도, 준수한 정확	높은 정확도와 빠른 속도의 균형
파라미터	적은 연산으로	적은 파라미터 대비
효율성	실시간 성능 최적화	성능 향상
범용성	검출 특화	다양한 비전 작업 지원

### III. 실험 설계 및 데이터셋 구축

#### 1. 실험 환경

##### 가. 교통안전표지 검출 대상

본 연구에서는 보호구역 통합표지 및 표준안을 기준으로 연구 대상의 객체 검출 범위를 설정하고 데이터 수집이 용이한 49종의 교통안전표지를 최종 선정하여

모델 학습 작업을 수행하였다. 그림 2는 교통안전표지 검출 대상 49종을 나타낸다.

구분	세부시열명	이미지	구분	세부시열명	이미지	구분	세부시열명	이미지	구분	세부시열명	이미지
8	어린이보호구역시정		9	어린이보호구역내		18	장애인보호구역내		27	최고속도제한	
1	어린이보호구역시정 (대형)		10	어린이보호구역내		19	장애인보호구역내		28	서행	
2	노인보호구역시정		11	노인보호구역내		20	장애인보호구역내		29	정차·주차 금지	
3	노인보호구역시정 (대형)		12	노인시정 (속도별)		21	어린이보호구역제		30	노인보호 (노인보호구역안)	
4	장애인보호구역시정		13	노인보호구역내		22	노인보호구역제		31	어린이보호 (어린이보호구역안)	
5	장애인보호구역시정 (대형)		14	노인보호구역내		23	장애인보호구역제		32	장애인보호 (장애인보호구역안)	
6	어린이보호구역시정		15	노인보호구역내		24	보호구역제 (속도)		33	속도제한 (어린이보호구역)	
7	어린이시정 (속도별)		16	장애인보호구역시정		25	어린이보호		34	서행	
8	어린이보호구역내		17	장애인시정 (속도별)		26	전망금지		35	통단표도	
36	대각선통단표도		43	중형 (가로)		40	장애인보호구역		47	보호용하리 (보호)	
37	고형색통단표도		44	중형 (세로)		41	가림 (가로)		48	통행표지대 (보호)	
38	어린이보호구역		45	속도위반단속장비		42	가림 (세로)				
39	노인보호구역		46	신호기 정상유동							

그림 2. 교통안전표지 검출 대상 49종

#### 나. 이미지 데이터 수집

학습에 사용되는 이미지 데이터의 정확성은 분석 결과의 신뢰성과 직결되므로 식별 가능한 고품질 데이터 확보가 매우 중요하다. 그러나 많은 연구자들이 활용 가능한 데이터를 확보하는 것에 어려움을 겪고 있다. 이에 본 연구에서는 비교적 수집이 용이한 포털사이트의 지도 서비스에서 제공하는 로드뷰 이미지를 활용하여 데이터를 수집하였다. 해당 데이터는 전체 데이터셋의 약 90% 이상을 차지하는 기초 이미지 데이터로 활용되었고 AI 허브 (AI-Hub) 및 경찰청 도시교통정보센터(UTIC)에서 제공하는 공공데이터를 추가로 수집하여 부족한 이미지 데이터를 보완하였다.

#### 다. 분석 서버

본 연구의 데이터 분석 및 실험은 Linux Ubuntu 22.04 운영체제 기반의 서버에서 수행되었다. 분석 서

버의 주요 기술 사양은 표 3과 같다.

표 3. 분석 서버의 주요 기술 사양

No.	구분	기술 사양
1	OS	Linux Ubuntu 22.04
2	GPU / Driver Version	Nvidia RTX A5000 24GB / NVIDIA-SMI 560.35.03
3	CPU	AMD EPYC 7352
4	RAM	512GB
5	CUDA	Version 12.4
6	cuDNN	8.9.7

## 2. 데이터셋 구축

### 가. 학습 데이터셋 구축

본 연구에서는 학습 데이터셋의 체계적 구축과 검출 성능 향상을 위해 총 4단계의 반복적 데이터 구축 과정과 추가 학습을 수행하였다. 1차 단계에서는 49개 클래스를 대상으로 각 30장의 이미지로 초기 학습을 수행하였고 성능 분석을 통해 검출률이 낮은 32개 클래스를 선별하였다. 이후 2차 및 3차 단계에서는 각각 150장, 500장의 이미지를 추가 확보하여 재학습을 수행하였으며, 단계별 평가를 통해 26개 및 22개의 검출 성능 향상이 필요한 클래스를 대상으로 추가 학습을 진행하였다. 마지막 단계에서는 추가 학습이 필요한 22개 클래스를 대상으로 1,000장의 이미지를 추가하여 모델을 학습시켰다. 따라서, 총 41,270장의 데이터셋을 활용하여 연구를 진행하였다. 표4는 데이터셋의 규모를 나타낸다.

표 4. 데이터셋의 규모

단계	이미지 데이터 및 클래스	합계
1차	30장의 이미지 데이터 x 총 49 클래스	1,470
2차	150장의 이미지 데이터 x 총 32 클래스	4,800
3차	500장의 이미지 데이터 x 총 26 클래스	13,000
4차	1,000장의 이미지 데이터 x 총 22 클래스	22,000
	전체	41,270

### 나. 하이퍼파라미터 설정

학습 과정에서 하이퍼파라미터(Hyperparameter) 조정과 추가적인 전처리 기법 테스트를 병행하여 특정 객체의 검출 성능을 향상시키기 위한 보정 작업을 수행하였다. 특히 객체 검출의 정확도 향상을 위한 신뢰도 임계값(Confidence Threshold)의 최적화를 수행하

였고 여러 차례 반복적인 테스트를 진행하였다. 그 결과, 기준값 0.6(60%)이 최적의 설정값임을 확인하였으며, 최적의 기준값을 적용한 후 대부분의 객체 클래스에 대해 전반적으로 안정적이고 일관된 객체 검출 성능이 확보된 것으로 나타났다. 또한, 추가적인 검증 실험을 통해 현재 데이터셋의 클래스 분포 비율과 임계값(Threshold) 설정이 성능 최적화를 달성하는 데 있어 가장 적합한 조합임을 실증적으로 확인하였다. 표5는 하이퍼파라미터 설정값을 나타낸다.

표 5. 하이퍼파라미터

Parameter	Value
Learning Rate	0.001
Batch Size	64
Epoch	100

## IV. 실험 결과

### 1. 성능 평가 지표

본 연구에서는 객체 검출 모델의 성능을 평가하고 검증하기 위한 주요 지표로 mAP(mean Average Precision), 정밀도(Precision), 재현율(Recall), F1-score를 활용하였다. 이러한 지표들은 모델이 객체를 얼마나 정확하게 검출하고 구분하는지를 정량적으로 평가하는 데 필수적인 요소이며, 각 지표는 모델 성능을 다양한 관점에서 종합적으로 분석하는 데 중요한 역할을 한다[12].

AP(Average Precision)와 mAP(mean Average Precision)는 정밀도(Precision)와 재현율(Recall)의 관계를 기반으로 산출되는 성능 지표이며, 객체 검출 모델의 정확성과 일관성을 정량적으로 평가하는 데 활용된다. AP는 단일 클래스에 대한 성능을 나타내는 지표인 반면 mAP는 여러 클래스에 대한 AP의 평균값으로 모델의 전반적인 성능을 평가하는 데 적합하다. 일반적으로 mAP 값이 높을수록 모델의 검출 정확도가 우수함을 의미한다[13]. mAP50과 mAP50-95는 객체 검출 모델의 성능을 더욱 정밀하게 평가하기 위한 지표이다. mAP50은 IoU(Intersection over Union) 기준값을 0.5로 고정하여 산출한 클래스별 AP의 평균값을 의미하며, 비교적 완화된 기준에서

객체를 얼마나 잘 검출하는지를 평가하고 전반적인 검출 여부를 판단하는 데 유용한 지표이다. 또한, mAP50-95는 IoU 기준값을 0.5부터 0.95까지 0.05 간격으로 변화시키며 각 구간에서 계산된 AP를 평균한 값이며, 다양한 IoU 기준을 반영하여 객체 위치의 정밀도까지 함께 평가하므로 모델의 엄격하고 종합적인 성능을 확인하는 데 유용한 지표이다.

F1-score는 정밀도와 재현율을 동시에 고려하여 모델의 전체적인 균형을 평가하는 지표이다. 두 값의 조화평균을 계산해 0과 1 사이의 단일 수치로 나타내며, 예측에 대한 정밀도와 재현율을 한 번에 보는 종합적인 분류 성능 지표이다.

### 2. 실험 결과 및 분석

YOLOv10과 YOLOv11의 객관적인 성능 비교를 위해 동일하게 구축된 데이터셋을 기반으로 비교 실험이 진행되었다. 각 모델은 모두 동일한 환경과 조건에서 학습되었으며, 성능 평가는 총 41,270장의 검증 데이터셋을 활용하여 정량적으로 수행되었다. 그림3은 성능 비교 테스트 과정을 나타낸다.

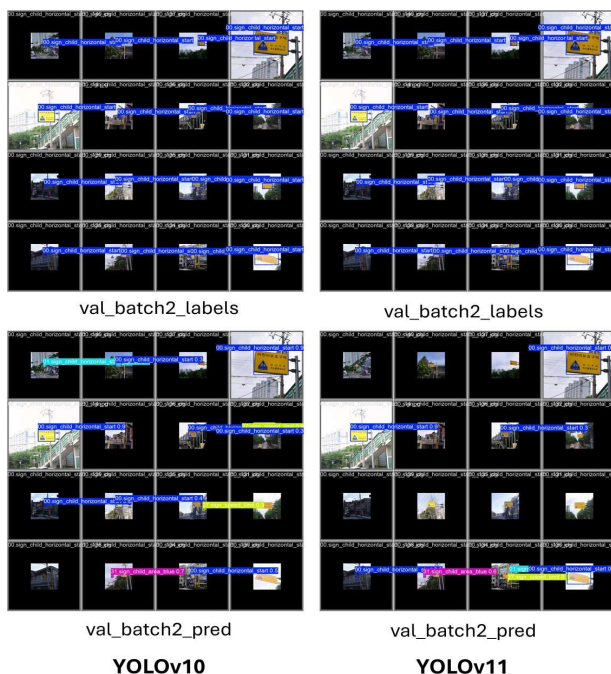


그림 3. 성능 비교 테스트 과정

YOLOv10과 YOLOv11 모델의 객체 검출 성능을

정량적으로 측정하고 비교·분석하기 위하여 총 4단계로 나누어 반복 실험을 수행하였고 최고의 성능을 나타낸 마지막 4단계의 성능을 측정한 결과, 두 모델 모두 우수한 객체 검출 성능을 나타냈다. 성능 평가 결과는 표6과 같다.

표 6. Performance Metrics

Model Ver.	YOLOv10 (Large)	YOLOv11 (Large)
mAP50	0.857	0.858
mAP50-95	0.727	0.731
P-C Curve	0.99	1
R-C Curve	0.92	0.93
F1-Curve	0.80 at 0.36	0.79 at 0.40

그림 4와 같이 mAP 성능 평가 결과, YOLOv11 모델이 전반적으로 향상된 성능을 보이는 것으로 나타났다. 특히 YOLOv11은 mAP50: 0.858, mAP50-95: 0.731로 YOLOv10(mAP50: 0.857, mAP50-95: 0.727) 보다 미세하지만 일관된 성능 향상을 보이며, 이는 다양한 IoU 기준에서도 객체 위치 추정의 정밀도가 개선되었음을 나타낸다.

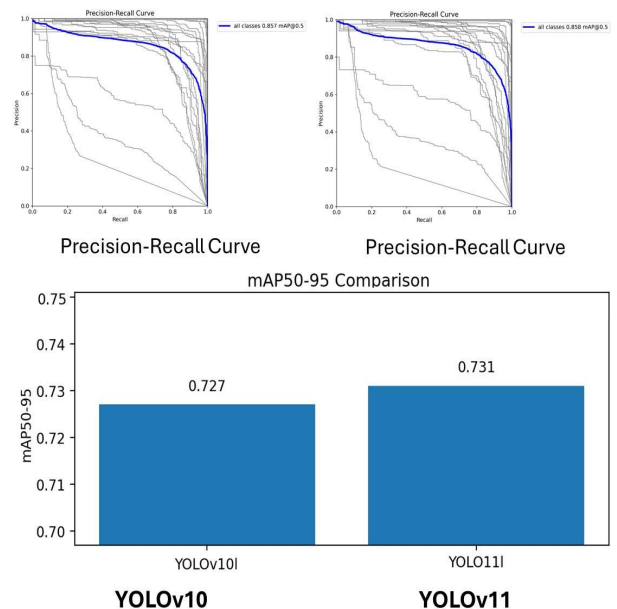


그림 4. mAP 성능 평가

그림 5와 같이 YOLOv11 모델은 Confidence Threshold 약 0.40에서 Precision-Confidence Curve 값 1.00과 Recall-Confidence Curve 값 0.93을 기록하

여, YOLOv10 모델(Precision-Confidence Curve 0.99, Recall-Confidence Curve 0.92) 대비 오검출을 효과적으로 억제하는 동시에 실제 객체를 보다 높은 비율로 검출하는 성능을 나타냈다. 이는 YOLOv11이 높은 정밀도를 유지하면서도 재현율을 동시에 개선한 모델임을 의미한다. 비록 F1-Confidence 값은 YOLOv10이 0.80(at 0.36), YOLOv11이 0.79(at 0.40)로 유사한 수준을 보였으나 이는 YOLOv11이 더 높은 Confidence Threshold 구간에서 최적의 성능 균형을 형성하면서 정밀도 중심의 보수적인 검출 특성을 유지하기 때문으로 해석할 수 있다. 또한, mAP50 및 mAP50-95의 향상을 종합적으로 고려할 때, YOLOv11은 전반적인 객체 검출 성능과 위치 추정의 정밀도 측면에서 YOLOv10 대비 개선된 모델로 평가된다.

의 균형 측면에서 YOLOv10 모델 대비 신뢰성이 향상된 객체 검출 결과를 제공하는 것으로 나타났다.

본 연구의 결과는 ‘Ultralytics’에서 제시한 YOLOv10과 YOLOv11의 성능 비교 결과와 유사한 경향을 보였다. Ultralytics에 따르면, YOLOv11은 YOLOv10 대비 정확도 측면에서 소폭 향상된 성능을 보였으며, GPU(T4) 환경에서 TensorRT 최적화 시 추론 속도가 약 25% 개선되었다. 또한, 메모리 사용량은 약 14% 감소하고 연산량(FLOPs)은 약 28% 감소한 것으로 보고되었다. 따라서, YOLOv11은 더 적은 연산량과 파라미터 수를 유지하면서도 추론 속도와 검출 정확도 측면에서 전반적인 성능 향상을 달성하여 효율성과 실용성을 동시에 개선한 모델로 평가된다[14]. 표 7은 640 픽셀 이미지를 기준으로 Ultralytics에서 측정한 YOLOv10과 YOLOv11의 성능 지표를 비교한 결과를 나타낸다.

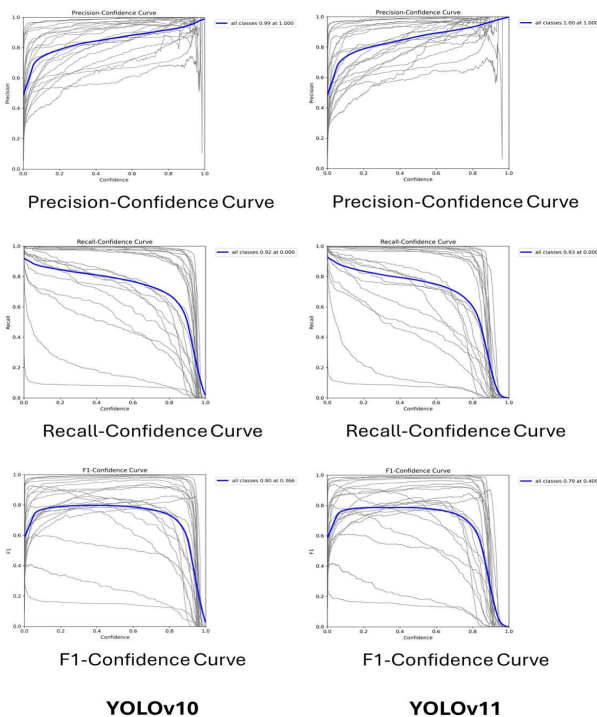


그림 5. 성능 평가 분석

실험 결과, 두 모델 모두 우수한 검출 성능을 나타냈지만 YOLOv11이 전반적인 검출 정확도와 안정성 측면에서 YOLOv10 모델 대비 더 우수한 성능을 나타냈다. 특히 YOLOv11 모델은 정밀도와 재현율

표 7. Performance and Metrics Comparison(V10 vs V11)

Model Ver.	YOLOv10 (Large)	YOLOv11 (Large)
mAP 50-95	53.3	53.4
Speed CPU ONNX (ms)	-	238.6
Speed T4 TensorRT10 (ms)	8.33	6.2
params (M)	29.5	25.3
FLOPs (B)	120.3	86.9

YOLOv11은 향상된 Backbone - Neck - Head 구조를 통해 복잡한 도로환경에서도 교통안전표지와 같은 소형 객체에 대한 정교한 특징 표현이 가능하며, 다양한 작업(검출, 분류, 분할, 추적 등)을 통합적으로 지원하는 구조를 갖추고 있어서 교통 상황 인식, 객체 추적, 위험 요소 분석 등 지능형 교통 시스템에 요구되는 복합적인 기능을 효과적으로 수행할 수 있다. 반면, YOLOv10은 실시간 처리 속도는 우수하지만, 상대적으로 특징 표현력과 확장성 측면에서 한계가 존재한다. 따라서, 높은 신뢰성과 다기능 처리가 요구되는 지능형 교통 시스템 응용 환경에서는 YOLOv11이 YOLOv10 대비 더 안정적이고 신뢰도 높은 검출 결과를 제공할 수 있으며, 교통안전표지 검출 및 지능형 교통 시스템의 활용성 측면

에서 YOLOv11 모델이 더 적합한 모델로 평가된다.

### 3. 활용 방안

YOLOv10과 YOLOv11은 각각 실시간 처리 성능과 정확도 및 확장성 측면에서 강점을 가지며, 이러한 특성을 바탕으로 다양한 객체 검출 응용 분야에 효과적으로 활용될 수 있다. 예를 들어 YOLOv10은 NMS를 제거한 엔드 투 엔드 구조를 통해 추론 지연을 최소화하여 자율주행, CCTV를 활용한 객체 검출 시스템, 영상 감시 등과 같이 실시간성이 중요한 환경에 적합하다. 반면, YOLOv11은 개선된 네트워크 구조를 바탕으로 정교한 특징 표현과 높은 검출 정확도를 제공할 뿐만 아니라, 검출, 분할, 분류, 추적 등 다양한 컴퓨터 비전 작업을 통합적으로 지원하여 지능형 교통시스템, 스마트 팩토리, 의료 영상 분석, 드론 및 로봇 비전 시스템 등 복합적인 작업이 요구되는 환경에 더 적합하다.

본 연구에서는 다음과 같은 이미지 데이터 기반의 교통안전표지 및 보호구역 시설물 관리 응용 시나리오를 제안한다. 첫째, 공공 데이터셋을 활용하여 모델을 학습하고 전처리 과정을 수행한 후, 영상 분석을 통해 시설물을 자동으로 검출 및 분류할 수 있다. 둘째, 결과 데이터를 GIS(지리정보시스템) 데이터베이스와 연계하여 지도 기반으로 시각화하고 이를 바탕으로 시설물의 유지·보수 현황을 체계적으로 관리할 수 있다. 셋째, 주기적인 이미지 데이터 분석을 통해 데이터의 최신성을 유지하면, 교통안전 관리의 효율성과 활용성을 향상시킬 수 있다.

## V. 결론 및 향후 계획

### 1. 요약 및 시사점

본 연구에서는 지능형 교통 시스템의 다양한 영역에서 활용할 수 있는 효과적인 교통안전표지 검출 모델의 정확도 향상과 모델 비교를 위해 YOLOv10과 YOLOv11 모델의 성능을 직접 비교·분석하여 인공지능 딥러닝 기반 모델의 활용 가능성을 탐구하였다. 특히 수집이 용이한 이미

지 데이터를 확보하여 전처리 및 정규화 작업을 통해 고품질 데이터셋을 구축하였고 최종 성능 평가에서 mAP50-95 정확도를 0.73까지 향상하는 유의미한 결과를 도출하였다.

두 모델의 객체 검출 성능을 비교한 결과, 모두 우수한 성능을 보였으나 YOLOv11 모델이 검출 정확도와 안정성, 그리고 정밀도와 재현율의 균형 측면에서 YOLOv10 모델 대비 더 향상된 성능을 나타냈다. 특히 YOLOv11 모델은 개선된 구조를 기반으로 복잡한 환경에서의 소형 객체 검출과 컴퓨터 비전 기술을 활용한 다양한 작업 수행에 강점을 나타내서 지능형 교통 시스템과 같은 복합적 응용 환경에 더 적합할 것으로 평가된다. 반면, YOLOv10 모델은 실시간 처리 성능에 강점이 있어서 실시간성이 요구되는 응용 분야에 효과적으로 활용될 수 있다. 따라서, 두 모델의 특성을 적절히 활용할 경우, 지능형 교통 시스템 뿐만 아니라 다양한 산업 분야에 폭넓게 적용할 수 있다.

본 연구는 지능형 교통 시스템의 다양한 영역에서 최적의 객체 검출 모델을 선정하고 활용 방안을 수립하는 데 중요한 기준으로 활용될 수 있다. 또한, 본 연구에서 도출된 각 YOLO 모델의 성능 비교 결과는 딥러닝 기반 객체 검출 기술을 적용하고자 하는 다양한 산업 분야에서 유용하게 활용될 것으로 기대된다.

### 2. 향후 연구 계획

두 모델 모두 우수한 성능이 확인된 것은 각 모델의 특성과 함께 데이터 셋의 품질과 학습 과정의 적절성을 시사한다. 다만, 모델의 일반화 성능을 더욱 정확하게 검증하기 위해서는 다양한 환경 조건을 반영한 추가적인 평가가 필요할 것이다.

객체 검출의 성능은 모델 구조 뿐만 아니라 학습 데이터의 품질에 크게 영향을 받는다. 특히 학습 데이터의 정확성은 분석 결과의 신뢰도를 결정하는 핵심 요소이다. 이에 따라 데이터 증강 및 전처리 기법 등 데이터 품질과 직결되는 핵심 요인에 대한 후속 연구가 요구된다. 향후 연구에서는 데이터셋의 규모와 다양성을 확장하여 데이터 품질 및 검출 정확도를 향상시키기 위한 추가적인 연구가 필요할 것이다.

## REFERENCES

- [1] 유영상, “도로교통 체계의 지능화”, ETRI(한국전자통신연구원), *기술정책연구본부*, 1-4쪽, 2019년 11월
- [2] 교통AI 빅데이터 융합플랫폼 통해, 안전한 도로환경 조성한다(2025), <http://www.engjournal.co.kr/news/articleView.html?idxno=3101> (accessed Mar., 27, 2026).
- [3] 전효원, 박민주, “CCTV 기반 교통 안전 확보를 위한 YOLOv11 기반 객체 검출 성능 향상 연구”, *안전문화연구*, 제44호, 1-2쪽, 2025년 7월
- [4] Jiaqi Wang and Jian Su, “A Review of Object Detection Techniques in IoT-Based Intelligent Transportation Systems”. *Computers, Materials & Continua*, vol. 84, no. 1, pp. 142-145, 2025.
- [5] 전효원, 박민주, “CCTV 기반 교통 안전 확보를 위한 YOLOv11 기반 객체 검출 성능 향상 연구”, *안전문화연구*, 제44호, 9-10쪽, 2025년 7월
- [6] Ultralytics YOLO11(2024), <https://docs.ultralytics.com/models/yolo11> (accessed Mar., 27, 2026).
- [7] 경찰청, “2024 교통안전포지 설치·관리 업무편람”, 경찰청, 14-15쪽, 2024년 12월
- [8] Joseph Redmon, Santosh Divvala, Ross Girshick, Ali Farhadi, “You Only Look Once: Unified, Real-Time Object Detection”, *IEEE Conference on Computer Vision and Pattern Recognition*, pp. 779-788, 2015.
- [9] Ao Wang, Hui Chen, Lihao Liu, Kai Chen, Zijia Lin, Jungong Han, Guiguang Ding, “YOLOv10: Real-Time End-to-End Object Detection”, arXiv preprint arXiv:2405.14458, pp. 1-10, 2024.
- [10] Rahima Khanam, Muhammad Hussain, “YOLOv11 An Overview of the Key Architectural Enhancements”, arXiv:2410.17725, pp. 1-8, 2024.
- [11] Ultralytics YOLO11(2024), <https://docs.ultralytics.com/models/yolo11> (accessed Apr., 4, 2026).
- [12] 송정현, “ESG 환경에서의 컴퓨터비전 및 딥러닝 기반 결함 연구: 금속 표면 미세결함 인식을 향상 중심으로”, 호서대학교 벤처대학원 박사학위논문, 2025년 12월
- [13] Performance Metrics Deep Dive(2026), <https://docs.ultralytics.com/guides/yolo-performance-metrics> (accessed Apr., 4, 2026).
- [14] YOLOv10 vs YOLO11: A Deep Dive into Real-Time Object Detection Architectures(2026), <https://docs.ultralytics.com/compare/yolov10-vs-yolo11> (accessed Apr., 19, 2026).
- [15] 정도윤, 김남호, “YOLOv10 기반 실내 환경에서의 화재 및 연기 실시간 탐지 성능 평가”, *스마트미디어저널*, 제14권, 10호, 63-70쪽, 2025년 10월
- [16] 최준오, 무탈리 라잔드라, 서용철, “이안류 탐지를 위한 YOLO 모델 비교와 시각적 해석 연구”, *대한공간정보학회지*, 제32권, 4호, 107-116쪽, 2024년 12월
- [17] 전승배, 김주완, 김정범, 정명훈, “YOLO 모델 기반 해양 쓰레기 탐지 및 성능 비교”, *해양공간정보학회지*, 제13권, 2호, 21-31쪽, 2024년 1월
- [18] 이용환, 김홍준, “YOLO 시리즈(V1에서 V11까지)와 응용 애플리케이션 분석 비교”, *반도체디스플레이기술학회지*, 제23권, 4호, 190-198쪽, 2024년 1월

## 저자 소개



류지성(정회원)

2021년 Vlerick Business School ELP  
과정 수료.  
2023년 단국대학교 산업경영학과 학사 졸업.  
2026년 단국대학교 일반대학원 경영학과 석·박사 통합과정

<주관심분야 : 인공지능, 딥러닝, 디지털 트윈>



송인국(정회원)

University of Tennessee at Martin,  
Computer Science 학사.  
The George Washington University,  
Information Management 석사.  
The George Washington University,  
Information & System Management 박사.  
2004년~ 단국대학교 경영학과 교수

<주관심분야 : IT비즈니스, 인공지능, IS>