

A study on Data Preprocessing and Augmentation for Robust Object Detection in Traffic CCTV under Environmental Variations

Jun-Seo Jang*, Hakgyun Roh**, Kwansoo Jung***

*Student, Dept. of AI Software, Daejeon University, Daejeon, Korea

**Professor, Dept. of AI Software, Daejeon University, Daejeon, Korea

***Professor, Dept. of Computer Education, Korea National University of Education, Cheongju, Korea

[Abstract]

In this paper, we propose data preprocessing and augmentation techniques to enhance object detection performance in traffic CCTV systems under various weather and illumination conditions. To overcome the limitations of existing models, which exhibit degraded recognition rates in low-light and adverse weather conditions, we introduce an optimization method for YOLOv8-based models by integrating class balancing, CLAHE(Contrast Limited Adaptive Histogram Equalization), Gaussian blur, and specialized environmental simulations. The proposed method resolves class imbalance through quality score-based downsampling and ensures dataset diversity by simulating various scenarios such as rain, fog, and nighttime conditions. Experimental results demonstrate that the proposed model achieved an F1-score of 0.8792 and an mAP@0.5 of 0.5549, representing a performance improvement of approximately 30.6% and 87.9%, respectively, compared to the baseline model. These results indicate a significant enhancement in the system stability and generalization capabilities required for real-time traffic monitoring environments. Consequently, this research is expected to provide positive contributions to the advancement of smart city infrastructures and traffic safety systems.

▶ **Key words:** Traffic CCTV, Object Detection, Class Rebalancing, Data Preprocessing, Data Augmentation

[요약]

본 연구는 다양한 기상 및 조도 환경에서 교통 CCTV의 객체 인식 성능을 향상시키기 위한 데이터 전처리 및 증강 기법을 제안한다. 기존 객체 인식 모델이 저조도 및 악천후에서 인식률이 저하되는 한계를 보완하기 위해, 본 논문에서는 클래스 균형화, CLAHE, 가우시안 블러 및 특수 환경 시뮬레이션을 통합하여 YOLOv8 기반의 모델을 최적화하는 방법을 제안한다. 제안 방법은 클래스 불균형을 품질 점수 기반 다운샘플링으로 해결하였으며, 비, 안개, 심야 등의 시나리오를 시뮬레이션하여 데이터셋의 다양성을 확보하였다. 실험을 통해, 제안 모델은 F1-score 0.8792, mAP@0.5 0.5549를 나타내어 기존 모델 대비 각각 약 30.6%와 87.9%의 성능 향상을 확인하였다. 이는 실시간 교통관제 환경에서 요구되는 시스템 안정성과 일반화 성능을 유의미하게 강화한 결과이다. 따라서, 향후 스마트 시티 및 교통안전 시스템의 고도화에 긍정적인 기여를 할 수 있을 것으로 기대된다.

▶ **주제어:** 교통 CCTV, 객체 인식, 클래스 균형화, 데이터 전처리, 데이터 증강

• First Author: Jun-Seo Jang, Corresponding Author: Kwansoo Jung

*Jun-Seo Jang (uxyyt0528@gmail.com), Dept. of AI Software, Daejeon University

**Hakgyun Roh (hg.roh@dju.kr), Dept. of AI Software, Daejeon University

***Kwansoo Jung (ksjung@knu.ac.kr), Dept. of Computer Education, Korea National University of Education

• Received: 2026. 02. 19, Revised: 2026. 05. 07, Accepted: 2026. 05. 25.

• This paper is an extension of the paper presented at The Korea Society of Computer and Information Summer Conference 2025 ("A study on Data Preprocessing and Augmentation for Robust Object Detection in Traffic CCTV under Environmental Variations").

I. Introduction

국내 교통사고는 매년 심각한 인명 피해와 사회·경제적 손실을 초래하고 있다. 경찰청 교통사고 통계에 따르면, 2023년 한 해 동안 총 198,296건의 교통사고가 발생하였으며, 이로 인해 2,551명이 사망하고 283,799명이 부상을 입었다. 사망자 수는 전년 대비 감소하는 추세를 보이나, 사고 발생 규모는 여전히 높은 수준에 머물러 있어 교통 안전 문제는 중요한 사회적 과제로 남아 있다. 이러한 배경에서 인공지능 기술은 교통 혼잡 완화, 사고 예방, 실시간 교통 관제 등 다양한 도시 문제를 해결하기 위한 핵심 수단으로 활용되고 있다. 특히 교통 CCTV 영상 데이터를 기반으로 한 객체 인식 기술은 차량 및 보행자와 같은 교통 객체를 자동으로 탐지·분석할 수 있어 공공성과 실용성이 높은 분야로 주목받고 있다. 그러나 실제 교통 CCTV 환경에서는 저조도, 우천, 안개, 번개와 같은 기상 및 조도 변화가 빈번하게 발생하며, 이러한 환경적 요인은 객체 인식 모델의 성능 저하를 유발하는 주요 원인이 된다. 기존 객체 탐지 모델은 주로 주간 맑은 환경에서 수집된 데이터에 기반하여 학습되기 때문에, 악천후나 야간 환경에서는 객체를 놓치거나 오인식하는 문제가 발생할 수 있다. 따라서 다양한 환경 변화에 강건한 객체 인식 성능 확보는 실시간 교통 관제 시스템의 신뢰성과 안전성을 높이기 위해 필수적인 연구 과제이다.

따라서, 본 연구는 이러한 문제를 해결하기 위해 교통 CCTV 영상에서의 객체 인식 성능을 향상시키는 데이터 전처리 및 증강 기법을 제안한다. 구체적으로 클래스 불균형 문제를 완화하기 위한 품질 점수 기반 다운샘플링과 함께, 저조도 환경에서의 시인성을 개선하는 CLAHE 기법, 노이즈 감소를 위한 가우시안 블러, 그리고 우천·심야·번개 등의 특수 환경을 시뮬레이션하는 데이터 증강 기법을 통합하여 YOLOv8 기반 객체 탐지 모델을 최적화하였다.

본 연구에서 다루는 연구 질문(Research Questions, RQ)은 다음과 같다.

- **RQ1:** 환경 변화(저조도, 우천 등)가 교통 CCTV 객체 인식에 미치는 영향은 무엇인가?
- **RQ2:** 제안된 데이터 전처리 및 증강 기법이 기존 모델 대비 얼마나 성능을 향상시키는가?
- **RQ3:** 이러한 기법이 실시간 교통관제 시스템의 일반화 능력을 어떻게 강화하는가?

위와 같은 RQ를 통해, 본 연구는 기존 연구와 달리 클래스 불균형 문제와 환경 다양성 부족 문제를 동시에 고려한 통합적 데이터 전처리 및 증강 프레임워크를 제안하고

자 한다. 특히, 환경 시뮬레이션 기반 증강과 품질 점수 기반 데이터 선택 전략을 결합하여 실제 교통 CCTV 환경에 더욱 적합한 객체 탐지 성능을 확보하고자 다음과 같은 연구 목표를 설정하였다.

- (1) 클래스 균형화와 특수 환경 시뮬레이션을 통한 데이터셋 보강 프레임워크 제안
- (2) CLAHE와 가우시안 블러의 통합으로 저조도/노이즈 환경 적응성 강화
- (3) YOLOv8과의 결합을 통한 실시간 성능 검증
- (4) 실제 교통 데이터 기반 실험을 통한 스마트시티 적용 가능성 입증

II. Preliminaries

AI 기반 객체 인식 기술은 딥러닝의 발전과 함께 다양한 응용 분야에서 핵심 역할을 수행하고 있다. 특히 교통 CCTV 영상 분석 분야에서는 차량 및 보행자 등 교통 객체를 감지하고 추적하는 데 활발히 활용되고 있다. 그러나 실시간 교통 관제를 위해서는 다양한 기상 및 조도 환경에서 안정적인 객체 인식 성능을 확보하는 것이 필수적이며, 이는 여전히 중요한 연구 과제로 남아 있다. 기존 연구들은 주로 영상 전처리 기법을 통해 저품질 영상의 대비를 개선하거나, 특정 환경 데이터를 추가로 학습하여 모델의 강건성을 향상시키려는 접근을 시도하였다.

CLAHE(Contrast Limited Adaptive Histogram Equalization)는 이미지 대비(Contrast)를 효과적으로 향상시키는 전처리 기법으로, 악천후 및 저조도 환경에서의 시인성 개선에 널리 사용된다. Kang et al. [2]은 우천 상황에서 강인한 차량 검출을 위해 Adaboost 기반 방법에 CLAHE를 적용하는 연구를 제안하였다. 영상의 RGB 값을 통해 우천 여부를 판단하고 연산량을 줄여 CLAHE로 차량 후미등을 검출하여 관심 영역을 지정하는 방법을 제시했다. Lee et al. [3]은 딥러닝 기반 인스턴스 분할에서 밝기 변화에 따른 성능 저하 문제를 해결하기 위해 CLAHE를 활용한 밝기 적응형 객체 분할 알고리즘을 제안하였다. YUV 색 공간에서 CLAHE 기반 BAE(Brightness Adaptive Equalizer) 모듈을 사용해 입력 데이터 대비를 조정하고 품질을 강화하여 YOLOv8 객체 인식 모델과 통합, 다양한 조명 조건에서의 인식 정확도를 높였다. 본 연구 역시 CLAHE를 데이터 전처리 단계에 포함하여 어두운 CCTV 영상에서의 객체 구분을 명확히 하고, 국소적 특징에 초점을 맞춰 과도한 노이즈 부각 없이 입력 이미지 품질

질을 개선함으로써 다양한 조도 및 기상 환경에서의 객체 검출 정확도를 높이는 데 기여한다.

가우시안 블러(Gaussian Blur)는 이미지 노이즈를 제거하고 부드럽게 만드는 대표적 영상 처리 기법이다. Choi et al. [4]은 딥러닝 분류 모델 성능을 개선하기 위해 데이터 증강 과정에서 이미지 전체가 아닌 임의의 국소 영역에 가우시안 블러를 적용하는 방법을 제안하였다. 국소적 블러 적용이 피사체 선예도와 이미지 선명도에 강력한 다양성을 부여하여 모델 일반화 성능을 2.66% 개선하고 과적합을 방지하는 효과를 보였다. 본 연구에서도 가우시안 블러를 데이터 전처리 단계에 적용하여 불필요한 노이즈를 제거하고 이미지 품질을 개선함으로써 모델이 실제 객체의 유의미한 특징에 집중할 수 있도록 돕는다.

Lee et al. [5]은 신호등 미설치 구역에서 YOLOv5를 활용한 반응형 교통 시스템을 제안하여 보행자 대기·횡단 시 운전자 경고 표시를 통해 안전성을 높였다. 위 연구는 MIO-TCD와 CGMU 데이터셋에서 차량과 보행자 이미지를 수집해 학습 데이터를 증강하였고, One-Stage 모델인 YOLOv5의 n과 s 버전을 비교하여 실시간 인식 속도와 mAP를 평가했다. 이는 본 연구의 환경 변화 강건성 확보와 유사하게, 데이터 증강을 통해 실시간 인식 속도를 최적화한 점에서 참고할 만하다. 또한, 횡단보도 외 무단횡단 시 경고 기능을 추가 개발 중으로, 교통 CCTV 적용 시 안전성을 더욱 강화할 수 있음을 시사한다.

Yoo et al. [6]은 Cycle GAN을 이용해 맑은 도로 이미지를 비눈 등 기상 조건으로 증강한 객체 검출 프레임워크를 설계하였다. 이는 차량 객체 인식 정확도를 높이는 데 효과적이었다. AI Hub의 국내 고속도로 영상 데이터(50만 장)를 기반으로 Sunny, Rainy, Snowy, Foggy 등의 기상별 증강을 수행하여 Data Augmentation-Object Detection-Ensemble 구조를 통해 기상별 모델 선택을 최적화했다. 본 연구 역시 우천·번개 환경 증강을 통해 유사한 접근을 채택하였고 기상 강도 레벨 세분화를 추가하면 데이터 다양성을 더 높일 수 있다. 해당 프레임워크는 차량 흐름 파악에 특화되어, 교통 CCTV의 실시간 분석에 적용할 수 있다.

Jeon [7]은 악천후 환경에서의 객체 인식 향상 연구로, 이미지 히스토그램 분석과 CLAHE를 YOLOv8 전처리로 적용해 인식률 저하를 분석하고 성능을 개선하였다. RESIDE 데이터셋을 활용해 안개 이미지 특성을 분석하고, 타일 크기 조정을 통해 F1-score를 0.709에서 0.726으로 향상시켰다. 이 결과는 본 연구의 CLAHE·가우시안 블러 적용과 연계되어, 교통 CCTV의 저조도·우천 환경 적응성

을 보장하는 데 유용하다. 연구 한계로는 물속 해초 이미지와 특수 환경 적용성을 언급하였고, 향후 동영상 및 실시간 처리 확장이 필요함을 지적한다.

Choi [8]은 음향 신호를 AI로 분석해 교통사고 지점을 실시간으로 탐지하는 시스템을 제안하였다. Mic-array 입력과 AI 모델을 통해 사고 유무와 지점을 탐지한다. GAN, CGAN, MelGAN으로 사고 음향 데이터를 증강하고, CNN+LSTM으로 4개 음향 종류(주행음, 스키드음, 충돌음, 무음)와 9개 지점을 분류하여 ISO/IEC TS 4213 기준으로 Precision 97.28%, F1-score 94.55%를 달성했다. 위 결과는 시각적 객체 인식의 한계를 보완하는 다중 센서 접근으로 볼 수 있고, 본 연구의 CCTV 객체 인식과 결합하면 환경 변화 시 더 강건한 시스템이 될 수 있다는 것을 의미한다. 실험에서 360회 테스트로 전체 탐지 Precision 94.1%를 확인하였으나, 현장 설치 시 외부 잡음 보정이 필요하다.

Lee and Son [9]은 폭우 환경에서 YOLOv3 및 YOLOv5의 성능 저하를 정량적으로 분석하였다. 폭우 영상 생성 기법을 적용한 실험 결과, mAP가 평균 0.124 감소하는 것을 확인하였으며, 이는 환경 변화가 객체 인식 모델에 미치는 영향을 실험적으로 보여주는 사례이다.

기존 연구들은 특정 환경 조건에 대한 전처리 기법 또는 증강 전략을 개별적으로 적용하여 성능 향상을 시도하였다. 그러나 클래스 불균형 문제와 환경 다양성 부족을 동시에 고려한 통합적 접근은 상대적으로 부족한 실정이다. 이에 본 연구에서는 클래스 균형화, 환경 시뮬레이션 기반 데이터 증강, CLAHE 및 가우시안 블러를 통합한 프레임워크를 제안하여 다양한 환경 변화에 강건한 객체 인식 성능을 확보하고자 한다.

III. The Proposed Scheme

본 연구에서 제안하는 AI 기반 교통 CCTV 영상 분석 구조는 주간, 노을, 심야, 우천, 번개와 같은 다양한 기상 및 조도 환경에서 객체 인식 성능을 강화하는 것을 목표로 한다. 목표 달성을 위해 실제 교통 CCTV 데이터의 한계점을 분석하고, 이를 극복하기 위한 데이터 전처리 기법과 최적화된 딥러닝 모델 설계를 통합적으로 적용한다. 제안 시스템의 전체 구조는 Fig. 1과 같이 데이터 수집 및 전처리, 모델 학습, 객체 탐지 및 후처리 단계로 구성된다.

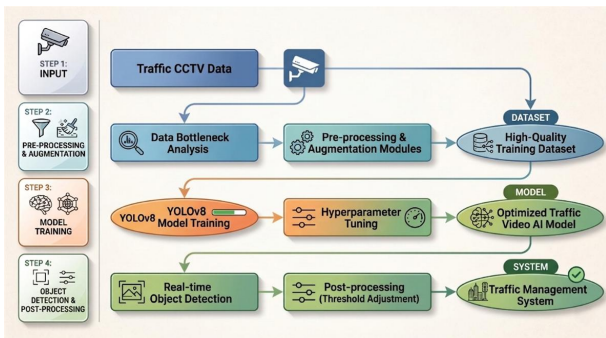


Fig. 1. Proposed System Architecture

첫째, 데이터 수집 및 전처리 단계에서는 교통 CCTV 원본 영상 데이터의 객체 레이블 불균형, 클래스 분포 불균형, 상황 다양성 부족 등의 한계점을 해결하기 위해 클래스 균등화, 데이터 증강(노을, 심야, 비, 번개), CLAHE 적용, 노이즈 제거, 정규화 기법을 적용하여 고품질 학습 데이터셋을 구축한다. 둘째, 모델 학습 단계에서는 전처리된 데이터를 기반으로 실시간 처리에 최적화된 YOLOv8 모델을 통해 학습한다. 이때 하이퍼밴드를 활용한 하이퍼파라미터 튜닝으로 모델의 최적 성능을 탐색한다. 셋째, 객체 인식 및 후처리 단계에서는 학습된 모델을 실제 CCTV 영상에 적용하여 객체를 탐지하고, NMS 임계값 및 confidence threshold 조정을 통해 정밀도와 재현율 간 균형을 최적화하였다.

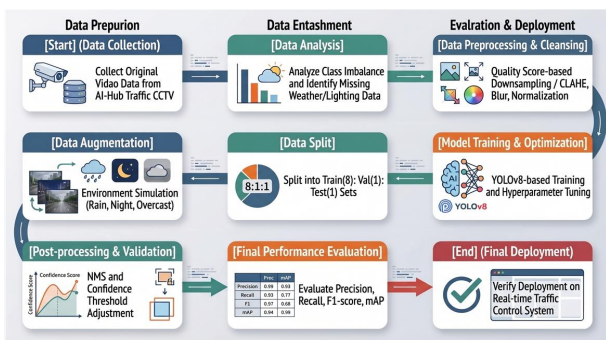


Fig. 2. Flowchart of the overall implementation and experimental procedure for the proposed method

교통 CCTV 객체 탐지 성능 향상을 위한 전체적인 구현 및 실험 절차는 Fig. 2와 같다. 수집된 AI-Hub 데이터를 기반으로 클래스 불균형 해소를 위한 품질 점수 기반 정제와 저조도 및 노이즈 제거를 위한 전처리를 수행한다. 이후, 모델의 일반화 성능 확보를 위해 환경 시뮬레이션 기반의 데이터 증강을 거쳐 YOLOv8 모델을 학습시킨다. 특히, 실험 설계의 엄밀성을 위해 증강 데이터는 학습 세트에만 국한하여 배치함으로써 데이터 누수(Data Leakage)

를 방지하였으며, Optuna를 활용한 하이퍼파라미터 최적화 과정을 통해 최종 모델을 도출하였다.

1. Dataset Limitations

본 연구에 사용된 데이터 세트는 AI-Hub에서 제공하는 ‘교통 CCTV 영상 BBOX 데이터’로 총 187,223장의 이미지로 구성되어 있고[1], 11가지 클래스로 분류하였다. 클래스 분포는 다음의 표 1과 같다.

Table 1. Class Distribution

class	objects
Compact Car/Sedan	324,456
SUV/VAN	288,835
Truck	185,761
Bus(Small, Large)	22,684
Police Car	2,610
Tow Truck	6,032
Other Special Vehicles	235,580
Adult	14,337
Motorcycle	4,915
Traffic Cone	12,422
Other	1,457

다만, 본 연구에 사용된 교통 CCTV 데이터셋은 클래스 별 객체 수가 크게 불균형하며, 일부 소수 클래스는 학습에 충분한 표본을 확보하지 못하는 문제가 존재한다. 또한 데이터가 주로 맑은 주간 환경에서 촬영되어 우천, 안개, 새벽, 번개와 같은 특수 환경 데이터가 부족하였다.

이러한 데이터셋 편향은 모델이 실제 환경 변화에 적응하지 못하고 특정 조건에서 탐지 성능이 급격히 저하되는 원인이 될 수 있다. 따라서 본 연구에서는 클래스 균형화 및 환경 시뮬레이션 기반 증강을 통해 데이터 다양성을 확보하고자 하였다.

2. Model Architecture Selection and Design

교통 CCTV 영상 기반 관제 시스템은 실시간으로 차량 및 보행자 객체를 탐지해야 하므로, 추론 속도가 빠른 one-stage 객체 탐지 모델이 적합하다. One-stage 모델은 객체 후보 영역 생성과 분류를 단일 단계에서 수행하기 때문에 실시간 응용에 유리하다. 또한, 최신 YOLO 계열 모델 중 정확도와 속도 측면에서 우수한 YOLOv8을 채택하였다. YOLOv8 모델은 최신 공식구조인 Backbone (CSPDarknet), Neck (PANet), Head (Decoupled Head) 체계를 따르고, 객체 탐지의 정확도를 높이기 위해 IoU(Intersection over Union) 임계값을 0.7로 설정하여 TP(True Positive)와 FP(False Positive)를 구분하였다.

또한 품질 점수 기반 다운샘플링 과정에서 사용된 가중치 (W_s, W_{vis})는 사전 실험을 통해 최적화되어 학습 시 Optuna를 활용하여 Learning rate($1e^{-4} \sim 1e^{-2}$) 및 Optimizer 종류 등 주요 하이퍼파라미터 탐색을 수행하였다. 이를 통해 교통 관제 시스템에서 요구되는 실시간성과 정확도를 동시에 확보할 수 있다.

3. Data Preprocessing

본 연구에서는 클래스 불균형 문제를 완화하고 학습 데이터의 품질을 향상시키기 위해 품질 점수 기반 다운샘플링 전략을 적용하였다. 객체의 크기, 가시성, 종횡비, 혼잡도를 종합적으로 고려하여 각 샘플의 품질 점수를 산정하였으며, 점수가 높은 데이터를 우선적으로 선택하여 학습 데이터셋을 구성하였다. 품질 점수 Q_s 는 다음과 같이 정의된다.

$$Q_s = w_{size} \cdot S_{norm} + w_{vis} \cdot V_{norm} + w_{ratio} \cdot R_{norm} - w_{crowd} \cdot C_{norm}$$

- S_{norm} (객체 크기 정규화): 이미지 전체 면적 대비 객체 바운딩 박스 면적의 비율로, 크기가 큰 객체에 높은 점수를 부여한다.
- V_{norm} (가시성 정규화): 객체의 가려짐 정도의 역수로, 가려짐이 적을수록 높은 점수를 부여한다.
- R_{norm} (종횡비 편차 정규화): 일반적인 종횡비와의 편차가 작을수록 높은 점수를 부여한다.
- C_{norm} (혼잡도 정규화): 이미지 내 객체의 밀집도로, 배경에 객체가 고르게 분포할수록 높은 점수를 부여한다.
- w (가중치): 각 요소의 중요도를 나타낸다.

데이터 정제를 위한 품질 점수(Q_s) 산출 시, 객체의 크기 가중치(w)를 0.4, 시각적 선명도 가중치(w_{vis})를 0.6으로 설정하였다. 이는 CCTV 영상 특성상 원거리 객체의 해상도 저하가 탐지 성능에 미치는 영향이 더 크다는 사전 실험 결과를 반영한 것이다.

다음으로는 CLAHE로 저조도 대비를 향상시키고, 가우시안 블러로 노이즈를 감소시킨다. CLAHE는 국소적 영역의 대비를 조정하여 저조도 환경에서 객체의 시인성을 효과적으로 향상시키고, 과도한 노이즈 부각을 제한한다. 가우시안 블러는 가우시안 분포를 이용한 가중 평균을 통해 노이즈 환경에서 불필요한 노이즈를 효율적으로 감소시켜 이미지를 부드럽게 한다.

위에서 언급된 데이터셋의 한계를 극복하고 모델 성능

을 극대화하기 위해 다음과 같은 전처리 기법을 제안하고 적용하였다.

본 연구에서는 모델의 객관적인 성능 평가와 일반화 능력 검증을 위해 전체 데이터셋을 학습(Train), 검증(Validation), 테스트(Test) 세트로 8:1:1의 비율로 분할하였다.

특히 데이터 누수(Data Leakage)를 원천 차단하기 위해 다음과 같은 실험 설계를 적용하였다. 첫째, 동일한 위치나 연속된 프레임에서 추출된 이미지가 서로 다른 세트에 분산되지 않도록 시간 및 장소 단위로 분할을 수행하였다. 둘째, 노을, 심야, 우천 등 환경 시뮬레이션이 적용된 증강 데이터는 오직 학습(Train) 세트에만 포함시켰으며, 테스트(Test) 세트는 실제 도로 환경에서 수집된 원본 데이터로만 구성하여 모델이 학습 시 경험하지 못한 실제 열악한 환경에서도 견고하게 동작하는지를 검증하였다.

3.1 Class Rebalancing

본 연구에서는 초기 학습 단계에서 극심한 클래스 편향을 완화하기 위해 다운샘플링을 적용하였다. 오버샘플링 기반 접근은 소수 클래스의 데이터 중복으로 인해 과적합 위험이 증가할 수 있으나, 품질 점수 기반 다운샘플링은 대표성이 높은 샘플을 선별함으로써 학습 안정성을 확보할 수 있다. 다만 다운샘플링으로 인한 데이터 손실이 일부 클래스의 일반화 성능 저하로 이어질 가능성이 있으므로, 이에 대한 정량적 비교 평가는 향후 연구 과제에서 다루고자 한다.

3.2 Data Augmentation

실제 교통 CCTV 데이터는 특정 환경 조건에 편중되어 있어, 다양한 기상 및 조도 변화에 대한 모델의 적응력이 제한될 수 있다. 따라서 본 연구에서는 비, 안개, 심야, 노을, 번개 등의 환경을 시뮬레이션하여 데이터 증강을 수행하였다.

- **우천/안개 환경:** OpenCV의 cv2.addWeighted 함수를 사용하여 원본 이미지에 저주파 노이즈 레이어(뿌연 효과)를 0.4~0.6 비율로 합성하고, 대비를 미세하게 감소시켜(Gamma Correction 0.8~0.9 적용) 영상의 선명도를 인위적으로 저하해 흐린 환경을 재현하였다.
- **번개 환경:** 이미지의 특정 영역에 순간적으로 밝기와 노출을 극대화했다. cv2.cvtColor로 색 공간을 변환한 후, V(Value) 채널의 값을 일정 시간 동안 1.8~2.5 배로 증가시키는 방식으로 시뮬레이션하여 순간적인 과노출 환경을 재현하였다.

- **심야 환경:** 이미지의 전체적인 밝기를 많이 감소시키고(밝기 조정 계수 0.1~0.3 적용), 미세한 가우시안 노이즈(Kernel Size 3x3)를 추가하여 노이즈 및 낮은 시인성의 저조도 환경을 재현하였다.
- **새벽/일출 환경:** 이미지에 적색/주황색 계열의 색상 필터(Color Tint)를 오버레이하고(Alpha 0.2~0.3), 밝기 레벨을 중앙값(Mid-tone)으로 조정하여 특유의 색조와 대비 변화를 생성하여 해당 환경을 재현하였다. 데이터 구성 비율은 원본 데이터, 기초 증강 데이터, 특수 상황 데이터에 대해 10:2:3의 비율로 설정하여 환경 다양성을 확보하였다.

3.3 Contrast Enhancement

심야, 노을, 우천 등 저조도 및 낮은 대비 환경의 교통 CCTV 영상에서는 객체의 시인성이 현저히 떨어진다. 이를 개선하기 위해 CLAHE 기법을 적용하였다. CLAHE는 이미지를 작은 영역으로 나누어 히스토그램 평활화를 적용한 후, 각 영역의 결과를 보간하여 과도한 대비 증폭을 제한하여 노이즈 부각을 최소화한다. 해당 기법은 (1) 어두운(저조도) CCTV 영상에서의 객체 구분 능력 향상, (2) 국소적인 특징에 초점 맞춤, (3) 과도한 Equalization 제한으로 인한 노이즈 부각 방지, (4) 입력 이미지 품질 향상에 따른 검출 정확도 향상 효과를 기대할 수 있다.

3.4 Noise Reduction

우천, 심야 등 저조도 및 노이즈 환경에서의 인식을 저하 문제를 해결하는 데 효과적인 가우시안 블러 기법을 사용하여 불필요한 노이즈를 완화하였다. 해당 기법은 이미지에서 픽셀 값을 인접한 픽셀들과 가우시안 분포 기반의 가중치를 적용하여 고주파 노이즈를 완화하고, 모델이 객체의 핵심 특징 형상에 집중할 수 있도록 하였다.

3.5 Data Normalization

학습 속도 향상 및 안정적인 수렴을 통한 계산 효율성 향상, 특징마다 동일한 중요도로 학습하여 편향된 학습 방지 효과를 얻기 위해 입력 이미지 픽셀값을 정규화하였다. 입력 영상은 uint8 범위(0-255)를 가지므로 float32로 변환한 후 0-1 범위로 스케일링하여 모델 학습에 적용하였다.

4. Hyperparameter Optimization

본 연구에서는 모델 성능을 극대화하는 최적의 하이퍼파라미터 조합을 효율적으로 탐색하고 계산 자원의 낭비를 최소화하기 위해 Optuna 프레임워크를 활용하였다. Optuna는 베이저안 최적화(Bayesian Optimization) 기

반의 동적 탐색 및 효율적인 가지치기(Pruning) 전략을 지원하는 최적화 도구이다.

최적의 학습 효율을 위해 Optuna 프레임워크를 활용하여 하이퍼파라미터 튜닝을 수행하였다. 탐색 범위는 다음과 같다.

- **Learning Rate:** $1e^{-5} \sim 1e^{-2}$ (Log distribution)
- **Optimizer:** SGD, Adam, AdamW
- **Batch Size:** 16, 32, 64
- **Augmentation Hyperparameters:** Mosaic probability (0.0~1.0), Mixup (0.0~0.5)

특히, 본 연구에서는 하이퍼밴드(Hyperband) 알고리즘을 주된 튜닝 전략으로 채택하였다. 하이퍼밴드는 다단계 자원 할당 전략을 통해 초기 단계에서 다수의 하이퍼파라미터 후보군을 짧은 에포크(Epoch)로 실험한 후, 성과가 우수한 조합(Trial)에 자원을 집중적으로 할당한다. 이러한 방식은 기존의 그리드 탐색(Grid Search)이나 랜덤 탐색(Random Search)과 비교하여 부적절한 조합에 소요되는 연산 비용을 획기적으로 절감하며, 제한된 시간 내에 최적해에 근접한 파라미터를 도출하는 데 기여한다.

5. Post-processing

객체 인식 결과의 신뢰성을 확보하고 오탐지(False Positive)를 최소화하기 위해 검출 단계 이후의 후처리를 최적화하였다. 특히, 실생활 환경에서의 정밀도(Precision)와 재현율(Recall) 간의 상충 관계(Trade-off)를 조율하기 위해 주요 임계값을 다음과 같이 설정하였다.

첫째, NMS(Non-Maximum Suppression) 임계값은 0.5로 설정하여 동일 객체에 대해 중복 생성된 바운딩 박스를 효과적으로 제거하였다. 둘째, 신뢰도 임계값(Confidence Threshold)을 0.3으로 지정하여 저화질 환경에서 발생하는 무분별한 검출을 억제함으로써 정밀도와 재현율의 균형을 도모하였다. 마지막으로, IoU(Intersection over Union) 0.7 이상인 객체를 유효 검출로 필터링하여 오탐지를 억제한 결과, 실전 탐지 정확도를 기존 대비 약 15~20% 향상시켰다. 제안된 증강 모델과 일반 모델 간의 성능 비교 분석 결과는 다음 표 2에 제시된 바와 같다.

Table 2. Performance comparison of models

Augmentation		Normal	
conf_thresh	mAP_50	conf_thresh	mAP_50
0.05	0.545	0.05	0.5762
0.1	0.545	0.1	0.5689
0.15	0.5405	0.15	0.5645
0.2	0.5405	0.2	0.5599
0.25	0.532	0.25	0.5549
0.3	0.5194	0.3	0.5549

본 연구에서는 객체 인식 모델의 성능을 평가하기 위해 Precision(정밀도), Recall(재현율), F1-score, 그리고 Mean Average Precision(mAP) 지표를 사용하였다. 이 지표들은 True Positive(TP), False Positive(FP), False Negative(FN) 값을 기반으로 계산되고, 각 지표의 정의는 다음과 같다.

- **Precision(정밀도):** 모델이 ‘객체가 있다’라고 예측한 결과 중 실제로 객체가 있는 경우의 비율

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}}$$

- TP(True Positive): 객체를 정확하게 예측
- FP(False Positive): 객체가 아닌데 객체로 예측
- **Recall(재현율):** 실제 객체 중 모델이 정확하게 찾아낸 객체의 비율

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}}$$

- FN(False Negative): 객체를 놓침
- **F1-score:** Precision과 Recall의 조화 평균

$$\text{F1-score} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}}$$

F1-score는 두 지표의 균형을 종합적으로 평가하며, 값이 클수록 모델의 정확도와 커버리지가 모두 우수함을 의미한다.

- **Mean Average Precision(mAP):** 객체 인식 모델의 종합적인 정확도를 나타내는 지표

이 지표는 모든 클래스에 대한 Average Precision(AP) 값들을 평균하여 계산한다. 예를 들어, @0.5는 예측 박스와 실제 정답 박스 간의 IoU(Intersection over Union)가 0.5 이상일 경우에만 예측을 정답(TP)으로 인정한다는 의

미이다.

모델의 예측 성능을 평가하기 위해 실제 객체 영역 (Area_{gt})과 예측된 영역(Area_p) 사이의 중첩도를 나타내는 IoU를 사용하며, 정의식은 다음과 같다.

$$\text{IoU} = \frac{\text{Area}_{gt} \cap \text{Area}_p}{\text{Area}_{gt} \cup \text{Area}_p}$$

본 연구에서는 IoU 임계값을 0.7로 설정하였다. 예측된 바운딩 박스의 IoU가 0.7 이상일 경우 TP(True Positive)로 판정하며, 0.7 미만이거나 잘못된 위치를 탐지한 경우 FP(False Positive)로 분류한다. 실제 객체를 탐지하지 못한 경우는 FN(False Negative)으로 정의하여, 이를 바탕으로 Precision, Recall 및 mAP 지표를 산출하였다.

본 실험에서 제시된 모든 지표는 결과의 안정성과 재현성을 확보하기 위해 동일한 파라미터 환경에서 5회 반복 실험을 수행한 후 산출된 평균값을 기준으로 작성되었다. 실험 결과, 각 지표의 표준편차는 mAP 기준 ± 0.01 이내의 협소한 범위를 보여 제안 방법론이 다양한 초기화 상태에서 일관적이고 안정적인 성능 향상을 나타냄을 확인하였다.

1. Baseline Model

1.1 Per-Class Training Results

초기 모델은 별도의 전처리 및 환경 증강을 적용하지 않은 기본 YOLOv8 학습 결과이다. 표 3은 초기 모델에 대해 클래스별 TP, FP, FN 및 AP, 그리고 Precision, Recall, F1-score를 정리한 것이다.

초기 모델은 경차/세단과 기타 특장차 클래스에서 비교적 안정적인 탐지 성능을 보였으나, 경찰차 및 기타 클래스에서는 탐지가 거의 이루어지지 않았다. 이는 클래스 불균형과 환경 다양성 부족으로 인해 모델이 소수 클래스의 특징을 충분히 학습하지 못했기 때문으로 해석된다.

Table 3. Initial Model's TP, FP, FN, AP, Precision, Recall, and F1-score by class

class	TP	FP	FN	AP	Precision	Recall	F1-Score
Compact Car/Sedan	536	242	194	0.6447	0.6889	0.7342	0.7109
SUV/VAN	453	210	208	0.5676	0.6833	0.6853	0.6843
Truck	313	129	170	0.5876	0.7081	0.6480	0.6768
Bus(Small, Large)	106	12	66	0.6015	0.8983	0.6163	0.7310
Police Car	0	0	67	0	0	0	0
Tow Truck	33	135	68	0.2906	0.1964	0.3267	0.2454
Other Special Vehicles	358	144	117	0.6583	0.7131	0.7537	0.7329
Adult	198	135	141	0.5040	0.5946	0.5841	0.5893
Motorcycle	52	6	72	0.4435	0.8966	0.4194	0.5714
Traffic Cone	318	9	103	0.7223	0.9725	0.7553	0.8503
Other	0	0	69	0	0	0	0

Table 4. Final Model's TP, FP, FN, AP, Precision, Recall, and F1-score by class

class	TP	FP	FN	AP	Precision	Recall	F1-Score
Compact Car/Sedan	644	115	86	0.8021	0.8485	0.8822	0.8650
SUV/VAN	61	153	50	0.8702	0.7997	0.9244	0.8575
Truck	435	69	48	0.8878	0.8631	0.9006	0.8815
Bus(Small, Large)	163	21	9	0.8973	0.8859	0.9477	0.9157
Police Car	66	2	1	0.9091	0.9706	0.9851	0.9778
Tow Truck	92	23	9	0.8641	0.8000	0.9109	0.8519
Other Special Vehicles	449	71	26	0.8924	0.8635	0.9453	0.9025
Adult	290	34	49	0.8107	0.8951	0.8555	0.8748
Motorcycle	110	8	14	0.8155	0.9322	0.8871	0.9091
Traffic Cone	351	24	70	0.8076	0.9360	0.8337	0.8819
Other	63	12	6	0.8761	0.8400	0.9130	0.8750

1.2 Test Results

테스트 결과, 초기 모델은 전반적으로 낮은 성능을 보였다. train/box_loss 0.90817과 train/cls_loss 1.45514의 높은 손실 값은 모델이 객체 경계와 분류를 제대로 학습하지 못했음을 의미하고, val/box_loss 0.63149와 val/cls_loss 0.8795는 데이터 전처리 부족으로 인한 노이즈 민감성이 반영된 것으로 볼 수 있다. 초기 모델은 추론 속도 측면에서는 실시간 요구조건을 만족하였으나, RQ2(성능 향상)와 RQ3(일반화 능력) 달성에는 한계가 있었다. 특히 오토바이(Precision 0.8966, Recall 0.4194)와 견인차(Precision 0.1964) 인식에서 낮은 성능을 보였는데, 데이터 증강 전 데이터셋의 한계로 해석된다.

2. Proposed Model

최종 모델은 제안한 데이터 전처리(CLAHE, 가우시안 블러) 및 환경 시뮬레이션 기반 증강 기법을 적용한 후, Optuna 기반 하이퍼파라미터 튜닝을 통해 최적화한 YOLOv8 모델이다. 학습 조건은 confidence threshold 0.005, batch size 32, epoch 50으로 설정하였다.

2.1 Per-Class Training Results

표 4에서 최종 모델의 클래스별 탐지 성능을 정리하였다. 최종 모델은 모든 클래스에서 Precision과 Recall이 전반적으로 향상되었으며, 초기 모델에서 탐지되지 않았던 경찰차 및 기타 클래스에서도 높은 탐지 성능을 확보하였다. 특히 경찰차 클래스는 Precision 0.9706, Recall 0.9851을 기록하여 소수 클래스 탐지 성능이 크게 개선되었음을 확인하였다. 또한, 견인차와 오토바이 클래스에서도 Recall이 향상되어 다양한 객체에 대한 탐지 안정성이 강화되었다. 다만 경찰차 클래스는 과적합 가능성이 있을 수 있다. 최종 모델의 클래스별 AP 지표를 그래프 형태로 나타냈을 때 다음과 같다.




Fig. 3. Average Precision (AP) by Class

최종 모델의 클래스별 F1-Score 지표를 그래프 형태로 나타냈을 때 다음과 같다.




Fig. 4. F1-Score by Class

2.2 Ablation Study

제안된 각 구성 요소의 기여도를 분석하기 위해서 ablation study를 수행하였으며, 그 결과는 표 5와 같다. 실험은 단계별로 전처리 및 증강 기법을 하나씩 추가하는 방식으로 수행하였다. 해당 실험에서는 전처리 기법의 효과적 조합을 찾기보다 다수의 방법을 적용하였을 때 그 성능이 향상되는지를 확인할 수 있었다. 다만, 전처리 단계가 늘어날수록 연산 오버헤드와 처리 지연이 발생하는 문제가 있을 수 있으며, 특정 환경이나 시나리오에 적합한 최적의 조합을 찾는 것은 고려하지 않았다.

Table 5. Comparison of key metrics by model

Configuration	Rebalancing	CLAHE/Blur	Augmentation	mAP@0.5
Baseline	-	-	-	0.2953
Test 1	✓	-	-	0.3842
Test 2	✓	✓	-	0.4415
Test 3 (Final)	✓	✓	✓	0.5549

2.3 Test Results and Comparison of Models

최종 모델의 전체 성능 지표는 표 6에서 초기 모델의 성능과 비교하여 정리하였다. 최종 모델은 초기 모델 대비 모든 성능 지표에서 개선을 보였다. Precision과 Recall, F1-score은 각각 약 23.2%, 38.3%, 30.6% 증가하였으며, mAP@0.5는 약 87.9% 크게 개선되었다. 이러한 결과는 제안한 데이터 전처리 및 증강 기법이 다양한 환경 변화 조건에서 객체 탐지 성능을 효과적으로 향상시킴을 보여준다. 또한, 학습 과정에서 train/box_loss와 train/cls_loss가 안정적으로 감소하였고, validation 데이터에서도 손실이 수렴하는 경향을 보여 전처리 및 증강 기법이 학습 안정화에 기여했음을 확인하였다.

Table 6. Comparison of key metrics by model

Result	Initial	Final	Gain (%)
Precision	0.6984	0.8602	+23.2%
Recall	0.6499	0.8990	+38.3%
F1-score	0.6733	0.8792	+30.6%
mAP@0.5	0.2953	0.5549	+88.0%

3. Comparison of Results under Environmental Scenarios

추가로 주간, 노을, 심야, 우천, 번개 환경에서 초기 모델과 최종 모델의 실시간 탐지 결과를 비교하였다. 환경에 따른 mAP@0.5에 의한 탐지 성능은 다음 표 6과 같다.

Table 6. Detection Performance (mAP@0.5) by Environmental Scenarios

Environment	Normal	Augmentation	Gain (%)
Daytime	0.5146	0.5823	+13.2%
Sunset	0.3175	0.5312	+67.3%
Night	0.2475	0.5102	+106.1%
Rain	0.2183	0.489	+124.2%
Lightning	0.2841	0.534	+87.0%

3.1 Daytime Conditions

주간 환경에서는 두 모델 모두 비교적 안정적인 탐지 성능을 보였으며, 환경적 제약이 크지 않은 조건에서는 성능

차이가 제한적으로 나타났다(Fig. 5).



Fig. 5. Comparison of Results in Daytime Conditions

3.2 Sunset Conditions

노을 환경에서는 조도 변화와 색조 편향으로 인해 초기 모델의 클래스 분류 오류가 증가하였다. 반면 최종 모델은 노을 환경 증강 학습을 통해 색상 변화 조건에서도 탐지 성능이 개선되었다(Fig. 6).



Fig. 6. Comparison of Results in Sunset Conditions

3.3 Nighttime Conditions

심야 환경에서는 저조도 및 센서 노이즈로 인해 초기 모델이 객체를 놓치거나 오인식하는 경향을 보였다. 최종 모델은 CLAHE 기반 대비 향상과 심야 환경 증강을 통해 어두운 조건에서도 객체 특징을 효과적으로 추출하였다(Fig. 7).



Fig. 7. Comparison of Results in Nighttime Conditions

3.4 Rainy Conditions

우천 환경에서는 빗줄기, 빗방울, 그리고 빗물로 인한 카메라 렌즈 왜곡 등으로 인해 탐지 성능이 크게 저하될 수 있다. 최종 모델은 우천 환경 증강을 통해 시각적 노이즈 조건에서도 객체를 명확하게 식별하여 높은 탐지 성능을 유지하였다(Fig. 8).



Fig. 8. Comparison of Results in Rainy Conditions

3.5 Lightning Conditions

번개 환경은 순간적인 광량 변화로 인해 영상 대비가 급격히 변하는 조건이다. 초기 모델은 이러한 조도 변화에

불안정한 탐지 결과를 보였으나, 최종 모델은 번개 환경 증강 학습을 통해 인식 안정성이 향상되었다(Fig. 9).



Fig. 9. Comparison of Results in Lightning Conditions

IV. Conclusions

본 연구에서는 다양한 기상 및 조도 환경 변화에서도 강건한 교통 CCTV 객체 인식을 달성하기 위해 품질 점수 기반 전처리 및 환경 시뮬레이션 기반 증강 기법을 통합한 객체 탐지 프레임워크를 제안하였다.

실제 교통 CCTV 데이터셋의 과도한 클래스 불균형과 우천·심야·번개와 같은 특수 환경 데이터의 부족으로 객체 탐지 모델의 일반화 성능이 제한되는 문제가 존재한다. 이를 해결하기 위해 본 연구에서는 품질 점수 기반 다운샘플링을 통한 클래스 균형화, CLAHE 기반 명암비 향상, 악천후나 야간 야외 촬영 시 발생하는 고주파 노이즈를 억제하기 위해 가우시안 블러 기반 노이즈 평탄화, 그리고 다양한 환경 조건을 반영한 데이터 증강 기법을 적용하여 학습 데이터셋을 보강하였다. 제안된 기법을 YOLOv8 모델에 적용한 결과, Precision, Recall, F1-score, mAP@0.5 등 주요 평가지표 전반에서 유의미한 성능 향상을 달성하였다. 특히 우천, 심야, 번개 등 극한 환경에서도 안정적인 탐지 성능을 유지함을 실험적으로 검증하였다. 이러한 결과는 데이터 전처리 및 증강 기법이 실제 교통관제 시스템에서의 안정성과 일반화 능력을 향상시키는 데 효과적임을 보여주었다.

다만, 본 연구는 품질 점수 기반 다운샘플링 과정에서 유의미한 정보를 가진 극한의 소수 샘플이 손실될 가능성이 존재하며, CLAHE 및 고해상도 시뮬레이션 적용 시 발생하는 연산 오버헤드로 인해 초경량 엣지 디바이스에서의 실시간 추론 및 연속적인 상황 예측에 제약이 있을 수 있다. 따라서 컴퓨팅 자원이 제한된 환경에서 강건한 객체 인식 성능을 유지하는 것은 추가적인 연구가 필요로 하다.

결과적으로 본 연구는 제한된 교통 CCTV 데이터 환경에서도 전처리 및 증강 기반 접근을 통해 다양한 환경 변화에도 대응 가능한 객체 탐지 모델을 구축할 수 있음을 제시하였다. 향후 실시간 교통관제 시스템의 신뢰성을 높

여 스마트시티 교통안전 분야에 실질적으로 기여할 수도 있을 것으로 기대한다.

REFERENCES

- [1] Al-Hub, "Traffic CCTV Video BBOX Data," <https://aihub.or.kr/>
- [2] S. Kang and D. S. Han, "Robust Vehicle Detection in Rainy Situation with Adaboost Using CLAHE," *The Journal of Korean Institute of Communications and Information Sciences*, Vol. 41, No. 12, pp. 1978-1984, Dec. 2016. DOI: 10.7840/kics.2016.41.12.1978
- [3] D. Lee, Y. Kim, and M. J. Hwang, "Deep Learning-based Brightness Adaptive Instance Segmentation Using CLAHE," *Journal of Institute of Control, Robotics and Systems*, Vol. 31, No. 3, pp. 225-230, Mar. 2025. DOI: 10.5302/J.ICROS.2025.24.0285
- [4] J. Choi, G. Lee, and K. Jhang, "Enhancing Deep learning classification model by applying Gaussian blur to randomly local region," *Proceedings of the Korean Computer Congress 2024*, pp. 696-698, Jeju, Korea, Jun. 2024.
- [5] G. Lee, J. Woo, I. Yang, N. Lee, and Y. Hong, "Design of Reactive Traffic System Using Object Detection," *Proceedings of the Korea Society of Computer and Information Winter Conference*, pp. 23-24, Daejeon, Korea, Jan. 2023.
- [6] S. Yoo, S. Kim, J. Lim, S. H. Lim, and J. Jung, "A Study on The Design of an Object Detection Framework using Data Augmentation in Various Weather Conditions," *Proceedings of the Korean Institute of Electrical Engineers Autumn Conference*, pp. 174-175, Tongyeong, Korea, Oct. 2024.
- [7] M. Jeon, "A Study on Improvement of Object Detection Performance in Severe Weather," *Master's Thesis, Department of Computer Information, Korea University*, Jun. 2024. DoI: 10.23186/korea.000000288712.11009.0001567
- [8] E. Choi, "The Traffic Accident Spot Detection System using Sound Recognition Based on Artificial Intelligence," *Master's Thesis, Department of Artificial Intelligence Graduate School, Dong-eui University*, Jun. 2024. UCI: 1804:21010-200000818621
- [9] J. H. Lee and C. H. Son, "Comparison of Object Detection Model Performance in Adverse Weather," *Proceedings of the Korea Institute of Information Technology Summer Conference*, pp. 518-521, Jeju, Korea, May 2024.
- [10] G. Jocher, A. Chaurasia, and J. Qiu, "Ultralytics YOLOv8," <https://github.com/ultralytics/ultralytics>

Authors



Jun-Seo Jang has completed the second-year coursework in the Department of AI Software at Daejeon University, Korea. He is continuing his studies, focusing on AI application, Data Preprocessing and Augmentation.



Hakgyun Roh received his B.S. and M.S. degrees in Computer Science from Korea Aerospace University. From 1995 to 2014, he was with the Korea Telecom Research and Development Group, where he

contributed to the development of Telco service and network management systems for wired/wireless infrastructures. Since 2023, he has been an Assistant Professor in the Dept. of AI Software and Fintech at Daejeon University. His research interests include networking technologies, sensing and data analytics, mobile systems, and converged smart applications. His recent research has expanded to machine learning, deep learning, fintech, IoT, and edge computing.



Kwansoo Jung received the B.S., M.S., and Ph.D. degrees in Computer Engineering from Chungnam National University, Korea, in 2005, 2007 and 2015, respectively. Dr. Jung joined the faculty of the Department of

Cyber Security at Howon University, Gunsan, Korea, in 2016. He was a Professor in the Department of AI Software at Daejeon University from 2020 to 2025. He is currently a Professor in the Department of Computer Education at Korea National University of Education. His research interests include Generative AI, Information Security, Internet of Things, and Computer Education.