

# YOLOv8을 이용한 실시간 야생동물 로드킬 탐지 기법

김해성<sup>1</sup>, 문지훈<sup>2\*</sup>

<sup>1</sup>순천향대학교 AI·빅데이터학과 학생, <sup>2</sup>순천향대학교 AI·빅데이터학과 교수

## A Real-Time Wildlife Roadkill Detection Approach Using YOLOv8

Haesoung Kim<sup>1</sup>, Jihoon Moon<sup>2\*</sup>

<sup>1</sup>Undergraduate Student, Department of AI and Big Data, Soonchunhyang University

<sup>2</sup>Professor, Department of AI and Big Data, Soonchunhyang University

**요약** 지속적인 도시화와 도로 개발로 인해 야생동물의 로드킬 사고가 심각한 사회적 문제로 대두되고 있다. 특히 한국은 높은 도로 밀도로 인해 야생동물이 로드킬 위험에 더욱 노출되어 있다. 본 연구는 최신 객체 탐지 기술인 YOLOv8 모델을 활용하여 국내 야생동물 로드킬 사고를 예방하기 위한 객체 탐지 시스템을 제안한다. Roboflow를 이용해 6종의 포유류 이미지 데이터를 전처리한 후, YOLOv8 모델을 학습시켜 높은 정확도(mAP50: 0.986, mAP50-95: 0.86)를 달성하였다. 또한, YOLOv5 및 YOLOv7과의 비교 실험을 통해 YOLOv8의 우수성을 입증하였다. 본 연구는 보호색을 가진 동물들에서도 높은 탐지 성능을 보여 로드킬 사고 감소와 야생동물의 안전한 이동을 지원하며, 생태 통로 및 유도 울타리의 설계와 배치에 중요한 기초 자료를 제공한다.

**주제어** : 야생동물, 객체 탐지, 로드킬, 교통사고, YOLOv8

**Abstract** Increasing urbanization and road development have led to severe wildlife roadkill incidents, posing a significant social challenge. Especially in Korea, the high road density increases the exposure of wildlife to roadkill risks. This study proposes a wildlife object detection system using the latest object detection technology, YOLOv8, to mitigate domestic wildlife roadkill incidents. Using Roboflow for preprocessing, six mammal species were selected and the YOLOv8 model was trained, achieving high accuracy with mAP50 of 0.986 and mAP50-95 of 0.86. Comparative experiments with YOLOv5 and YOLOv7 demonstrated the superior performance of YOLOv8. The proposed system effectively detects animals even with protective coloration, contributing to the reduction of roadkill incidents and assisting in the design and placement of ecological corridors and guide fences. This research provides an important technological foundation for improving wildlife safety and maintaining ecological balance in urbanized areas.

**Key Words** : Wild Animals; Object Detection; Roadkill; Traffic Accident; YOLOv8

## 1. 서론

산업혁명 이후 지속된 도시화와 산업화는 국가 경제 발전의 핵심 동력으로 자리매김해 왔다. 이러한 발전은 인구의 생활 수준을 향상하고, 편리하고 쾌적한 생활 환경을 제공하는 데 이바지했지만, 그 과정에서 토지 개척과 산림 파괴 등 인간의 편익을 위한 자연 자원의 인위적 개발이 진행되면서 다양한 야생동물의 서식지가 심각하게 위협받고 있다[1, 2]. 특히, 도로망의 급속한 확장은 야생동물의 서식지 감소를 가속해 생물 다양성(biodiversity) 및 생태계(ecosystem) 균형에 부정적인 영향을 미치고 있다[3]. 이는 야생동물의 서식지 및 행동 패턴에 변화를 초래하며, 로드킬(roadkill)의 발생 빈도를 증가시켜 단순한 동물의 생존 문제를 넘어 사회 전반에 걸친 심각한 문제로 대두되고 있다[4]. 로드킬 사고는 생태계의 균형을 교란할 뿐만 아니라, 인간에게도 정신적 트라우마와 경제적 손실을 유발하는 등 사회적 문제로 이어지고 있다.

최근 환경 보호(environmental protection)와 생물 다양성 유지를 위한 노력이 국내외적으로 강조되고 있다[5]. 국내에서도 2000년대 초반부터 '저탄소 녹색 성장(low-carbon green growth)'과 '지속 가능한 발전(sustainable development)'을 내세워 환경 보호 및 생태계 공존의 중요성을 지속해서 강조해 왔다[6]. 특히 한국은 급속한 경제 발전과 함께 국토 개발이 급진적으로 진행되면서 야생동물의 서식지가 빠르게 사라지고 있다. 한국의 지리적 특성상 국토 면적이 제한적이며, 포르투갈(Portugal)이나 그리스(Greece)와 같은 유사한 국토 면적을 가진 국가에 비해 도로 밀도(road density)가 약 1.07로 매우 높은 편이다[7]. 이러한 높은 도로 밀도는 하천, 평지, 산림을 이동하는 야생동물들에게 로드킬의 위험을 증가시키며, 이는 생태계 전반에 걸쳐 부정적인 영향을 미친다[8]. 또한, 로드킬 사고는 야생동물의 개체 수 감소를 초래함으로써 생물 다양성 저하와 생태계 서비스(ecosystem services)의 악화를 불러일으킨다[9].

현재 국내에서는 로드킬 문제를 해결하기 위해 유도 울타리(guidance fence), 생태 통로(ecological corridor) 등 다양한 예방책이 제시되고 있으나, 각 생물의 특성이나 공간적 상관성에 따라 로드킬 발생 패턴이 다르므로 효과적인 예방책을 마련하는 데 많은 시간과 비용이 소요되고 있다[10, 11]. 예를 들어, 고라니와 같은 동물의 경우 도로 침입을 완전히 차단하기 위해서는 최소 1.8m 이상의 높은 울타리가 필요하지만, 이는 현실적으로 설치와 유지 관리가 어려운 상황이다[12]. 또한, 멧돼지

(wild boar)의 경우 날카로운 지형을 이용해 울타리를 쉽게 넘을 수 있어 추가적인 방어책이 필요하며, 청설모와 같은 소형 동물들은 생태 통로를 통해 안전하게 이동할 수 있지만, 이러한 통로의 설계와 유지 관리에 상당한 비용이 요구된다[13]. 따라서, 효율적이고 실용적인 로드킬 예방 방안이 절실히 요구되고 있다.

따라서, 로드킬 예방을 위한 더욱더 효율적이고 실용적인 방안을 마련하기 위해 사물인터넷(IoT: Internet of Things) 기술과 컴퓨터 비전(computer vision) 및 영상 처리 기술의 융합이 중요한 해결책으로 떠오르고 있다[14, 15]. IoT 기기는 도로 주변에 설치된 센서나 카메라와 연계되어 야생동물의 움직임을 실시간으로 감지하고, 이를 네트워크를 통해 중앙 시스템이나 운전자에게 즉각적으로 전달할 수 있다[16]. 특히, 고성능 객체 탐지 알고리즘을 영상 처리 기술에 적용하면 주행 중 이동 물체를 정확하고 신속하게 탐지하여 운전자에게 경고를 제공할 수 있다[17]. 이러한 통합 시스템은 설치 및 유지 관리 비용을 절감하면서도 효율적인 로드킬 예방 효과를 기대할 수 있으며, 수집된 데이터는 야생동물의 이동 패턴 분석과 생태계 보전 연구에 중요한 자료로 활용될 수 있다[18].

본 연구는 이러한 배경에서 로드킬 문제를 효과적으로 해결하려는 방안으로서, 최신 객체 탐지(object detection) 기술인 YOLOv8 모델을 활용한 야생동물 탐지 기법을 제안하고자 한다. YOLO (You Only Look Once) 모델은 실시간으로 객체를 탐지할 수 있는 심층 학습(deep learning) 기반의 단일 단계(single-stage) 객체 탐지 알고리즘으로, 이미지 내의 객체를 한 번의 처리 과정에서 탐지 및 분류하는 특징을 가지고 있다. YOLOv8은 YOLO 시리즈의 최신 버전으로, 이전 버전들에 비해 향상된 정확도(accuracy)와 처리 속도(speed)를 자랑하며, 더욱 정교한 객체 탐지가 가능하도록 설계되었다[19]. YOLOv8 모델은 높은 정확도와 실시간 처리 속도를 바탕으로 로드킬 사고를 예방하기 위한 주행 시 이동 물체에 대한 여러 가지의 물체 탐지 및 경고 시스템 구축에 적합하다.

본 연구는 Roboflow[20]를 이용한 데이터 라벨링(data labeling)을 통해 직접 구축한 데이터 셋을 YOLOv5, YOLOv7 모델과 비교 및 분석함으로써 YOLOv8 모델의 우수성을 검증하고자 한다[21, 22]. YOLOv5와 YOLOv7은 각각 YOLO 시리즈의 이전 버전으로, 이미 다양한 응용 분야에서 그 성능이 입증된 바 있으나, YOLOv8의 향상된 성능이 실제 로드킬 예방 시스템에 얼마나 기여할 수 있는지를 명확히 입증하고자 비교 연

구를 수행하였다. 이를 통해 YOLOv8 모델이 주행 중 이동 물체 탐지 시스템에서 얼마나 효과적으로 활용될 수 있는지를 평가하며, 궁극적으로, 인공지능 기술이 IoT 시스템에 적용되어 사람의 야생동물 탐지 역할을 대체함으로써 불필요한 노동력을 절감하고, 연구의 정확도를 높여 로드킬 사고 예방 및 생태계 보전에 기여하고자 한다[23].

본 연구의 주요 기여는 다음과 같다. (1) YOLOv8 모델을 활용한 주행 중 이동 물체에 대한 여러 가지로의 물체 탐지 기법을 제안함으로써 기존의 로드킬 예방책의 한계를 극복할 수 있는 새로운 접근법을 제공한다. (2) 국내 야생동물의 특성에 맞춘 데이터 셋을 구축하고, 이를 통해 모델의 성능을 최적화함으로써 실제 현장에서의 적용 가능성을 높인다. (3) YOLOv5, YOLOv7 모델과의 성능 비교를 통해 YOLOv8 모델의 우수성을 입증함으로써, 향후 로드킬 예방을 위한 기술적 기반을 마련하는 데 이바지한다. 이는 로드킬 사고를 줄이고, 야생동물의 생존과 생태계의 균형을 유지하는 데 중요한 역할을 할 수 있다.

본 논문의 나머지 구성은 다음과 같다. 2장에서는 연구의 이론적 배경을 다루며, 객체 탐지 모델의 원리와 YOLO 모델의 개념 및 구조에 관해 설명한다. 3장에서는 연구 방법론을 상세히 기술하며, 데이터 수집, 전처리, 모델 학습 과정에 대해 논의한다. 4장에서는 연구 결과를 제시하고, YOLOv8 모델의 성능을 다른 YOLO 모델과 비교 분석한다. 마지막으로, 5장에서는 연구의 결론을 도출하고, 한계점 및 향후 연구 방향을 제시한다.

## 2. 이론적 배경

본 장에서는 본 연구의 핵심인 객체 탐지 모델의 기본 원리와 YOLO 시리즈의 발전 과정을 살펴본다. 특히, YOLOv8 모델의 선택 이유와 그 우수성을 논리적으로 제시하여 본 연구의 기술적 기반을 확립하고자 한다.

### 2.1 객체 탐지의 기본 원리

객체 탐지는 주어진 이미지나 비디오 내에서 특정 객체를 식별하고 그 위치를 정확히 파악하는 컴퓨터 비전 기술의 한 분야이다. 객체 탐지는 자율주행 자동차, 보안 시스템, 의료 영상 분석 등 다양한 응용 분야에서 중요한 역할을 담당하고 있다[24].

객체 탐지의 초기 접근 방식은 기계학습(machine

learning)을 기반으로 하였다. 이 시기에는 특징 추출기(feature extractor)인 SIFT (Scale-Invariant Feature Transform), HOG (Histogram of Oriented Gradients) 등과 같은 알고리즘을 사용하여 이미지에서 유의미한 특징을 추출하고, 이를 전통적 분류기(traditional classifier)인 SVM (Support Vector Machine)이나 의사결정 나무(decision tree)를 통해 객체를 분류하였다[25]. 이러한 방법은 국부적인 객체 탐지에 한정되었으나, 심층 학습의 발전과 함께 대량의 데이터를 활용한 더욱 강력하고 범용적인 객체 탐지 모델이 등장하게 되었다[26, 27].

현대의 객체 탐지 알고리즘은 주로 심층 신경망(deep neural networks)을 기반으로 하며, 두 가지 주요 접근 방식인 단일 단계(single-stage) 모델과 이중 단계(two-stage) 모델로 구분된다[28].

- 단일 단계(single-stage) 모델: 객체 탐지와 분류를 한 번의 처리 과정에서 동시에 수행한다. 대표적인 모델로는 YOLO, SSD (Single Shot multibox Detector), RetinaNet 등이 있다[29]. 단일 단계 모델은 빠른 처리 속도가 장점이지만, 복잡한 객체의 탐지 정확도에서 다소 부족할 수 있다.
- 이중 단계(two-stage) 모델: 먼저 잠재적인 객체 후보 영역(region proposals)을 생성한 후, 해당 영역을 정밀하게 분류 및 탐지하는 두 단계로 이루어진다. 대표적인 모델로는 R-CNN (Region-based Convolutional Neural Networks) 계열이 있다 [30]. 이중 단계 모델은 높은 정확도를 제공하지만, 처리 속도가 상대적으로 느린 단점이 있다.

### 2.2 YOLO 시리즈의 발전과 YOLOv8의 우수성

YOLO는 실시간 객체 탐지를 가능하게 하는 단일 단계 방식의 객체 탐지 알고리즘이다. YOLO는 이미지를 그리드(grid)로 분할한 후, 각 그리드에서 바운딩 박스(bounding box)와 해당 객체의 신뢰도(confidence score)를 예측하는 방식으로 동작한다. YOLO의 주요 특징은 이미지를 한 번만 살펴보면서 객체의 위치와 종류를 동시에 예측하는 점으로, 이에 따라 빠른 처리 속도를 달성할 수 있다.

YOLO 시리즈는 여러 버전으로 발전해 왔으며, 각 버전은 이전 버전의 한계를 극복하고 성능을 향상하기 위해 다양한 개선이 이루어졌다. 표 1을 통해 YOLO 시리즈의 발전 과정을 한눈에 파악할 수 있으며, 각 버전의 특징과 장단점을 비교함으로써 YOLOv8의 우수성을 이해할 수 있다[22].

〈Table 1〉 YOLO series versions and key features

Version	Year	Key Features
YOLOv1	2016	Single neural network for detection & classification
YOLOv2	2017	Introduction of anchor boxes, batch normalization
YOLOv3	2018	Multi-scale predictions, enhanced multi-class classification
YOLOv4	2020	CSPDarknet53 backbone, Spatial Pyramid Pooling (SPP) module
YOLOv5	2020	PyTorch-based, various model sizes (small, medium, and large)
YOLOv6	2022	Efficient layer aggregation, optimized for speed and accuracy
YOLOv7	2022	New network architecture, various optimization techniques
YOLOv8	2023	Latest architectural improvements, more precise object detection & classification
YOLOv9	2024	Lightweight models, efficient memory usage
YOLOv10	2024	Integrated optimization techniques, customizable for various applications

YOLOv8은 YOLO 시리즈의 최신 버전으로, 이전 버전들에 비해 더욱 향상된 정확도와 처리 속도를 제공한다. 본 연구에서 YOLOv8을 중점적으로 다루는 이유는 다음과 같다:

- 정확도 향상: YOLOv8은 최신 심층 학습 기법을 적용하여 객체 탐지의 정확도를 크게 향상하였다. 이는 로드킬 예방 시스템에서 정확한 야생동물 탐지를 가능하게 하여, 사고 예방에 직접적으로 기여할 수 있다.
- 실시간 처리 속도: 로드킬 예방 시스템은 실시간으로 동물의 움직임을 감지하고 경고를 발송해야 하므로, 빠른 처리 속도가 필수적이다. YOLOv8은 단일 단계 모델로서 높은 처리 속도를 유지하면서도 정확도를 보장한다.
- 모델 최적화 및 경량화: YOLOv8은 다양한 하드웨어 환경에서 효율적으로 동작할 수 있도록 최적화되어 있어, 실제 현장에서의 적용 가능성이 높다. 이는 유지 관리 비용 절감과 시스템의 안정성을 높이는 데 기여한다.
- 확장성 및 유연성: YOLOv8은 다양한 크기의 모델을 제공하여, 필요에 따라 적절한 모델을 선택할 수 있다. 이는 다양한 야생동물의 특성과 환경에 맞춘 맞춤형 시스템 구축을 가능하게 한다.

## 2.3 기존 연구의 한계와 본 연구의 기여

야생동물 객체 탐지 분야에서는 최근 YOLOv5를 활용한 연구가 주목받고 있다. Kang은 YOLOv5 모델을

이용하여 야생동물 탐지 및 분류 모델을 개발하였으며, 실험실이나 연출된 상황이 아닌 실제 환경에서의 야생동물 이미지를 대상으로 높은 성능을 확인하였다[23]. 해당 연구는 기존의 이미지 분류 모델인 EfficientDet, EfficientNet, YOLOv4보다 우수한 성능을 보이는 YOLOv5의 활용 사례를 제시하여, 야생동물로 인한 로드킬 사고를 예방하는 데 기여할 수 있음을 보여주었다.

또한, Kim 등은 야생동물 침입 방지를 위해 SSD와 MobileNets를 결합한 실시간 모니터링 플랫폼을 설계 및 구현하였다[31]. 해당 연구는 99.2%의 평균 정밀도를 기록하여, 63.5%~81.4%, 68.3%~89.3%의 성능을 보이는 YOLOv2와 Faster R-CNN보다 우수한 성능을 달성하였다. 이를 통해 다양한 객체에 대한 감지에서 SSD와 MobileNets 조합이 다른 기법들보다 현저하게 높은 정확도를 보여주었다.

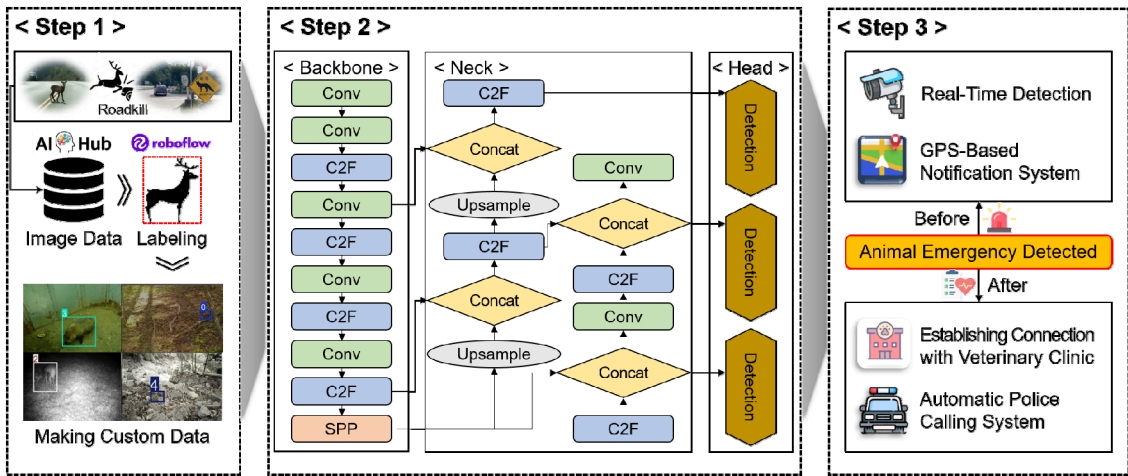
하지만 이러한 연구들은 실시간 모니터링 환경에서 리소스 효율성을 높이는 데 집중되어 있지만, 더 복잡하고 다양한 환경에서의 높은 정확도와 처리 속도를 동시에 만족시키는 데는 한계가 있다. 특히, 보호색을 가진 동물의 탐지 성능이나 작은 객체에 대한 탐지 성능에서는 추가적인 개선이 필요하다. 또한, Kang의 연구[23]에서는 YOLOv5를 활용하였으나, 최신 버전인 YOLOv8에 비해 정확도와 처리 속도 면에서 향상될 여지가 있다.

## 3. 연구 방법론

본 장은 Fig. 1과 같이 본 연구에서 수행한 연구 방법론(methodology)에 대해 상세히 설명한다. 연구 데이터의 선정 및 수집, 데이터 전처리 과정, YOLOv8 모델의 학습 및 평가 절차를 논의하며, 각 단계에서 사용된 도구와 기법의 선택 이유를 명확히 제시한다. 이를 통해 독자들이 연구의 신뢰성과 타당성을 충분히 이해하고, 연구 과정에서 얻은 인사이트를 쉽게 파악할 수 있도록 한다.

### 3.1 연구 데이터 선정 및 수집

본 연구는 국내에서 발생하는 야생동물 로드킬 사고의 현황을 분석한 이승민[32]의 연구를 기반으로, 객체 탐지 모델의 성능을 평가하기 위해 적절한 데이터를 선정하였다. 이승민의 연구에 따르면, 국내 로드킬 사고에서 발생 빈도가 높은 야생동물 종은 Table 2와 같다.



[Fig. 1] System architecture

<Table 2> Top 10 most common roadkill mammals in South Korea

Species	Percentage (%)
Raccoon Dog	12.9
Chipmunk	12.8
Weasel	10.6
Water Deer	10.6
Red Squirrel	5.9
Korean Hare	1.8
Leopard Cat	1.7
Others	43.7
Total	100

본 연구에서는 Table 2의 결과를 반영하여, 영상 데이터 수집이 가능한 너구리(Raccoon Dog), 다람쥐(Chipmunk), 족제비(Weasel), 고라니(Water Deer), 청설모(Red Squirrel), 멧토끼(Korean Hare)와 같이 6종의 포유류를 대상으로 객체 탐지를 진행하였다. 이는 로드킬 사고에서 빈도가 높은 중 중 영상 데이터 확보가 용이한 종들로 선정한 것이다. 본 연구에서 사용된 데이터셋은 야생동물의 로드킬 예방을 목적으로 설계된 실질적 환경 기반의 데이터로, 다양한 시간대와 장비(CCTV, DSLR, 센서 카메라 등)를 활용하여 수집되었다.

또한, 야생동물의 다양한 행동 패턴과 서식지 환경을 포괄하고 있으며, 청설모와 다람쥐처럼 외형적으로 유사한 종들을 포함함으로써, 실제 상황에서 발생할 수 있는 복잡한 분류 문제들을 충분히 반영하고자 하였다. 더불어, 총 3,000장의 고해상도 JPG 이미지로 구성된 데이터셋은 각 객체당 500프레임씩 수집되어 데이터 양적 측면에서도 충분한 수준을 확보하였으며, 모든 이미지는

1,920픽셀 해상도로 통일하여 데이터 품질의 일관성을 유지하였다. 이러한 특성으로 인해, 본 데이터셋은 시뮬레이터 환경뿐만 아니라 실제 야생동물의 이동 경로를 모니터링하고 분석하는 데에도 유용하게 적용될 수 있다.

### 3.2 데이터 전처리 및 라벨링

데이터 전처리 과정은 객체 탐지 모델의 성능에 직접적인 영향을 미치므로, 신중하게 수행되었다. 본 연구에서는 데이터 준비 플랫폼(data preparation platform)인 Roboflow를 활용하여 데이터 전처리를 진행하였다. Roboflow는 이미지 데이터를 효율적으로 업로드, 관리, 전처리, 라벨링할 수 있는 도구로, 객체 탐지 모델 학습에 필요한 데이터 셋 구축 과정을 간소화하고 자동화해 준다.

Roboflow의 주요 기능 및 활용 과정은 다음과 같다:

- 데이터 업로드 및 관리: AI Hub에서 수집한 야생동물 활동 영상 데이터를 Roboflow에 업로드하였다. Roboflow의 직관적인 인터페이스를 통해 대규모 데이터를 효율적으로 관리할 수 있었다.
- 데이터 라벨링: Roboflow의 라벨링 도구를 사용하여 각 이미지에 바운딩 박스를 생성하고, 객체의 클래스(class)를 지정하였다. 이는 모델이 학습할 수 있는 정답 데이터를 체계적으로 준비하는 데 필수적이다.
- 데이터 증강: 모델의 일반화 성능을 높이기 위해 이미지 회전, 크기 조정, 색상 보정 등의 증강 기법을 적용하였다. 이는 다양한 환경에서의 객체 탐지 성능을 향상하는 데 기여하였다.

- 데이터 분할: 최종적으로 라벨링이 완료된 데이터 셋을 학습, 검증, 평가 집합으로 8:1:1 비율로 나누었다[33]. 이는 모델의 학습과 평가 과정에서 데이터의 과적합(overfitting)을 방지하고, 모델의 일반화 능력을 검증하는 데 중요하다.
- 데이터 셋 생성 및 배포: Roboflow를 통해 YOLOv8 전용 RAW URL을 생성하여 모델 학습에 필요한 데이터 셋을 준비하였다. 이를 통해 다양한 객체 탐지 모델과의 호환성을 확보할 수 있었다.

Roboflow의 효율적인 데이터 관리와 전처리 기능을 통해 모델 학습에 필요한 고품질의 데이터 셋을 신속하게 준비할 수 있었으며, 다양한 데이터 증강 기법을 적용하여 모델의 일반화 능력을 향상할 수 있었다. 또한, Roboflow의 자동화된 데이터 분할 기능은 모델의 과적합을 방지하고, 학습 및 평가 과정의 효율성을 극대화하는 데 기여하였다.

### 3.3 모델 학습

YOLOv8 모델은 합성곱 신경망(CNN; Convolutional Neural Network)을 기반으로 하며, 이미지 내의 객체를 탐지하기 위해 여러 계층의 신경망을 활용한다. YOLOv8의 주요 구성 요소는 다음과 같다:

- 백본(backbone): 이미지에서 특징(feature)을 추출하는 역할을 한다. YOLOv8은 최적화된 백본 구조를 통해 효율적으로 특징을 추출하며, 다양한 크기의 객체를 탐지할 수 있는 능력을 갖추고 있다.
- 헤드(head): 추출된 특징을 기반으로 객체의 위치와 클래스를 예측한다. YOLOv8의 헤드는 다중 스케일 예측을 통해 다양한 크기의 객체를 정확하게 탐지할 수 있도록 설계되었다.
- 앵커 박스(anchor boxes): YOLOv8은 다양한 크기와 비율의 앵커 박스를 사용하여 객체의 위치를 예측한다. 앵커 박스는 K-means 알고리즘을 통해 데이터 셋에 맞게 사전 정의되며, 이를 통해 다양한 형태와 크기의 객체를 효과적으로 탐지할 수 있다.
- 손실 함수(loss function): YOLOv8은 객체의 위치, 클래스, 신뢰도 등을 최적화하기 위한 다양한 손실 함수를 사용하여 모델의 학습을 진행한다. 이를 통해 모델의 예측 정확도를 지속해서 향상한다.

YOLOv8은 이전 버전들에 비해 더 깊고 복잡한 신경망 구조로 되어 있으며, 이는 더욱 정교한 객체 탐지를 가능하게 한다. 또한, YOLOv8은 다양한 최적화 기법을 적용하여 모델의 효율성과 성능을 동시에 향상하였다.

이러한 구조적 개선은 로드킬 예방 시스템에서 실시간으로 정확한 야생동물 탐지를 수행하는 데 중요한 역할을 한다. 모델 학습 과정은 Table 3과 같이 설정하였다.

〈Table 3〉 Hyperparameters used for model training

Hyperparameter	Value
Epoch	100
Patience	30
Batch size	16
Image size	1920
Amp	True
Dropout	0.1

- 학습 과정: 총 100 epoch 동안 batch size를 16으로 설정하여 학습을 진행하였다. 모델의 과적합을 방지하기 위해 early stop 기능의 patience를 30으로, dropout을 0.1로 설정하였다. 이는 학습 도중 검증 손실이 개선되지 않으면 조기 종료를 유도하여 모델의 일반화 능력을 향상하였다.
- 고해상도 입력: 작은 객체의 탐지 성능을 높이기 위해 1,920픽셀의 고해상도로 이미지를 입력하였다. 높은 해상도는 객체의 세부 정보를 보존하여 탐지 정확도를 향상하는 데 기여한다.
- 메모리 최적화: 연구 환경의 하드웨어 성능을 최적화하기 위해 AMP (Automatic Mixed Precision)를 True로 설정하여, 큰 성능 손실 없이 학습 속도를 향상하였다. 이는 GPU 메모리 사용을 효율적으로 관리하여 모델 학습 시간을 단축한다.

## 4. 연구 결과

본 장에서는 본 연구에서 수행한 YOLOv8 모델의 객체 탐지 성능을 평가한 결과를 제시하고 분석한다. 성능 지표 분석과 학습 결과를 통해 YOLOv8 모델의 우수성을 입증하고, 기존의 YOLOv5 및 YOLOv7 모델과의 비교를 통해 본 연구의 기여도를 명확히 한다. 또한, 모델의 학습 과정에서 관찰된 과적합 여부와 실제 객체 탐지 사례를 통해 모델의 실용성을 검증하였다.

### 4.1 성능 지표 분석

모델의 성능 평가는 주로 정확도를 중심으로 이루어졌다. 정확도는 모델이 실제로 올바르게 예측한 객체의 비율을 나타내며, 이는 객체 탐지 시스템의 전반적인 성능

을 평가하는 데 중요한 지표이다. 본 연구에서는 정확도를 더욱 세분화하여 평가하기 위해 혼동행렬(Confusion Matrix), 평균 정밀도(mAP; mean Average Precision), PR Curve (Precision-Recall Curve), R Curve (Recall- Confidence Curve) 등과 같은 다양한 평가지표를 사용하였다. 또한, Training and Validation Loss 그래프를 통해 모델이 학습 과정에서 과적합이 발생했는지를 확인하였다.

다중분류 문제에서 혼동행렬은 모델의 예측 결과와 실제 레이블을 클래스별로 비교하여, 각 클래스에 대한 예측의 정확성을 직관적으로 시각화하는 도구이다. 혼동행렬은 각 행이 실제 클래스를, 각 열이 예측된 클래스를 나타내며, 행렬의 대각선에 위치한 값들은 각 클래스가 정확하게 예측된 비율을 보여준다. 비대각선의 값들은 잘못 예측된 경우들을 나타내어, 이를 통해 모델이 어떤 클래스를 다른 클래스로 잘못 분류했는지 파악할 수 있다.

mAP는 여러 클래스에 걸쳐 모델의 예측 정확도를 종합적으로 평가하는 지표이다. mAP는 클래스별로 Precision-Recall Curve를 작성한 후, 그 곡선 아래의 면적을 계산하여 평균을 산출한다. 이는 모델이 다양한 클래스에서 얼마나 정확하게 객체를 탐지하고 분류하는지를 반영한다. mAP 값이 클수록 모델의 객체 탐지 및 분류 성능이 우수하다는 것을 의미하며, 이는 모델이 다양한 조건에서도 안정적으로 작동함을 나타낸다.

정밀도(Precision)는 모델이 검출한 객체 중 실제로 올바르게 검출된 객체의 비율을 의미한다. 이는 모델의 False Positive 비율을 줄이는 데 중요한 역할을 한다. 높은 정밀도는 모델이 잘못된 객체를 검출하는 경우가 적음을 나타내며, 이는 실제 응용 시 오탐지의 가능성을 낮추는 데 기여한다. 반면, 재현율(Recall)은 실제로 존재하는 객체 중 모델이 올바르게 검출한 객체의 비율을 나타낸다. 이는 모델의 False Negative 비율을 줄이는 데 중요한 지표로, 높은 재현율은 모델이 실제 객체를 놓치지 않고 탐지하는 능력이 뛰어난 것을 의미한다.

본 연구에서는 PR Curve를 통해 모델의 정밀도와 재현율 간의 상관관계를 시각적으로 분석하였다. 이 곡선은 다양한 임계값에서 모델의 성능 변화를 보여주며, 모델이 특정 임계값에서 얼마나 정확하게 객체를 탐지하는지를 파악할 수 있게 해준다. 또한, R Curve는 신뢰도 임계값에 따른 재현율의 변화를 나타내어, 모델이 다양한 신뢰도 기준에서 얼마나 많은 실제 객체를 탐지할 수 있는지를 보여준다. 이러한 분석을 통해 YOLOv8 모델이 높은 정밀도와 재현율을 동시에 달성함으로써, 객체


탐지의 정확성과 완전성을 모두 충족시키고 있음을 확인할 수 있었다.

## 4.2 학습 결과 및 모델 성능 비교


모델의 전반적인 성능 비교를 위하여 동일한 데이터셋 및 하이퍼파라미터를 적용한 YOLOv5, YOLOv7, YOLOv8 모델에 대한 실험을 수행하였다. 학습 결과, 최종 모델의 평균 정확도(mAP)는 Table 4에 제시된 바와 같이 mAP50에서 0.986, mAP50-95에서 0.86으로 높은 성능을 나타냈다. 이는 동일한 조건 하에서 실험한 YOLOv5 및 YOLOv7 모델과 비교할 때 가장 우수한 성과를 확인할 수 있었다.

<Table 4> Comparison of mAP performance

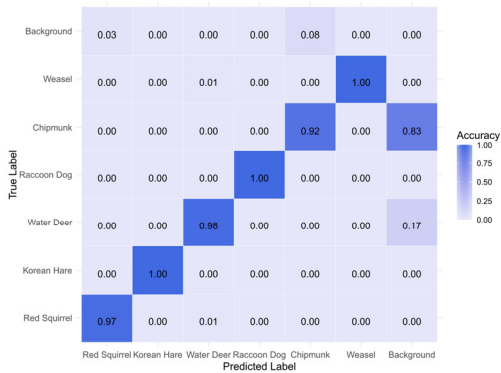
Model	mAP@0.5	mAP@0.5-0.95
YOLOv5	0.96	0.78
YOLOv7	0.98	0.78
YOLOv8	0.986	0.86



[Fig. 2] Confusion matrix for YOLOv5



[Fig. 3] Confusion matrix for YOLOv7



[Fig. 4] Confusion matrix for YOLOv8

<Table 5> Comparative accuracy analysis of YOLO models for various classes

Class	YOLOv5	YOLOv7	YOLOv8
Red Squirrel	0.98	0.96	0.97
Korean Hare	1.00	1.00	1.00
Water Deer	0.99	1.00	0.98
Raccoon Dog	1.00	1.00	1.00
Chipmunk	0.91	0.87	0.92
Weasel	1.00	0.95	1.00

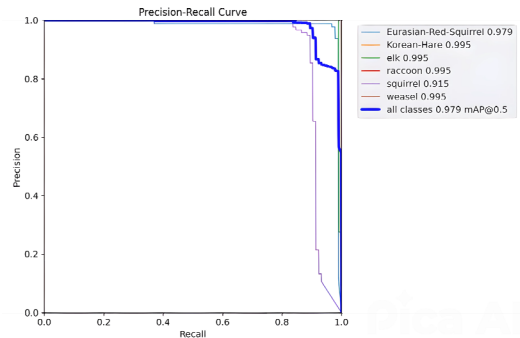
Figs. 2 to 4, Table 5에 제시된 혼동행렬 분석 결과에 따르면, YOLOv8 모델은 다른 버전의 YOLO 모델들(YOLOv5, YOLOv7)과 비교하였을 때 우수한 성능을 도출하였다. 특히, 다람쥐(Chipmunk) 클래스에서 YOLOv8은 0.92의 높은 정확도로, YOLOv5의 0.91과 YOLOv7의 0.87을 능가하는 경쟁력 있는 결과를 보였다. 이는 YOLOv8이 세밀한 객체 탐지에서도 높은 신뢰성을 제공하며, 다양한 환경에서 우수한 분류 성능을 입증하는 중요한 지표이다. 또한, 모든 클래스에 대해 일관되게 높은 정확도를 유지함으로써, YOLOv8이 포괄적인 우수성을 가진 모델임을 확인할 수 있었다.

다만, YOLOv8은 고라니(Water Deer) 클래스에서 YOLOv7에 비해 약간 낮은 정확도(0.98)를 기록하였으며, 이는 개선이 필요한 부분으로 보인다. 이러한 성능 차이를 더욱 깊이 분석하기 위해, 설명 가능한 인공지능 기법을 활용하여 모델의 예측 실패 원인을 분석하고, 해당 클래스에서의 성능을 향상하기 위한 구체적인 개선 방안을 모색할 필요가 있다[34]. 설명 가능한 인공지능을 통해 모델이 왜 특정 클래스에서 낮은 성능을 보이는지에 대한 통찰을 얻을 수 있으며, 이를 통해 향후 모델 성능을 체계적으로 개선하고자 한다.

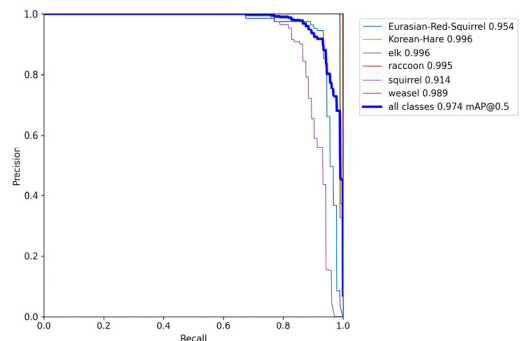
<Table 6> Comparison of PR curve, R curve, and FPS performance metrics by YOLO model

Model	PR Curve	R Curve	FPS
YOLOv5	0.979	0.98	0.60
YOLOv7	0.974	0.99	5.27
YOLOv8	0.986	0.99	0.11

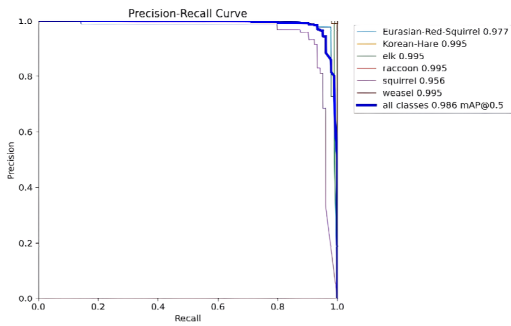
또한, Table 6에 제시된 PR Curve (Figs. 5 to 7)와 R Curve (Figs. 8 to 10) 분석 결과, 최종 모델은 각각 0.986과 0.99의 최고값을 기록하여 타 YOLO 모델들과 비교 시 YOLOv8 모델의 우수한 검출 성능을 입증하였다. 여기서 Eurasian-Red-Squirrel는 청설모, Korean-Hare는 멧토끼, elk는 고라니, raccoon은 너구리, squirrel은 다람쥐, weasel은 족제비를 의미한다. 이러한 높은 정확도는 IoT 환경에서의 실시간 객체 인식 및 모니터링에 적합함을 시사한다.



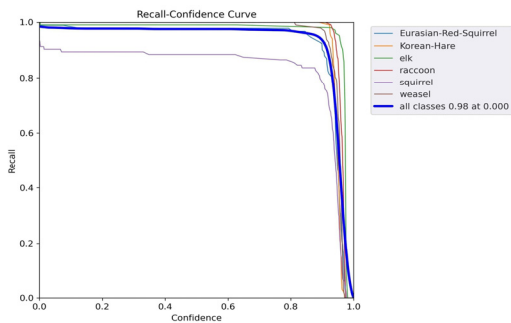
[Fig. 5] PR curve of YOLOv5




[Fig. 6] PR curve of YOLOv7




[Fig. 7] PR curve of YOLOv8



[Fig. 8] R curve of YOLOv5




[Fig. 9] R curve of YOLOv7




[Fig. 10] R curve of YOLOv8

처리 속도(FPS; Frames Per Second) 측면에서는 YOLOv5, YOLOv7, YOLOv8 모델의 FPS가 각각 0.60, 5.27, 0.11로 측정되었다. 특히, YOLOv8 모델은 약 0.1초당 프레임 처리 속도를 보여주었으며, 이는 YOLOv7 모델보다 약 4.16초 빠른 처리 속도를 나타낸다. 이러한 결과는 IoT 기반의 야생동물 모니터링 시스템에서 YOLOv8 모델이 실시간 객체 탐지에 있어 가장 높은 효율성이 보임을 확고히 한다.



[Fig. 11] Training and validation loss trends

모델의 높은 성능으로 인해 과적합 가능성을 배제하기 위해 Training 및 Validation Loss 그래프를 분석한 결과, Fig. 11에 나타난 바와 같이 초기 손실이 높게 시작하였으나 학습 진행에 따라 지속해서 감소하는 추세를 보였다. 이는 본 모델이 훈련 데이터에 과적합되지 않고, 일반화 성능이 우수함을 나타낸다. 실제로 Fig. 12에 제시된 검출 결과를 통해, 거의 모든 객체가 정확하게 인식되고 있음을 확인할 수 있어, 본 연구에서 제안한 모델이 IoT 환경에서의 객체 탐지에 효과적으로 활용될 수 있음을 시사한다.



[Fig. 12] Examples of actual detection results

## 5. 결론

본 연구에서는 YOLOv8 모델을 활용하여 국내 도로 환경에서 야생동물 로드킬 사고를 예방하기 위한 객체 탐지 시스템을 개발하였다. 연구 결과, YOLOv8 모델은 높은 정밀도와 재현율을 바탕으로 뛰어난 객체 탐지 성능을 보였으며, 과적합 없이 안정적인 학습 과정을 거쳐 우수한 일반화 능력을 입증하였다. 이를 통해 YOLOv8 모델은 주행 중에 발생할 수 있는 다양한 이동 물체를 탐지하는 데에도 적용 가능성을 보여줌으로써, YOLOv8이 실시간 로드킬 예방 시스템에서 정확하고 효율적인 야생동물 탐지를 가능하게 함을 보여준다.

하지만 본 연구에서는 데이터의 제한성으로 인해 일부 야생동물 종에만 집중하였으며, 다양한 종에 대한 탐지 성능을 충분히 평가하지 못했다는 한계가 있다. 또한, 매우 작은 크기의 객체 탐지 정확도는 여전히 개선이 필요하며, 실제 도로 환경에서의 실시간 테스트가 부족하였다. 향후 연구에서는 더 많은 종을 포함한 데이터 셋을 확보하고, 작은 객체 탐지 성능을 향상하기 위한 추가적인 기법을 적용할 필요가 있다. 또한, 최신 YOLOv9 및 YOLOv10 모델의 안정성 검증이 완료되면 이를 활용한 추가 연구를 진행할 계획이다.

그럼에도 불구하고, 본 연구는 YOLOv8 모델의 우수한 성능을 바탕으로 로드킬 예방 시스템의 실용성을 입증하였으며, Roboflow를 이용한 효율적인 데이터 전처리 및 라벨링 과정을 통해 모델 학습의 효율성을 크게 향상하였다. 이러한 결과는 실시간으로 동물들의 이동 패턴을 정확히 파악하고, 유도 울타리 및 생태 통로의 설계와 배치에 있어 중요한 기초 자료를 제공한다. 향후 YOLOv8 모델의 성능 향상과 상용화를 통해 로드킬 사고 예방에 더욱 효과적으로 기여할 수 있을 것으로 기대한다.

끝으로, 본 연구는 순천향대학교 SW중심대학사업단의 'SW 명문중학교 만들기' 프로그램[35]의 일환으로 진행되었으며, 순천향대 AI·빅데이터학과 학생인 김해성과 아산중학교 남현준 학생이 멘토-멘티로 참여하였다. 연구 과정에서 남현준 학생은 국내 로드킬 사고에서 데이터 분석을 통해 발생 빈도가 높은 야생동물 종을 선정 및 Roboflow를 활용하여 해당 종의 이미지 데이터를 전처리하였다. 나머지 연구인 YOLOv8 모델의 학습, 성능 평가 및 비교 실험 등은 문지훈 교수의 지도하에 김해성 학생이 수행하였다. 이러한 공동 연구를 통해 중학생은 SW와 인공지능 분야에 대한 실질적인 경험을 쌓고, 학습 동

기를 높일 수 있었다. 이는 지역 사회의 교육 발전에 기여하는 물론, 미래의 SW 인재육성을 육성하는 데 중요한 역할을 할 수 있을 것으로 기대한다.

## REFERENCES

- [1] S.E.Lee, H.G.Kang, M.R.Park, T.K.Park and H.L.Kim, "Drawing of Habitat Assessment Map and Conservation Value Assessment for Environmental Friendly Road Construction," *Journal of Korean Society of Environmental Engineers*, Vol.31, No.8, pp.611-618, 2009.
- [2] J.Lee, J.Oh and J.Moon, "A Study on the Analysis of Roadkill Status and the Installation of Ecological Pathway and Guided Fences for Roadkill Prevention in Korea," *The Journal of Society for e-Business Studies*, Vol.29, No.1, pp.17-33, 2024.
- [3] X.Huang, H.Wang, L.Shan and F.Xiao, "Constructing and optimizing urban ecological network in the context of rapid urbanization for improving landscape connectivity," *Ecological Indicators*, Vol.132, p.108319, 2021.
- [4] E.Kent, A.L. Schwartz and S.E. Perkins, "Life in the fast lane: roadkill risk along an urban-rural gradient," *Journal of Urban Ecology*, Vol.7, No.1, p.juaa039, 2021.
- [5] J.Rew, Y.Cho, J.Moon and E.Hwang, "Habitat suitability estimation using a two-stage ensemble approach," *Remote Sensing*, Vol.12, No.9, p.1475, 2020.
- [6] J.-H.Park, "The Critical Review of the Lee Myung-Bak Government's Green Technology Policy - From the Perspective of the Sustainable Technology Policy," *ECO*, Vol.13, No.2, pp.99-138, 2009.
- [7] D.Andersen and Y.Jang, "Biodiversity and Transportation Infrastructure in the Republic of Korea: A Review on Impacts and Mitigation in Developing the Country," *Diversity*, Vol.13, No.11, p.519, 2021.
- [8] F.Lala, P.I.Chiyo, E.Kanga, P.Omondi, S.Ngene, W.J.Severud, A.W. Morris and J. Bump, "Wildlife roadkill in the Tsavo Ecosystem, Kenya: identifying hotspots, potential drivers, and affected species," *Heliyon*, Vol.7, No.3, p.e06364, 2021.
- [9] H.K.Kweon, Y.H.Choi, M.J.Kim and J.W.Lee, "Study on the Status and Cause of the Road Kill for Wildlife Killing Reduce - A Case Study of National Road in Daejeon~Seosan Section -," *Journal of Forest and Environmental Science*, Vol.24, No.2, pp.99-109, 2008.
- [10] P.Medrano-Vizcaíno, C.Grilo, F.A.Silva Pinto, W.D.Carvalho, R.D.Melinski, E.D.Schultz and M.González Suárez, "Roadkill patterns in Latin American birds and mammals," *Global Ecology and Biogeography*, Vol.31, No.9, pp.1756-1783, 2022.
- [11] Y.Oh and G.Lee, "A Study on the Spatial Correlation

- between Roadkill and Traffic Accidents on Roads in Chungcheongnam-do," *Journal of Environmental Policy and Administration*, Vol.26, No.2, pp.147-166, 2018.
- [12] H.Croft, Deer Fence Height Guide: Your Questions Answered [Internet], <https://www.countyfencing.co.uk/blog/deer-fence-height-guide/>.
- [13] P.R.Armsworth, L.Cantú-Salazar, M.Parnell, Z.G.Davies and R.Stoneman, "Management costs for small protected areas and economies of scale in habitat conservation," *Biological Conservation*, Vol.144, No.1, pp.423-429, 2011.
- [14] S.-Y.Ahn, B.-S.Seo and S.D.Hong, "The Mirror-based real-time dynamic projection mapping design and dynamic object detection system research," *Journal of Internet of Things and Convergence*, Vol.10, No.2, pp.85-91, 2024.
- [15] T.Heyi and B.-W.Min, "A Research on the Application of Face Recognition Algorithm Based on Convolutional Model and Transformer Model in Community Monitoring System," *Journal of Internet of Things and Convergence*, Vol.9, No.5, pp.61-72, 2023.
- [16] C.Bang and B.Kim, "Real-time Fall Accident Prediction using Random Forest in IoT Environment," *Journal of Internet of Things and Convergence*, Vol.10, No.4, pp.27-33, 2024.
- [17] J.Mok and N.Kwak, "Performance Improvement of Facial Gesture-based User Interface Using MediaPipe Face Mesh," *Journal of Internet of Things and Convergence*, Vol.9, No.6, pp.125-134, 2023.
- [18] Y.Li and B.-W.Min, "Adaptive Enhancement of Low-light Video Images Algorithm Based on Visual Perception," *Journal of Internet of Things and Convergence*, Vol.10, No.2, pp.51-60, 2024.
- [19] G.Wang, Y.Chen, P.An, H.Hong, J.Hu and T.Huang, "UAV-YOLOv8: A small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios," *Sensors*, Vol.23, No.16, p.7190, 2023.
- [20] D.Deepa, A.Sivasangari, R.Roonwal and R.Nayan, "Pothole detection using roboflow convolutional neural networks," in *Proceedings of the 2023 7th International Conference on Intelligent Computing and Control Systems (ICICCS)*, Madurai, India, 2023, pp.560-564. Dissertations.
- [21] H.-J.Gwak, Y.Jeong, I.-J.Chun and C.-H.Lee, "Estimation of fruit number of apple tree based on YOLOv5 and regression model," *Journal of IKEEE*, Vol.28, No.2, pp.28-35, 2024.
- [22] C.-M.Lee, W.-S.Jeon and S.-Y.Rhee, "A Real-time System for Judging Vehicle Loads and Overloaded using Yolo with Post-Processing Algorithm," *Journal of Korean Institute of Intelligent Systems*, Vol.33, No.5, pp.414-422, 2023.
- [23] J.M.Kang, "A Study on a Wildlife Detection and Classification Model using YOLOv5," *The Journal of Korean Institute of Information Technology*, Vol.20, No.10, pp.21-27, 2022.
- [24] L.Aziz, M.S.B.H.Salam, U.U.Sheikh and S.Ayub, "Exploring Deep Learning-Based Architecture, Strategies, Applications and Current Trends in Generic Object Detection: A Comprehensive Review," *IEEE Access*, Vol.8, pp.170461-170495, 2020.
- [25] Y.-K.Hong and T.-W.Kim, "Estimation of Populations of Moth Using Object Segmentation and an SVM Classifier," *Journal of the Korea Academia-Industrial Cooperation Society*, Vol.18, No.11, pp.705-710, 2017.
- [26] D.Park, "A Study on the Applicability of Media Videos of Deep Learning Models Related to Computer Vision," *Communication Theories*, Vol.18, No.1, pp.111-154, 2022.
- [27] J.Moon, M.Bukhari, C.Kim, Y.Nam, M.Maquood and S.Rho, "Object detection under the lens of privacy: A critical survey of methods, challenges, and future directions," *ICT Express*, Vol.10, No.5, pp. 1124-1144, 2024.
- [28] R.Kaur and S.Singh, "A comprehensive review of object detection with deep learning," *Digital Signal Processing*, Vol.132, p.103812, 2023.
- [29] J.Y.Kim, S.H.Jung and C.B.Sim, "A Study on Object Detection using Restructured RetinaNet," *Journal of Korea Multimedia Society*, Vol.23, No.12, pp.1531-1539, 2020.
- [30] H.Kim, J.Lee, J.Rew and E.Hwang, "Automated Facial Wrinkle Segmentation Scheme Using UNet++," *KSII Transactions on Internet & Information Systems*, Vol.18, No.8, 2024.
- [31] D.-H.Kim, S.-H.Yoo, S.-H.Park, D.-S.Kim and J.-M.Lee, "Design and Implementation of Real-Time Monitoring Platform for Preventing Wild Animals," *The Journal of Korean Institute of Communications and Information Sciences*, Vol.46, No.8, pp.1294-1300, 2021.
- [32] S.-M.Lee, "Wildlife Vehicle Collision in South Korea: Current Status and Factor Analysis," M.S. Dissertation, Daegu University, Daegu, Republic of Korea, 2023, Online Source.
- [33] Q.Liu, Y.Zhang and G.Yang "Small unopened cotton boll counting by detection with MRF-YOLO in the wild," *Computers and Electronics in Agriculture*, Vol.204, p.107576, 2023.
- [34] F.Ullah, J.Moon, H.Naeem and S.Jabbar, "Explainable artificial intelligence approach in combating real-time surveillance of COVID19 pandemic from CT scan and X-ray images using ensemble model," *The Journal of Supercomputing*, Vol.78, No.17, pp.19246-19271, 2022.
- [35] Campus News, The Chosun Daily [Internet], [https://lifeflearning.chosun.com/pan/site/data/html\\_dir/2024/05/31/2024053101931.html](https://lifeflearning.chosun.com/pan/site/data/html_dir/2024/05/31/2024053101931.html)

김 해 성(Haesoung Kim)

[준회원]



- 2021년 3월 ~ 현재 : 순천향대학교 AI·빅데이터학과 학사과정 재학 중

〈관심분야〉

인공지능, 컴퓨터 비전, 딥러닝, 사물인터넷, 이미지 처리

문 지 훈(Jihoon Moon)

[정회원]



- 2015년 2월 : 한성대학교 정보통신공학과 (공학사)
- 2021년 2월 : 고려대학교 전기전자공학과 (공학박사)
- 2021년 6월 ~ 2022년 8월 : 중앙대학교 박사후연구원

- 2022년 9월 ~ 현재 : 순천향대학교 AI·빅데이터학과 조교수

〈관심분야〉

지속 가능한 솔루션, 설명 가능한 인공지능, 딥러닝 응용, 데이터 마이닝, 시계열 분석 등