

Comparative Analysis of RT-DETR and YOLOv8 for Real-Time Egg Defect Detection under Computational Constraints

Namil Kang*, Yechan Cha**, Bo-Young Kim***, Jihoon Moon****

*Student, Dept. of AI and Big Data, Soonchunhyang University, Asan, Korea

**Student, Asan Middle School, Asan, Korea

***Teacher, Asan Middle School, Asan, Korea

****Professor, Dept. of AI and Big Data, Soonchunhyang University, Asan, Korea

[Abstract]

In this study, we present a comparative analysis of two state-of-the-art object detection models, RT-DETR and YOLOv8, for real-time egg defect detection. As the global demand for eggs continues to rise, ensuring their quality and safety is paramount for mitigating health risks and addressing food safety concerns. The models were employed to analyze transillumination images of eggs and classify them into six distinct categories: Normal, Crack, Blood Spot, Discoloration, Foreign Body, and Deformation. A dataset comprising 11,000 egg images provided by AI-Hub was utilized, with a train-validation-test split ratio of 9:1:1 to conduct the experiments. The performance of the models was assessed based on two key metrics: detection accuracy and inference speed. For RT-DETR, two variants (r18 and r50) were trained, while YOLOv8 involved the training of three variants (nano, medium, and large). The evaluation results indicated that the RT-DETR-r50 model demonstrated superior accuracy, achieving a mean Average Precision (mAP) of 0.852 (mAP@0.5) at an IoU threshold of 0.5 and 0.851 (mAP@0.5:0.95) across multiple IoU thresholds. Conversely, the YOLOv8n model exhibited exceptional speed, with an average inference time of 0.0021 seconds per image. These findings emphasize the trade-off between accuracy and inference speed, providing critical insights into the development of efficient quality control systems for egg production facilities.

► **Key words:** Computer Vision, Egg Defect Detection, RT-DETR, YOLOv8, Real-Time Detection

-
- First Author: Namil Kang, Corresponding Author: Jihoon Moon
 - *Namil Kang (vkdntmxk999@sch.ac.kr), Dept. of AI and Big Data, Soonchunhyang University
 - **Yechan Cha (chayechan0323@naver.com), Asan Middle School
 - ***Bo-Young Kim (bboya414@naver.com), Asan Middle School
 - ****Jihoon Moon (jmoon22@sch.ac.kr), Dept. of AI and Big Data, Soonchunhyang University
 - Received: 2024. 10. 18, Revised: 2024. 11. 25, Accepted: 2024. 11. 27.

[요 약]

본 논문에서는 실시간으로 계란의 결함을 감지하기 위해 두 가지 고급 물체 감지 모델인 RT-DETR과 YOLOv8의 성능을 비교 및 분석한다. 전 세계적으로 계란 수요가 증가함에 따라, 품질과 안전성을 보장하는 실시간 결함 감지 기술은 건강 위협과 식품 안전 문제를 예방하기 위해 필수적이다. 이에 따라, 두 객체 감지 모델을 이용하여 계란의 투광 이미지를 분석하고, 정상, 균열, 혈반, 탈색, 이물질, 기형 등 6가지 카테고리를 분류한다. 이를 위해, AI-Hub의 11,000개 계란 이미지 데이터 셋을 기반으로 훈련, 검증, 평가 비율을 9:1:1로 설정하여 실험을 진행한다. 다음으로, 두 객체 감지 모델의 성능은 감지 정확도와 추론 속도 측면에서 평가한다. RT-DETR 모델은 두 가지 버전(r18, r50)으로 학습되며, YOLOv8 모델은 세 가지 버전(nano, medium, large)으로 학습되어 상호 비교된다. 실험 결과, 정확도 측면에서는 RT-DETR-r50 모델이 IoU 임계값 0.5에서 mAP이 0.852(mAP@0.5), 다양한 IoU 임계값에서 0.851(mAP@0.5:0.95)을 도출하였다. 반면, 속도 측면에서는 YOLOv8n 모델이 이미지당 평균 0.0021초의 추론 시간을 기록하여 더 나은 성능을 보였다. 본 연구는 정확성과 속도 간의 균형을 강조하며, 계란 생산 시설에서 효율적인 품질 관리 시스템을 구현하기 위한 유용한 통찰력을 제공한다.

▶ 주제어: 컴퓨터 비전, 계란 결함 탐지, RT-DETR, YOLOv8, 실시간 검출

I. Introduction

계란은 필수 단백질, 비타민, 미네랄을 포함한 다양한 영양소를 함유하고 있어 건강 유지와 성장 촉진에 중요한 역할을 한다. 이처럼 탁월한 영양학적 가치로 인해, 계란은 전 세계적으로 중요한 식량 자원으로 널리 인정받고 있다[1][2]. 특히, 개발도상국에서는 계란이 영양 결핍 문제를 완화할 수 있는 저렴한 대안으로 활용되며, 필수 식단의 한 부분을 차지하고 있다[3]. 전 세계적으로 계란 수요가 증가함에 따라, 고품질 계란 공급을 보장하는 것은 매우 중요하다. 결함이 있는 계란은 소비자에게 심각한 건강 위협을 초래할 가능성이 있으며, 이는 심각한 식품 안전 문제로 이어질 수 있다[4-6]. 따라서, 결함이 있는 계란을 신속하고 효율적으로 검출하는 것은 품질 관리와 소비자 안전을 확보하기 위한 필수적인 과정이다.

컴퓨터 비전 기술의 발전은 계란 결함 검출을 포함한 식품 산업 자동화 분야에 다양한 물체 감지 모델을 적용할 가능성을 열었다. 이 중에서도 RT-DETR(Real-Time Detection Transformer)와 YOLOv8(You Only Look Once version 8)은 각기 다른 장점이 있는 최신 객체 탐지 알고리즘으로 주목받고 있다[7]. RT-DETR은 Transformer 기반 아키텍처를 활용하여 객체 탐지 작업에서 높은 정확도를 달성하도록 설계되었으며, YOLOv8은 뛰어난 속도와 효율성 덕분에 실시간 애플리케이션에 특히 적합하다[8].

결함 계란 탐지에 적합한 모델을 선택하는 과정은 탐지 성능과 추론 속도와 같은 생산 환경의 구체적인 요구 사항

에 따라 달라진다. 예를 들어, 추론 속도가 중요한 환경에서는 YOLOv8과 같이 복잡도가 낮고 추론 시간이 빠른 모델이 더 적합할 수 있다. 반면, 정확성이 요구되는 환경에서는 RT-DETR이 정교한 아키텍처를 바탕으로 더 뛰어난 성능을 제공할 가능성이 크다[9]. 비록 이러한 고급 모델들이 활용 가능하지만, 실시간 결함 계란 탐지의 성능을 구체적으로 평가한 비교 연구는 아직 충분하지 않다[10]. 따라서, 계란 생산 설비에서 효과적인 품질 관리 시스템을 구현하려면 다양한 시나리오에서 속도와 정확성 간의 최적의 균형을 제공하는 모델을 이해하는 것이 필수적이다.

컴퓨터 비전 시스템에서 실시간 처리의 기준은 일반적으로 초당 30프레임(FPS) 이상의 처리 속도로 정의된다. 이는 각 프레임을 33밀리초 이내에 처리하여 연속적이고 즉각적인 반응을 보장하는 것을 의미한다. 이러한 속도는 산업 환경에서 시각 데이터를 기반으로 신속한 의사 결정과 조치가 요구되는 상황에서 특히 중요하다[11][12]. 객체 탐지나 실시간 모니터링과 같은 응용 분야에서는 30FPS가 널리 수용되는 표준으로 자리 잡고 있지만, 일부 고성능 작업 환경에서는 60FPS 이상의 처리 속도가 요구되기도 한다. 계란 분류 공정에서는 환경에 따라 계란이 한 줄로 이동하는 방식과 여러 개가 동시에 이동하는 방식이 모두 사용될 수 있다.

실제 산업 환경에서 다수의 계란이 동시에 처리되는 상황을 반영하기 위해, 본 연구는 여러 계란이 배치된 판 형

식의 이미지를 활용하여 실험을 진행한다. 이러한 환경에서는 각 계란의 상태를 개별적으로 분석할 수 있는 다중 객체 탐지 능력이 필수적이며, 이를 고려하여 여러 계란이 포함된 이미지를 기반으로 실험을 설계한다. 본 연구는 결합 계란 탐지를 목적으로 RT-DETR과 YOLOv8 모델을 포괄적으로 비교하며, 두 모델의 검출 정확도와 추론 속도를 중심으로 성능을 평가한다. 이를 통해, 다양한 생산 환경에서 적합한 기술을 선택하기 위한 유용한 통찰력을 제공하며, 검출 정확도와 추론 속도 간의 균형을 바탕으로 결합 계란 검출을 위한 최적의 솔루션을 제안한다.

본 논문의 나머지 구성은 다음과 같다. II장에서는 딥러닝 모델을 활용한 불량 계란 탐지와 관련된 기존 연구를 검토하고, 실험에 사용된 모델의 세부 사항을 설명한다. III장에서는 사용된 데이터 셋, 데이터 전처리 과정, 실험 설정 등 제안된 프레임워크의 방법론을 다룬다. IV장에서는 RT-DETR과 YOLOv8 모델의 성능을 비교한 실험 결과를 제시하며, 모델 간의 성능 차이를 분석한다. 마지막으로, V장에서는 본 논문의 결론을 제시하고, 향후 연구 방향에 대해 논의한다.

II. Literature Review and Models

1. Literature Review

Turkoglu는 사전 훈련된 고밀도 콘볼루션 네트워크(DenseNet201) 모델을 사용하여 특징을 추출한 후, 이를 BiLSTM(Bidirectional Long Short-Term Memory)에 입력하여 계란의 상태를 분류한 딥러닝 기반 결합 계란 감지 모델을 제안하였다[13]. 이 연구에서는 오염된 계란, 피문은 계란, 금이 간 계란, 건강한 계란 등 총 400개의 이미지로 구성된 데이터 셋을 이용해 실험을 진행하였으며, 제안된 모델은 99.17%의 높은 분류 정확도를 도출하였다.

Botta 등은 CNN(Convolutional Neural Network)을 기반으로 계란 껍질의 균열을 자동으로 감지하는 방법론을 제안하였다[14]. 데이터 수집을 위해 150개의 흰 계란 이미지를 다양한 각도에서 촬영하였으며, 제안한 CNN 모델은 3개의 콘볼루션 레이어와 풀링 레이어로 구성되어, 이미지를 균열 및 정상 클래스로 분류하였다. 실험 결과, CNN 모델은 96.92%의 정확도를 달성하여 기존의 SVM(Support Vector Machine) 기반 방법론보다 우수한 분류 성능을 확인할 수 있었다.

이전 연구들은 금이 간 계란을 탐지하는 데 높은 정확도를 보였으나, 주로 작은 데이터 셋을 기반으로 분류 작업

에 초점을 맞추었다. 더불어, 제안한 모델들은 대규모 생산 환경에서 실시간 감지에 최적화되지 않았을 가능성이 있다. 본 연구는 RT-DETR, YOLOv8과 같은 고급 객체 감지 모델을 활용하여 계란 선별 공정에서 적합한 실시간 불량 계란 감지 시스템을 제안한다는 점에서 기존 연구와 차별화된다. 이를 통해, 계란 생산 설비에서 효율적인 품질 관리를 위한 실용적인 솔루션을 제시하며, 다양한 모델의 성능 비교를 통해 실시간 환경에 가장 적합한 모델을 도출하고자 한다.

2. Model Descriptions and Analysis

RT-DETR과 YOLOv8 모델은 모두 효율적인 객체 감지를 목표로 하지만, 설계 철학과 구조적 접근 방식에서 차이가 있다. 본 장에서는 각 모델의 작동 원리를 상세히 기술하고, 두 모델의 강점과 약점을 분석하여 계란 결합 탐지 작업에서 적합성을 평가한다.

2.1 RT-DETR

RT-DETR은 실시간 애플리케이션을 위해 설계된 트랜스포머 기반 객체 감지 모델로, 특징 추출을 위한 CNN과 글로벌 컨텍스트 모델링을 위한 트랜스포머 아키텍처를 통합한다.

RT-DETR은 효율적인 객체 감지를 위해 여러 주요 구성 요소로 구성된다. CNN 기반 백본 네트워크는 입력 이미지를 처리하여 특징 맵(feature map)을 생성하며, 이는 객체 감지에 중요한 가장자리, 텍스처와 같은 로컬 시각적 특징을 캡처한다. 이어지는 트랜스포머 인코더-디코더 아키텍처는 이미지 내 글로벌 관계를 모델링하여, 복잡한 장면에서도 객체 간의 연관성을 이해하는 데 중요한 역할을 한다.

- 인코더는 특징 맵을 처리하여 이미지 내 여러 부분의 상호 관계를 학습하며, 이는 객체가 겹치거나 복잡한 장면에서 특히 유용하다.
- 디코더는 인코더 출력에서 특정 영역에 초점을 맞추며, 객체가 포함될 가능성이 높은 영역에 주의를 기울여 객체 예측을 생성한다. 이 과정은 학습된 컨텍스트를 기반으로 예측을 정교화한다.
- 감지 헤드(detection head)는 디코더의 출력을 처리하여 최종 바운딩 박스와 클래스 확률을 예측하며, 추상적인 특징을 구체적인 결과로 변환한다.

RT-DETR은 트랜스포머 아키텍처를 활용해 전체 이미지의 컨텍스트를 고려함으로써, 겹치거나 가려진 객체가 있는 복잡한 장면에서 감지 정확도를 높이는 장점을 제공한다[15][16]. 또한, 정교한 아키텍처에도 불구하고 경량




Fig. 1. Workflow of Real-Time Egg Defect Detection and Categorization

설계로 구현되어, 제한된 컴퓨팅 리소스를 가진 디바이스에서도 실시간 추론이 가능하다[17].

2.2 YOLOv8

YOLOv8은 속도와 효율성에 최적화된 YOLO 시리즈의 최신 반복 버전으로, 객체 감지를 단일 단계 문제로 구성하는 전통을 계승하였다. 이 모델은 한 번의 평가로 전체 이미지에서 경계 상자와 클래스 확률을 동시에 예측하며, 객체 감지의 단순성과 정확성을 모두 제공한다[18].

YOLOv8은 고속 물체 감지를 위해 설계된 여러 구성 요소로 구성되어 있다[19].

- 백본 네트워크: 입력 이미지를 처리하여 다양한 추상화 수준에서 계층적 특징을 추출하며, 시각적 패턴을 효과적으로 캡처한다.
- 목 구성 요소(neck): 여러 레이어에서 생성된 특징 맵을 결합하여 다중 스케일 특징 표현을 개선하며, PANet(Path Aggregation Network) 또는 FPN(Feature Pyramid Network)과 같은 구조를 통해 특징 융합을 최적화한다.
- 인식 헤드(detection head): 최종적으로 경계 상자 좌표, 객체 점수, 클래스 확률을 예측하며, 추출된 특징을 바탕으로 객체를 정확히 감지한다.

YOLOv8은 앵커 프리(anchor-free) 접근 방식을 채택하여 물체의 중심과 크기를 직접 예측함으로써, 인식 과정을 단순화하고 계산 효율성을 높였다. 그리하여, 빠른 처리 속도로 실시간 애플리케이션에 적합하고, 간소화된 설계로 인해 구현과 학습이 용이하며, 광범위한 커뮤니티 지원과 풍부한 리소스를 통해 다양한 환경에 쉽게 적용할 수 있다[20].

2.3 RT-DETR vs. YOLOv8

RT-DETR과 YOLOv8은 효율적이고 정확한 객체 감지를 목표로 하지만, 아키텍처 설계와 접근 방식에서 본질적인 차이를 보인다. RT-DETR은 트랜스포머 메커니즘을

활용해 글로벌 컨텍스트를 효과적으로 캡처하며, 복잡한 장면에서 더 높은 감지 정확도를 제공할 수 있다. 그러나, 이러한 정교한 설계는 상대적으로 더 많은 컴퓨팅 리소스를 요구할 가능성이 있다. 반면, YOLOv8은 간소화된 컨볼루션 아키텍처를 채택해 속도와 효율성을 극대화하였으며, 컴퓨팅 리소스가 제한된 환경에서도 실시간 객체 감지가 가능하다[21][22]. 이 모델은 처리 속도가 중요한 애플리케이션에 적합한 선택지로 주목받고 있다.

본 연구는 계란 결함 탐지 작업에서 RT-DETR과 YOLOv8 모델의 성능을 비교함으로써, 다양한 생산 환경에서 정확도와 속도 간의 최적 균형을 제공할 수 있는 모델을 제안한다. 이를 통해, 계란 생산 설비의 효율적인 품질 관리에 이바지할 수 있는 실용적인 솔루션을 제시한다.

III. Proposed Framework

본 연구는 RT-DETR, YOLOv8과 같이 고급 객체 감지 모델을 적용하여 생산 설비에서 실시간 계란 결함 검출을 목표로 하는 방법론을 제안한다. 제안한 방법론의 프레임워크는 그림 1과 같다. 제안한 방법론은 촬영된 투광 이미지를 입력받아 모델이 이미지 내 계란을 감지한 뒤, 각 계란의 상태를 분석하여 해당 결함 범주로 분류한다. 이를 통해 계란 생산 과정에서 효율적인 품질 관리와 결함 계란의 자동 판별을 지원한다.

1. Datasets

본 연구에서는 계란 결함 감지 모델의 훈련 및 평가를 위해 AI-Hub에서 제공하는 계란 데이터 셋을 활용하였다[23]. 해당 데이터 셋은 계란 선별기를 통해 수집된 다양한 유형의 계란 이미지를 포함하며, 다음과 같은 주요 구성 요소로 이루어져 있다:

- 투광 이미지: 투과광을 활용하여 계란 내부의 특징을 강조한 이미지

- 컬러 이미지: 계란의 표준 RGB 이미지
- 보관기간 투광 이미지: 시간 경과에 따른 변화를 관찰하기 위해 서로 다른 저장 시간에서 촬영한 투광 이미지

데이터 셋은 XML 형식의 라벨 정보를 제공하며, 개체 클래스 및 경계 상자 좌표와 같은 세부 정보가 포함되어 있다. 전체 데이터 셋은 약 18만 개의 계란 트레이(케이스)와 약 150만 개의 주석이 달린 계란 개체가 포함되어 있다. 그러나, 구축된 계란 투광 이미지는 다양한 상태의 계란이 무작위로 분배 및 촬영되었기 때문에 특정 클래스의 샘플을 추출하기 어려움이 있다. 이를 해결하기 위해, 그림 2와 같이 AI-Hub에 구축된 계란 투광 이미지의 클래스 분포를 기반으로, 약 11,000개의 투광 이미지를 무작위로 선택하여 실험에 적합한 샘플을 구성하였다. 선택된 데이터는 9:1:1 비율로 훈련/검증/평가 집합으로 분할하였다.




Fig. 2. Class Distribution of Transmitted Egg Images in the AI-Hub Dataset

그림 3은 각 클래스에 해당하는 계란 이미지 예시를 보여주며, 데이터는 6개의 주요 카테고리 분류된다:

1. Normal: 결함이 없는 계란
2. Crack: 껍질에 금이 간 계란
3. Blood: 내부에 핏자국이 있는 계란
4. Decolorize: 색이 비정상적으로 변색된 계란
5. Foreign Body: 이물질에 오염된 계란
6. Deformities: 모양이 비정상적인 계란




Fig. 3. Representative Examples of Egg Images for Each Defect Class

2. Data Preprocessing

RT-DETR과 YOLOv8 모델의 학습을 위해 주석 형식과 라벨 데이터의 표준화에 중점을 두고 여러 단계의 데이터 전처리를 수행하였다. 원본 라벨 데이터는 XML 형식으로 제공되며, 각 이미지와 계란 개체에 대한 정보를 포함하고 있으며, 바운딩 박스 정보는 객체 클래스와 함께 왼쪽 하단 (x_{min}, y_{min}) 및 오른쪽 상단 (x_{max}, y_{max}) 좌표로 저장되어 있다.

- RT-DETR: 모델 호환성을 위해 바운딩 박스 좌표를 경계 상자의 폭과 높이, 왼쪽 하단 좌표 형식으로 변환하였다. 이 과정에서 오른쪽 상단 좌표에서 왼쪽 하단 좌표를 빼서 폭과 높이를 계산하였다.
- YOLOv8: YOLOv8이 요구하는 정규화된 좌표 형식에 맞게 주석 데이터를 조정하였다. 이는 이미지 치수를 기준으로 바운딩 박스 좌표를 변환하는 과정으로, 모델 학습의 일관성을 유지하였다[24].

효율적인 데이터 처리를 위해 각 이미지 파일에 고유 식별자를 부여하였으며, 각 객체 클래스에는 숫자 식별자를 할당하였다. RT-DETR는 주석 데이터를 JSON 형식으로 변환하였으며, YOLOv8는 주석 데이터를 텍스트 형식으로 저장하였다. 이러한 표준화를 통해 모델이 데이터에 일관되게 액세스하고 처리할 수 있도록 보장하였다.

객체 감지 모델의 일반화를 향상하고 과적합을 방지하기 위해 다양한 데이터 증강 기법을 적용하였다:

- 밝기 조정: 다양한 조명 조건을 시뮬레이션하기 위해 이미지의 색상, 밝기, 대조를 무작위로 변형

- 확대: 객체를 여러 크기에서 학습하도록 돕기 위해 이미지를 무작위로 확대하고 주변을 검은색으로 채움
- 자르기: IoU 기반 자르기 기법을 사용하여 객체의 일부 분만 포함되도록 처리하였으며, 너무 작은 객체는 제거
- 좌우 반전: 객체가 좌우 대칭적으로 학습할 수 있도록 이미지를 좌우로 반전

이러한 데이터 증강 기법은 RT-DETR과 YOLOv8 모델에서 제공하는 데이터 증강 옵션을 기반으로 각 증강 기법의 적용 확률은 모델 학습 시 다음과 같이 설정되었다:

- 밝기 조정: 50%
- 자르기: 80%
- 좌우 반전: 50%
- 확대: 항상 적용

위의 전처리 과정과 데이터 증강 기법은 모델이 다양한 크기, 조명, 배치 조건에서 데이터를 학습할 수 있도록 하여 실제 시나리오에서 발생할 수 있는 다양한 변수를 반영한다. 이를 통해 모델의 일반화 성능을 향상하고, 보이지 않는 데이터에 대한 예측력을 개선할 수 있다.

IV. Experiments

1. Hyperparameter Configuration

RT-DETR과 YOLOv8n 모델의 학습 프로세스를 최적화하기 위해, 예비 실험 결과와 리소스 제약을 기반으로 하이퍼파라미터를 신중히 설정하였다. 설정된 하이퍼파라미터는 표 1에 요약되어 있다.

Table 1. Hyperparameter Settings for RT-DETR and YOLOv8 Models

Hyperparameter	RT-DETR	YOLOv8
Epoch	72	100
Optimizer	AdamW	AdamW
Learning Rate	0.0001	0.01
Batch Size	8	16

RT-DETR 모델은 충분한 반복을 통해 모델이 안정적으로 수렴할 수 있도록 에포크 수를 72로 설정하였다. AdamW 옵티마이저를 사용하여 희박한 기물기를 처리하여 일반화 성능을 개선하였으며, 학습 과정의 진동이나 발산 없이 안정적으로 진행하고자 학습률은 0.0001로 설정하였다. 또한, 메모리 제약을 고려하여 배치 크기를 8로 설정해 계산 리소스에 과부하가 걸리지 않도록 하였다.

YOLOv8 모델은 RT-DETR 모델과 동일한 옵티마이저와 배치 크기 설정을 유지하였으나, 더 많은 반복 학습을 위해 에포크 수를 100으로 설정하였다. 또한, YOLOv8의 학습률은 0.01로 설정하여 모델의 빠른 수렴을 지원하였다.

두 모델 모두 과적합 방지를 위해 가중치 감쇠(weight decay)와 조기 종료(early stopping)를 적용하여 학습이 실험 데이터 셋에 최적화하도록 설정하였다. 이를 통해 학습 안정성과 모델의 일반화 성능을 극대화할 수 있다.

2. Mean Average Precision

객체 감지 모델의 성능을 평가하기 위해 mAP(mean Average Precision)를 주요 평가지표로 사용하였다. mAP는 객체 탐지와 분류 모델의 성능을 평가하는 데 널리 활용되는 지표로, 모델이 객체의 위치를 얼마나 정확히 예측하고, 해당 객체가 어떤 클래스에 속하는지를 평가하는 데 중요한 역할을 한다.

mAP는 정밀도와 재현율의 관계를 기반으로 측정되며, 모델의 전반적인 성능을 정량화한다. 정밀도(precision)는 객체 감지 모델이 예측한 객체 중 실제로 올바르게 예측된 객체의 비율로, 모델의 예측 정확성을 나타낸다. 재현율(recall)은 실제 객체 중 객체 감지 모델이 정확히 탐지한 객체의 비율로, 모델이 놓치지 않고 탐지한 객체의 비율을 평가한다.

AP(Average Precision)는 특정 클래스에 대해 정밀도와 재현율의 관계를 시각화한 정밀도-재현율 곡선 아래 면적의 값이다. 정밀도-재현율 곡선은 재현율이 증가함에 따라 정밀도가 어떻게 변하는지를 나타내며, 모델의 성능을 여러모로 평가하는 데 활용된다. AP는 다양한 임계값에서 정밀도와 재현율을 종합적으로 분석하여 산출되며, 이를 통해 특정 클래스에서의 탐지 성능을 정량화할 수 있다.

mAP는 모든 클래스에 대한 AP값을 평균 내어 객체 감지 모델의 전반적인 성능을 평가하는 지표이다. 본 연구는 IoU(Intersection over Union) 임계값을 기준으로 mAP를 계산하였다. IoU 임계값이 0.5일 때의 평균 AP를 나타내는 mAP@0.5와, IoU 임계값을 0.5에서 0.95까지 0.05 단위로 변화시키며 계산한 mAP@0.5:0.95를 사용하여 모델의 정확성과 일관성을 평가하였다.

mAP는 모델이 객체의 위치를 정확히 예측하고, 올바른 클래스를 분류할 수 있는 능력을 평가하는 데 중요한 지표로 다양한 IoU 임계값에서의 평가를 통해 객체 감지 모델의 성능을 더욱 철저히 분석할 수 있다. 이러한 분석은 모델의 강건성을 측정하고, 실제 시나리오에서 성능을 예상하는 데 유용하다.

3. Experimental Results

본 연구에서는 실시간 계란 결함 검출을 위한 RT-DETR과 YOLOv8 모델의 성능을 비교하고자 계란 데이터 셋을 이용하여 실험을 수행하였다. 모델의 파라미터 크기와 설계 복잡도를 기준으로 다양한 모델을 선택하여 실험을 진행하였다. RT-DETR 모델은 r18과 r50 버전을, YOLOv8 모델은 nano (n), medium (m), large (l) 버전을 선택하였다. RT-DETR 모델은 더 높은 파라미터 크기로 복잡한 장면에서의 높은 정확도를 목표로 설계되었으며, YOLOv8 모델은 속도와 효율성을 강조하는 다양한 크기의 아키텍처로 구성되었다. 표 2는 각 모델의 파라미터 크기를 백만 단위로 나타낸다.

Table 2. Configuration of Experiment Model Types and Parameters

Model	Parameters (Million)
RT-DETR-r18	20
RT-DETR-r50	42
YOLOv8n	3.2
YOLOv8m	25.9
YOLOv8l	43.7

두 모델은 공정한 비교를 보장하기 위해 동일한 데이터 셋과 전처리 과정을 기반으로 학습 및 평가를 수행하였다. 모델 학습 과정에서 최적화된 환경을 제공하기 위해, 원본 데이터 셋의 이미지 크기인 1440×1080 을 640×640 으로 변환하여 학습을 진행하였다. 이와 같은 크기 조정은 모델이 효율적으로 학습하고 실시간 애플리케이션에 적합하도록 처리되었다. 이를 통해 다양한 모델 아키텍처가 계란 결함 탐지 작업에서 어떻게 성능을 발휘하는지 평가하며, 모델의 설계 목표에 따라 적합한 선택이 가능하도록 근거를 제공한다.

3.1 Performance Analysis of RT-DETR and YOLOv8 Models

본 실험은 각 모델의 정확도, 추론 속도, 메모리 사용량, 학습된 모델 크기를 중심으로 평가를 진행하였다. 표 3은 RT-DETR 모델과 YOLOv8 모델의 실험 결과를 비교한 성능 지표이다.

RT-DETR-r18 모델은 IoU 임계값 0.5에서 평균 정밀도(mAP@0.5) 0.844를 기록하였고, IoU 임계값이 0.5에서 0.95까지 변화하는 상황(mAP@0.5:0.95)에서는 평균 0.843을 달성하였다. 해당 모델은 이미지당 평균 0.0048초의 추론 시간을 보였으며, 초당 약 208.33프레임(FPS)을 처리할 수 있다.

RT-DETR-r50 모델은 IoU 임계값 0.5에서 mAP 0.852, mAP@0.5:0.95에서 0.851을 달성하였다. 이 모델의 평균 추론 시간은 이미지당 0.0089초이었으며, 초당 약 112.36프레임(FPS)을 처리할 수 있다. 성능 비교 결과, RT-DETR-r50 모델은 정확도에서 우위를 보였지만, 추론 속도는 RT-DETR-r18 모델이 더 우수하였다. 이는 RT-DETR-r50 모델이 더 정교한 탐지 능력을 갖추지만, RT-DETR-r18 모델이 실시간 애플리케이션에서 더 적합할 가능성이 있음을 시사한다.

YOLOv8n 모델은 mAP@0.5에서 0.793, mAP@0.5:0.95에서 0.792를 기록하며, 이미지당 평균 추론 시간은 0.0021초로 초당 약 476.19프레임(FPS)을 처리하였다. 이는 RT-DETR 모델보다 빠른 처리 속도를 보여주지만, 탐지 정확도는 상대적으로 낮았다.

YOLOv8m 모델은 mAP@0.5에서 0.788, mAP@0.5:0.95에서 0.787를 기록하였으며, 추론 속도는 이미지당 0.0096초로 초당 약 104.17프레임(FPS)을 처리하였다. YOLOv8n 모델보다 정확도는 비슷하지만, 처리 속도는 크게 저하되었다.

YOLOv8l 모델은 mAP@0.5에서 0.799, mAP@0.5:0.95에서 0.798를 기록하며, YOLOv8 계열 중 가장 높은 정확도를 달성하였다. 그러나, 추론 속도는 이미지당 0.0152초로 초당 약 65.79프레임(FPS)을 처리하며, 가장 느린 속도를 보였다.

RT-DETR 모델은 YOLOv8 모델보다 높은 탐지 정확도를 보였으며, 특히 RT-DETR-r50 모델은 다양한 IoU 임계값에서 일관된 성능을 보여 강력한 탐지 능력을 입증하였다. 반면, YOLOv8n 모델은 가장 빠른 추론 속도를 보여 실시간 처리에 유리한 특징을 보였다.

RT-DETR 모델은 메모리 사용량 측면에서 YOLOv8n 모델보다 효율적이었으며, 이는 계산 리소스가 제한적인 환경에서 우위를 제공할 수 있다. 반면, YOLOv8 모델은 RT-DETR 모델보다 더 작은 학습된 모델 크기를 보여 저장 공간이 제한된 상황에서 유리한 선택지가 될 수 있다.

프로덕션 환경에서의 모델 선택은 아래와 같다:

- 정확성이 중요한 경우: RT-DETR 모델은 계란 품질을 보장하기 위해 높은 탐지 정확도를 제공하며, 안전성과 제품 품질이 중요한 환경에서 적합하다.
- 속도가 중요한 경우: YOLOv8n 모델은 처리 속도가 가장 빠르므로, 초고속 처리가 필요한 환경에서 유리하다.

RT-DETR 모델은 정확도가 중요한 계란 결함 검출 작업에서 높은 실용성을 보였으나, 추론 속도가 느려 처리량이 많은 환경에서 제한이 될 수 있다. 이를 개선하기 위해, 추후 연구에서는 모델 가지치기나 양자화 기법을 적용하

Table 3. Performance Comparison of RT-DETR and YOLOv8 Models (Best Results Highlighted in Bold)

Model	Parameters (Million)	mAP@0.5	mAP@0.5:0.95	Average Inference Time (Seconds)	Average FPS	Memory Usage (MiB)	Trained Model Size (MB)
RT-DETR-r18	20	0.844	0.843	0.0048	208.33	312	100.95
RT-DETR-r50	42	0.852	0.851	0.0089	112.36	426	194.76
YOLOv8n	3.2	0.793	0.792	0.0021	476.19	524	5.49
YOLOv8m	25.9	0.788	0.787	0.0096	104.17	734	44.61
YOLOv8l	43.7	0.799	0.798	0.0152	65.79	880	75.65

여 RT-DETR 모델의 추론 속도를 최적화할 필요가 있다 [25-27]. 또한, 데이터 셋을 확장하여 다양한 계란 결함과 환경 조건을 포함하면 모델의 강건성과 일반화 성능을 더욱 향상할 수 있을 것이다.

3.2 Confusion Matrix Analysis for RT-DETR and YOLOv8 Models

각 모델의 계란 클래스 분류 성능을 평가하기 위해 혼동 행렬(confusion matrix)을 시각화하였다. 그림 4는 RT-DETR 모델과 YOLOv8 모델의 혼동행렬을 보여주며, 각 클래스에 대한 모델의 예측 정확도와 오류 분포를 상세히 나타낸다. 혼동행렬에서 계란 클래스 이외의 배경(background)은 다음 두 가지 경우로 처리하였다:

- 모델이 객체를 탐지하였으나 실제 라벨이 없는 경우
- 모델이 객체를 탐지하지 못하였지만, 실제 라벨이 존재하는 경우

RT-DETR 모델은 모든 계란 클래스에 대해 YOLOv8 모델보다 우수한 분류 성능을 보여준다. 특히 RT-DETR-r50 모델은 Crack과 Foreign Body 클래스에서 가장 높은 정확도를 기록하며, 복잡한 장면에서도 클래스 간 구분이 뛰어난 성능을 나타냈다.

YOLOv8 모델은 RT-DETR 모델보다 전체적으로 낮은 분류 성능을 보였으며, 특히 Deformities 클래스에서 가장 저조한 결과를 나타냈다. 또한, YOLOv8 모델은 Normal 클래스와 다른 클래스 간의 혼동 비율이 높아, 클래스 간 구분 성능이 다소 떨어지는 경향을 보인다.

RT-DETR 모델은 YOLOv8 모델보다 전반적으로 더 높은 정확도와 클래스 구분 능력을 보이며, 특히 복잡한 장면에서 강점을 입증하였다. 이 결과는 RT-DETR 모델이 정확성과 정교한 클래스 구분이 중요한 품질 관리 시스템에 적합함을 시사한다.

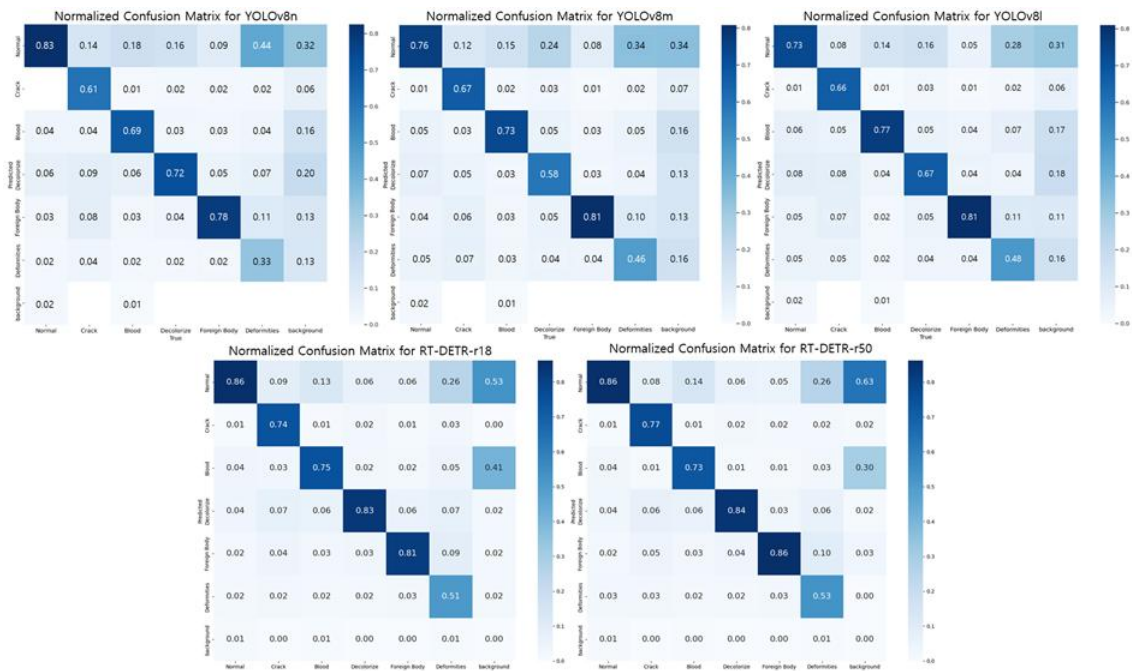


Fig. 4. Confusion Matrices for Classifying Egg Defects Using RT-DETR and YOLOv8 Models

3.3 Inference Results of RT-DETR and YOLOv8 Models

Models

RT-DETR-r50 모델의 추론 결과는 그림 5와 같다. 해당 모델은 정상 계란, 금이 간 계란, 변색한 계란을 효과적으로 탐지하고 각 결함 유형에 따라 정확히 분류할 수 있음을 확인하였다. 이는 RT-DETR-r50 모델이 계란 선별 공정의 품질 관리를 위한 실질적 응용 가능성을 보여준다.




Fig. 5. Inference Results of RT-DETR-r50 Model for Detecting Egg Defects

YOLOv8n 모델의 추론 결과는 그림 6과 같다. 해당 모델은 다양한 계란 결함을 성공적으로 탐지하였으나, RT-DETR 모델과 비교하였을 때 분류 정확도가 약간 낮은 경향을 보였다. 이는 YOLOv8n 모델이 속도와 효율성을 강조하는 설계로 인해 일부 클래스의 구분에서 약간의 성능 저하를 나타냈을 가능성을 시사한다.




Fig. 6. Inference Results of YOLOv8n Model for Detecting Egg Defects

V. Conclusions

본 연구는 실시간 계란 결함 검출 기술 개발을 목표로, RT-DETR 모델과 YOLOv8 모델의 성능을 비교하여 계란 선별 공정에 최적화된 방법론을 제안하였다. 11,000개의 투과광 이미지로 구성된 AI-Hub 데이터 셋을 활용하여 모델을 훈련 및 검증하였으며, 데이터는 훈련/검증/평가 집합을 9:1:1의 비율로 분할하였다. 실험은 동일한 데이터 셋과 환경에서 수행되어 두 모델의 성능 차이를 공정하게 비교하였다.

RT-DETR-r50 모델은 mAP@0.5에서 0.852, mAP@0.5:0.95에서 0.851을 달성하며, 탐지 정확도 면에서 가장 우수한 성능을 확인할 수 있었다. 또한, 평균 추론 시간은 0.0089초로 실시간 애플리케이션에서 적합한 처리 속도를 기록하였다. 반면, YOLOv8n 모델은 평균 추론 시간 0.0021초로 RT-DETR 모델보다 빠른 속도를 보였으나, 탐지 정확도는 상대적으로 낮았다. 특히 YOLOv8 모델은 모델 크기가 증가할수록 성능 저하가 나타났으며, 이는 복잡한 탐지 작업에서 RT-DETR 모델의 강점을 입증한다.

따라서, RT-DETR 모델의 높은 탐지 정확도는 계란 결함 탐지와 같은 정확성이 우선시되는 애플리케이션에서 적합하며, 결함 제품이 소비자에게 전달되는 것을 방지하는데 중요한 역할을 할 수 있다. 그러나 YOLOv8 모델은 빠른 처리 속도가 요구되는 환경에서 장점을 보이며, 특히 계산 리소스가 제한적인 상황에서 유용한 선택지가 될 수 있다. 또한, 본 연구는 데이터 셋 내 클래스 불균형이 탐지 성능에 영향을 미칠 수 있음을 확인하였다. 일부 클래스에서 낮은 성능이 관찰되었으며, 이는 소수 클래스 샘플을 추가 확보하고 학습에 활용함으로써 개선할 수 있을 것이다.

결론적으로, 본 연구는 두 객체 감지 모델의 성능과 속도 간의 상충 관계를 조명하였으며, 특정 생산 환경에 적합한 모델 선택을 위한 실질적인 근거를 제공하였다. RT-DETR 모델은 정확성과 강건성이 중요한 품질 관리 환경에 적합하며, YOLOv8 모델은 속도와 효율성이 요구되는 생산 환경에 적합한 옵션임을 보여준다. 향후 연구에서는 데이터 셋을 확장하여 다양한 결함 유형과 계란 등급을 탐지할 수 있는 고도화된 탐지 시스템을 개발할 계획이다. 또한, 모델 경량화 기술을 활용하여 RT-DETR 모델의 추론 속도를 개선함으로써 정확도와 속도 간의 균형을 최적화하는 방향으로 연구를 진행하고자 한다.

ACKNOWLEDGEMENT

This study was supported by MSIT (Ministry of Science, ICT), Korea, under the National Program for Excellence in SW, supervised by IITP (Institute of Information & Communications Technology Planning & Evaluation) in 2024 (2021-0-01399).

REFERENCES

- [1] P. Mason, "The importance of eggs in an environmentally sustainable diet," *Nutrition Bulletin*, Vol. 48, No. 3, pp. 400-410, August 2023. DOI: 10.1111/nbu.12632
- [2] M. Myers and C. H. S. Ruxton, "Eggs: Healthy or Risky? A Review of Evidence from High Quality Studies on Hen's Eggs," *Nutrients*, Vol. 15, No. 12, p. 2657, June 2023. DOI: 10.3390/nu15122657
- [3] S. Réhault-Godbert, N. Guyot, and Y. Nys, "The Golden Egg: Nutritional Value, Bioactivities, and Emerging Benefits for Human Health," *Nutrients*, Vol. 11, No. 3, p. 684, March 2019. DOI: 10.3390/nu11030684
- [4] M. Gallo, L. Ferrara, A. Calogero, D. Montesano, and D. Naviglio, "Relationships between food and diseases: What to know to ensure food safety," *Food Research International*, Vol. 137, p. 109414, November 2020. DOI: 10.1016/j.foodres.2020.109414
- [5] H. Onyeaka, S. Ghosh, K. Obileke, T. Miri, O. A. Odeyemi, O. Nwaiwu, and P. Tamasiga, "Preventing chemical contaminants in food: Challenges and prospects for safe and sustainable food production," *Food Control*, Vol. 155, p. 110040, January 2024. DOI: 10.1016/j.foodcont.2023.110040
- [6] S. Thangaraju, N. Modupalli, and V. Natarajan, "Food adulteration and its impacts on our health/balanced nutrition," in *Food Chemistry: The Role of Additives, Preservatives and Adulteration*, M. Naeem, M. M. Özcan, and M. Naveed, Eds., pp. 189-216, December 2021. DOI: 10.1002/9781119792130.ch7
- [7] Y. Sun, Z. Sun, and W. Chen, "The evolution of object detection methods," *Engineering Applications of Artificial Intelligence*, Vol. 133, p. 108458, April 2024. DOI: 10.1016/j.engappai.2024.108458
- [8] Y. Zhao, W. Lv, S. Xu, J. Wei, G. Wang, Q. Dang, Y. Liu, and J. Chen, "DETRs Beat YOLOs on Real-time Object Detection," in *Proc. IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp. 16965-16974, Seattle, WA, USA, June 2024. DOI: 10.1109/CVPR52733.2024.01605
- [9] E. L. T. Jun, M.-L. Tham, and B.-H. Kwan, "A Comparative Analysis of RT-DETR and YOLOv8 for Urban Zone Aerial Object Detection" in *Proc. 2024 IEEE International Conference on Automatic Control and Intelligent Systems (I2CACIS)*, pp. 340-345, Shah Alam, Malaysia, June 2024. DOI: 10.1109/I2CACIS
- 61270.2024.10649836
- [10] X. Yang, R. B. Bist, S. Subedi, and L. Chai, "A Computer Vision-Based Automatic System for Egg Grading and Defect Detection," *Animals*, Vol. 13, No. 14, p. 2354, July 2023. DOI: 10.3390/ani13142354
- [11] Z. Zhang, Q. Zhou, H. Jin, Q. Li, and Y. Dai, "A Real-Time Intelligent Valve Monitoring Approach through Cameras Based on Computer Vision Methods," *Sensors*, Vol. 24, No. 16, p. 5337, August 2024. DOI: 10.3390/s24165337
- [12] S. Bultmann and S. Behnke, "Real-Time Multi-View 3D Human Pose Estimation using Semantic Feedback to Smart Edge Sensors," *arXiv preprint*, June 2021. DOI: 10.48550/arXiv.2106.14729
- [13] M. Turkoğlu, "Defective egg detection based on deep features and Bidirectional Long-Short-Term-Memory," *Computers and Electronics in Agriculture*, Vol. 185, p. 106152, June 2021. DOI: 10.1016/j.compag.2021.106152
- [14] B. Botta, S. S. R. Gattam, and A. K. Datta, "Eggshell crack detection using deep convolutional neural networks," *Journal of Food Engineering*, Vol. 315, p. 110798, February 2022. DOI: 10.1016/j.jfoodeng.2021.110798
- [15] J. Zhang, K. Yang, A. Constantinescu, K. Peng, K. Müller, and R. Stiefelhagen, "Trans4Trans: Efficient Transformer for Transparent Object and Semantic Scene Segmentation in Real-World Navigation Assistance," *IEEE Transactions on Intelligent Transportation Systems*, Vol. 23, No. 10, pp. 19173-19186, March 2022. DOI: 10.1109/TITS.2022.3161141
- [16] W. Xu, C. Zhang, Q. Wang, and P. Dai, "FEA-Swin: Foreground Enhancement Attention Swin Transformer Network for Accurate UAV-Based Dense Object Detection," *Sensors*, Vol. 22, No. 18, p. 6993, September 2022. DOI: 10.3390/s22186993
- [17] M. Liu et al., "Bearing-DETR: A Lightweight Deep Learning Model for Bearing Defect Detection Based on RT-DETR," *Sensors*, Vol. 24, No. 13, p. 4262, June 2024. DOI: 10.3390/s24134262
- [18] M. Safaldin, N. Zaghdan, and M. Mejdoub, "An Improved YOLOv8 to Detect Moving Objects," *IEEE Access*, Vol. 12, pp. 59782-59806, April 2024. DOI: 10.1109/ACCESS.2024.3393835
- [19] M. Bakirci, "Enhancing vehicle detection in intelligent transportation systems via autonomous UAV platform and YOLOv8 integration," *Applied Soft Computing*, Vol. 164, p. 112015, July 2024. DOI: 10.1016/j.asoc.2024.112015
- [20] J. Moon, M. Bukhari, C. Kim, Y. Nam, M. Maqsood, 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, October 2024. DOI: 10.1016/j.icte.2024.07.005
- [21] Y. Lee, H. Cho, B.-Y. Kim, and J. Moon, "A YOLOv8-Based

- Two-Stage Framework for Non-Destructive Detection of Varroa destructor Infestations in *Apis mellifera* Colonies," Journal of the Korea Society of Computer and Information, Vol. 29, No. 10, pp. 137-148, October 2024. DOI: 10.9708/jksoci.2024.29.10.137
- [22] H. Kim and J. Moon, "A Real-Time Wildlife Roadkill Detection Approach Using YOLOv8," Journal of Internet of Things and Convergence, Vol. 10, No. 5, pp. 185-196, October 2024. DOI: 10.20465/KIOTS.2024.10.5.185
- [23] AI-Hub, Egg Defect Detection Dataset, <https://www.aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=data&dataSetSn=71504>
- [24] Ultralytics, Ultralytics YOLOv8: State-of-the-art Object Detection Models, <https://github.com/ultralytics/ultralytics>
- [25] M. Zhu and S. Gupta, "To prune, or not to prune: exploring the efficacy of pruning for model compression," arXiv preprint, November 2017. DOI: 10.48550/arXiv.1710.01878
- [26] T. Liang, J. Glossner, L. Wang, S. Shi, and X. Zhang, "Pruning and quantization for deep neural network acceleration: A survey," Neurocomputing, Vol. 461, pp. 370-403, August 2021. DOI: 10.1016/j.neucom.2021.07.045
- [27] A. Gholami, S. Kim, Z. Dong, Z. Yao, M. W. Mahoney, and K. Keutzer, "A Survey of Quantization Methods for Efficient Neural Network Inference," in Low-Power Computer Vision, B. Chattopadhyay and M. Shafique, Eds., Chapman and Hall/CRC, pp. 291-326, March 2021. DOI: 10.1201/9781003162810

Authors



Namil Kang has been a dedicated student in the Department of AI and Big Data at Soonchunhyang University, South Korea, since 2019. He will receive his Bachelor of Science degree in February next year.

His academic interests include real-time detection, deep learning, and emerging technologies that integrate these fields to address innovative challenges.



Yechan Cha, a dedicated second grader at Asan Middle School in Asan, South Korea, has a deep passion for software and artificial intelligence and aspires to make a significant contribution to these innovative fields.



Bo-Young Kim, a key information science educator at Asan Middle School, South Korea, since 2002, earned her Bachelor's and Master's degrees in Information Science and Mathematics Education from Hoseo University

in 2002 and 2008, respectively. Ms. Kim is deeply committed to cultivating outstanding students through advanced information education and championing sustainable software training.



Jihoon Moon earned his Ph.D. in Electrical Engineering from Korea University in 2021 and worked as a postdoctoral researcher at Chung-Ang University until 2022. He has been an assistant professor in the Department

of AI and Big Data at Soonchunhyang University since 2022. Dr. Moon's research encompasses a broad spectrum, including advanced data mining, information extraction, and time-series analysis, with a keen interest in applying these methods to industrial innovations. His focus extends to sustainable solutions, advanced machine learning, deep learning applications, and explainable AI, with a special emphasis on optimizing energy management and forecasting.