

# 스마트 농업을 위한 YOLO 기반 작물 해충 탐지 모바일 애플리케이션

김삼근\*, 안재근  
한경국립대학교 컴퓨터응용수학부(컴퓨터시스템연구소)

## A YOLO-Based Crop Pests Detection Mobile Application for Smart Farming

Sam-Keun Kim\*, Jae-Geun Ahn  
School of Computer Engineering & Applied Mathematics, Hankyong National University

**요약** 작물 해충은 작물 수확량 감소의 주된 원인 중 하나로, 식량농업기구(FAO)의 추정에 따르면 전 세계적으로 해충과 질병으로 인한 작물 손실이 20~40%에 이른다. 인구 증가와 기후 변화가 이 문제를 더욱 심화시키고 있다. 이에 본 논문에서는 쌀 생산에 심각한 위협을 주는 해충을 조기에 탐지하고, 초기 피해에 대응할 수 있는 적절한 살충제 정보를 제공함으로써 수확량 감소를 줄이고 환경 오염도 완화하는 방법을 제안한다. 현실적인 실외 환경에서 수집된 데이터를 데이터 증강 기술로 확장한 후, YOLO 기반의 컨볼루션 신경망(CNN)을 사용하여 훈련시켜 95.2%의 mAP@0.5 지표로 높은 정확도를 달성한 모델을 개발하였다. 또한, 작물 해충의 종류와 권장 살충제 정보를 제공하기 위해 서버에 데이터베이스를 구축하였다. 이렇게 개발된 YOLOv8 모델과 데이터베이스를 통합하여 플랫폼 독립적으로 작동하는 PWA(Progressive Web App)를 개발했다. 이 앱은 네트워크 연결이 불안정하거나 없는 야외 환경에서도 작동 가능하며, 특히 원거리 농촌 지역에 큰 이점을 제공하여 해충 탐지와 살충제 정보 접근성을 향상시킨다.

**Abstract** Crop pests are one of the primary causes of reduced agricultural yields, with the Food and Agriculture Organization (FAO) estimating that global crop losses due to pests and diseases range from 20% to 40%. The escalating issues of population growth and climate change further exacerbate this problem. This paper proposes a method to mitigate yield reductions and environmental pollution by providing timely pest detection and appropriate pesticide information for rice production, which faces significant threats from pests. By applying data augmentation techniques to real-world outdoor data, and by training a YOLO-based convolutional neural network, our model achieved high accuracy with a 95.2% mAP@0.5 metric. Additionally, a server database was constructed to provide information on types of crop pests and recommended pesticides. Using the developed YOLOv8 model and database, we developed a platform-independent progressive web app that operates even in areas with unstable or no network connections. The app is particularly beneficial in remote rural areas, enhancing access to pest detection and pesticide information.

**Keywords** : Object Detection, YOLO Algorithm, Deep Learning, Progressive Web App, Smart Farming

---

\*Corresponding Author : Sam-Keun Kim(Hankyong National Univ.)

email: skim@hknu.ac.kr

Received April 25, 2024

Accepted July 5, 2024

Revised May 14, 2024

Published July 31, 2024

## 1. 서론

농업 분야에서 해충은 주요 문제 중 하나이다. 식량농업기구(FAO: Food and Agriculture Organization)는 이러한 해충이 매년 전 세계 농작물 생산의 20~40%를 손실시킨다고 보고했다[1]. 따라서 농업에서는 작물 해충을 조기에 탐지하여 적절한 살충제를 선택함으로써 이러한 해충의 확산을 예방하는 것이 중요하다[2].

최근 스마트 농업이 도입되면서 인공지능(AI), 정보 및 무선 통신 기술, 사물인터넷(IoT) 등이 농업의 모든 측면에 적용되어 작물 병해, 비료 사용, 관개 및 농장에서의 식물 해충에 대한 정밀 조정을 가능하게 하고 있다[3-6]. 작물 건강 모니터링은 스마트 농업의 주요 응용 분야로 간주되며, 농장의 작물 해충 상태를 파악할 수 있도록 돕는다. 그러나 곤충 해충들의 복잡한 구조와 높은 유사성으로 인해 농민들이 작물 해충을 인식하고 분류하는 것은 어려운 과제이다[7]. 또한, 전통적인 수동 탐지 방법은 비효율적이고 비용이 많이 들며 시간이 오래 걸린다. 그런데도 감염 초기 단계에서 작물 해충을 인식하는 일은 적절한 살충제를 선택하여 해충의 확산을 예방하는 농민의 활동을 크게 지원할 것이다[7]. 따라서 기존 연구에서는 기계 학습, 인공 신경망, 컴퓨터 비전 시스템 등 인공지능 기술이 농업 분야의 작물 해충 인식 문제를 해결하기 위해 널리 사용되었다.

이미지 기반 인식은 다양한 분야에서 각각의 목적을 위해 많은 연구가 제안되었다. 농업 분야에서는 컨볼루션 신경망(CNN: Convolutional Neural Network)과 같은 딥러닝 방법이 작물 해충의 자동 분류를 위한 좋은 해결책으로 적용되었다[8-10]. CNN은 전통적인 이미지 처리 방법이나 기계 학습과 달리 모든 특징을 수작업으로 입력할 필요 없이 원시 픽셀에 직접 작용하여 특징을 자동으로 도출하고 잠재된 패턴을 인식한다. 또한, CNN은 의료 이미지 분석[11-13], 기계 지능적 고장 진단[14], 건설에서의 인프라 균열 탐지[15] 등 많은 응용 분야에서 이미지 노이즈와 조명 변화를 처리하는데 강한 견고성을 입증했다.

YOLO(You Only Look Once)는 딥러닝 기술에 기반을 둔, 심층 CNN을 활용해 객체를 탐지하는 객체 탐지 알고리즘이다. YOLOv8[16]은 YOLO 시리즈 중 이전 버전들보다 개선된 특징들과 성능 향상을 이룬 최신 모델 중 하나이다. 본 논문에서는 벼 해충 데이터베이스[17]에 최신 YOLOv8 객체 탐지 알고리즘을 적용하여 이전 버전들보다 성능이 개선된 최적의 모델을 개발하였

다. 이는 객체 탐지 분야에서의 기술 진보를 나타내며, 특히 농업 분야에서 유해 해충을 탐지하는 데 효과적이다. 또한, 개발된 YOLOv8 모델을 통합하여 플랫폼 독립적으로 작동하는 PWA(Progressive Web App)를 개발하였다. 이 앱은 HTML, CSS, 자바스크립트를 사용하여 모든 기기에서 네이티브 앱처럼 작동하며, 오프라인 사용, 전체 화면 모드 등을 지원하고, 앱 스토어에 의존하지 않고도 신뢰할 수 있는 사용자 경험을 제공한다. 제안된 PWA는 실시간으로 해충을 탐지하고, 탐지된 각 해충 클래스에 대해 농민과 농업 전문가에게 적절한 살충제 사용을 안내하는 정보를 제공한다. 이는 농업 커뮤니티에 큰 혜택을 제공하며, 해충 관리를 통한 작물 보호에 기여한다.

본 논문의 구성은 다음과 같다: 2장에서는 본 논문의 관련 연구를 기술하고, 3장에서는 실험에서 사용하는 데이터셋에 대해 자세히 설명한다. 4장에서는 YOLO 기반 작물 해충 탐지 애플리케이션을 제안하고, 5장에서는 제안한 모바일 애플리케이션을 적용한 실험 결과를 제시하고 분석한다. 마지막 6장에서는 결론 및 향후 연구 방향을 기술한다.

## 2. 관련 연구

작물 해충의 자동 딥러닝 기반 자동 분류를 위해 CNN 아키텍처를 사용하는 이미지 기반 시스템들이 다양하게 제안되었다. 작물 해충 분류를 위해 심층 CNN과 전이 학습(transfer learning)을 활용한 연구가 제안되었으며, 사용된 데이터셋은 24개에서 40개의 작물 곤충 클래스를 포함한다[7]. 그들은 사전 훈련된 딥러닝 모델들보다 더 좋은 95.97%의 높은 분류 정확도를 달성했다. [18]은 스마트폰 IP 카메라 기술을 기반으로 한 자동 시스템을 개발하여 디지털 이미지와 비디옌을 사용하여 작물에 해를 끼치는 해충을 탐지하고 분류함으로써 농약 사용 의존도를 줄였다. YOLOv5 변형, YOLOv3, YOLO-Lite, YOLOR 등 다양한 YOLO 아키텍처를 활용한 이 시스템은 다양한 조건에서 7,046개의 이미지로 훈련되었다. 8개 모델의 비교 분석 결과, YOLOv5x가 23종의 해충을 신속하고 정확하게 식별하는데 가장 우수한 성능(mAP@0.5 98.3%)을 보여, 실용 농업 응용에 대한 잠재력을 입증했다. [19]는 디지털 이미지에서 해충 탐지 및 분류를 위해 YOLOv5s를 기반으로 한 향상된 심층 신경망인 YOLO-GBS를 제안한다. 추가적인 탐지

헤드를 특징으로 하며, 전역 컨텍스트 Self-Attention을 통합하고, 더 나은 특성 융합을 위해 PANet을 BiFPN으로 교체하며, 전역 컨텍스트 Self-Attention을 활용하기 위해 Swin Transformer를 도입한다. 곤충 데이터셋에서의 실험 결과, YOLO-GBS는 79.8%의 mAP를 달성하여 YOLOv5s를 5.4% 초과 달성하였고, 복잡한 시나리오에서 상당히 향상된 성능을 제공한다. [8]은 모바일 애플리케이션 내 해충 탐지를 위해 구글 넷을 기반으로 한 CNN 모델을 사용했다. 작물 해충 이미지를 입력받아 처리하는 이 연구는 93.78%의 정확도를 보이는 최상의 모델을 실험적 방법으로 선정했고, 이 모델을 스마트폰 앱에 포함하여 인도네시아 농민이 해충을 식별할 수 있도록 지원하는 앱이 되었다. 또한, 작물 해충을 식별하고 살충제를 추천하기 위해 Faster R-CNN과 클라우드 컴퓨팅을 사용하는 모바일 앱이 제안되었다[20].

### 3. 데이터셋

#### 3.1 데이터셋 수집

데이터셋은 약 69.6MB의 크기를 가지며, 잘 알려진 벼 해충 클래스 10개에 속하는 3,156개의 이미지로 구성되어 있다[17]. 각 클래스는 벼 해충과 관련된 다양한 이미지를 포함하고 있으며, 이미지 해상도는 312×312 픽셀로 표준화되어 있다. 이 데이터셋은 다양한 소스에서 수집되어 다양성을 가지며, 이로 인해 밝기, 이미지 해상도 및 환경 조건에서 차이가 나타난다. 수집된 데이터는 주로 잎에 해로운 영향을 끼치는 벼 해충의 이미지를 포함하고 있다. 즉, 여러 종류의 벼 해충 이미지를 제공하는 몇 가지 공개 데이터셋에서 선별하여 만들어졌으며, 상당 부분은 IP102 데이터셋[21]에서 가져온 것이다. 총 3,156장의 이미지가 수집되었다.

#### 3.2 데이터 애노테이션

이미지 애노테이션은 딥러닝 모델을 학습시키기 전에 수행해야 하는 중요한 전처리 단계이다. 본 논문에서는 YOLO 기반의 객체 탐지 모델에 적용할 데이터셋에 대한 바운딩 박스(bounding box)와 다각형 분할(polygon segmentation)이라는 두 가지 애노테이션 기법을 사용한다.

Fig. 1(a)의 바운딩 박스 애노테이션은 객체를 감싸는 사각형 영역을 나타내는 것으로, 이 사각형은 객체의 경계를 명확히 하고 객체가 위치한 영역을 정의한다. 주요

속성은 바운딩 박스의 좌상단 점의 좌표( $x, y$ )와 너비(width), 높이(height)이다. 바운딩 박스는 객체의 위치와 크기를 효과적으로 나타내며 간단한 형태로 애노테이션 할 수 있는 장점이 있다. Fig. 1(b)의 다각형 분할 애노테이션은 객체의 정밀한 경계를 표현하는 다각형을 사용하여 객체를 분할하는 방법이다. 이 방법은 객체의 형태를 더 정확하게 반영할 수 있으며, 더 세밀한 경계 정보를 제공한다. 주요 속성은 다각형을 구성하는 점들의 좌표이다.

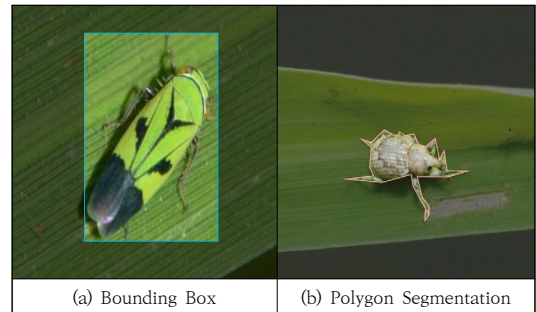


Fig. 1. Data annotation.

(a) Bounding box, (b) Polygon segmentation.

바운딩 박스를 사용하면 객체의 위치와 크기를 간단하게 표현할 수 있고, 다각형 분할을 사용하면 더 정확한 객체의 경계를 제공할 수 있다. 애노테이션 된 데이터셋은 딥러닝 모델을 학습시키는 데 사용되며, 이는 객체 탐지 작업에 활용될 수 있다.

#### 3.3 데이터 증강

데이터 증강 기법은 모델의 일반화 능력을 높이기 위하여 데이터셋을 여러 방법으로 변형시킨다. 각 증강 기법은 입력 이미지에 서로 다른 변형을 적용하여 훈련 데이터의 다양성을 증가시킨다. 본 논문에서는 이러한 증강 기법들을 사용하여 각 훈련 예제마다 3개의 변형된 출력을 생성한다. 사용된 8가지 증강 기법은 다음과 같다: 1) 자르기(crop): 최소 축소 없이 20% 최대 축소. 이미지에서 일부 영역을 자른 후 원본 크기로 다시 크기 조정. 2) 전단(shear):  $\pm 10^\circ$  수평,  $\pm 10^\circ$  수직 전단을 적용하여 이미지를 기울임. 3) 채도(saturation): -25%에서 +25% 사이의 채도 조절 적용. 4) 밝기(brightness): -15%에서 +15% 사이의 밝기 조절 적용. 5) 노출(exposure): -10%에서 +10% 사이의 노출 조절 적용. 6) 흐림(blur): 최대 2.5픽셀까지 이미지를 흐리게 만들.

7) 잘라내기(cutout): 10% 크기의 3개의 상자를 잘라내어 가림. 8) 모자이크(mosaic): 이미지를 4개의 작은 이미지로 나누고, 이를 다시 원래 이미지로 조합.

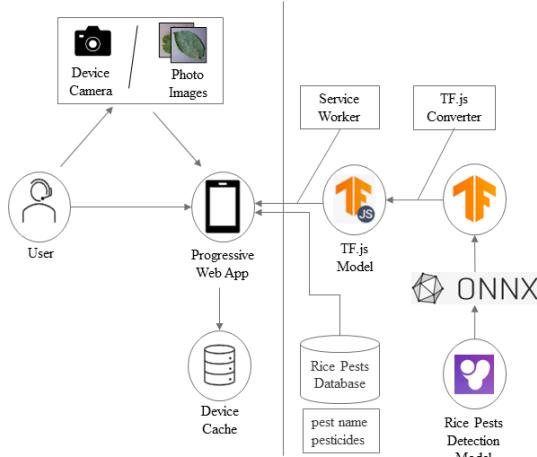


Fig. 2. Schematic diagram of the developed mobile-based system for identifying rice pests using YOLOv8.

## 4. YOLO 기반 작물 해충 탐지 시스템

제안된 시스템은 Fig. 2와 같이 벼 해충을 자동으로 탐지하기 위한 세 가지 주요 모듈로 구성된다.

### 4.1 사용자 인터페이스 모듈

사용자는 노지나 온실에서 안드로이드 기반 또는 iOS 기반의 장치를 통해 작물 해충 탐지 시스템과 인터페이스할 수 있다. 이 시스템의 PWA 사용자 인터페이스 모듈을 통해 촬영한 해충 이미지를 딥러닝 모듈에 요청하여 벼 해충을 쉽게 식별할 수 있다. 1) 기기 카메라/사진 이미지: 시스템의 입력 소스를 나타낸다. 사용자가 기기의 카메라를 사용하여 벼 해충 이미지를 캡처하고, 이 사진들이 해충 탐지에 사용된다. 2) 사용자: 기기를 사용하여 PWA와 상호 작용하는 개인이다. 사용자는 이미지를 캡처하고 해충 탐지 결과를 확인할 수도 있다. 3) PWA: 현대 웹 기능을 사용하여 사용자에게 앱과 같은 경험을 제공하는 웹 애플리케이션이다. 4) 기기 캐시: 사용자의 기기에 있는 로컬 스토리지이다. 5) 서비스 워커: 웹 애플리케이션과 네트워크 사이에서 프록시로 작용한다. PWA 뒤에 있는 핵심 기술로, 오프라인 사용을 허용한

다. 본 논문에서는 오프라인 상태에서도 작동하는 모바일 PWA를 개발하였다. 개발된 PWA는 사용자로부터 사진 이미지를 받아 탐지 모델을 통해 처리하고 결과를 표시하도록 설계되었다.

### 4.2 딥러닝 모듈

딥러닝 모듈은 YOLOv8[16]을 사용하여 작물 해충을 탐지하고 분류하는 이미지 처리를 담당한다. YOLOv8은 YOLO 객체 탐지 모델의 최신 버전이다. YOLOv8의 객체 탐지 모듈은 이미지 내의 객체를 식별하고 분류하는데 사용된다. YOLOv8은 딥러닝 기반의 CNN을 사용하여 이미지 전체를 한 번에 처리한다. 이전 버전들과 마찬가지로, YOLOv8도 이미지를 그리드로 나누고, 각 그리드 셀에 대해 여러 개의 바운딩 박스를 예측한다. 각 바운딩 박스에 대해 다음을 예측한다: 1) 바운딩 박스의 중심 (x, y), 2) 박스의 너비와 높이 (w, h), 3) 객체 존재 확률, 4) 클래스 확률. 이 모델은 이러한 예측을 통해 객체의 위치와 해당 객체의 클래스를 동시에 예측한다.

YOLOv8의 학습 과정은 바운딩 박스와 클래스 예측을 최적화하는 것을 목표로 하며, 이를 위해 바운딩 박스 손실 함수를 사용한다. 이 손실 함수는 실제 박스와 예측 박스 간의 IoU (Intersection over Union)를 최대화하기 위해 설계되었다. IoU는 컴퓨터 비전에서 객체 탐지 문제를 해결하는 데 있어 모델의 예측 성능을 평가하는 중요한 지표 중 하나이다. IoU는 예측된 바운딩 박스와 실제 바운딩 박스가 겹치는 영역을 두 박스의 합집합 영역으로 나눈 비율로 계산되며, 이 값은 0에서 1 사이이다. 값이 1에 가까울수록 모델의 예측 정확도가 높다는 것을 나타낸다.

본 논문에서는 벼 해충을 탐지하는 최적의 모델을 개발한다. 이 모델은 이미지를 입력받아 해충의 유무 및 종류를 판별하는 실제 운용 모델이다. 개발된 최적의 YOLOv8 모델은 먼저 ONNX 포맷으로 변환되고, 이후 TensorFlow 모델로 다시 변환된다. 마지막으로, TF.js 변환기를 통해 웹에서 운용 가능한 TF.js 모델로 변환되어, 브라우저상에서 자바스크립트를 사용하여 모델과 데이터베이스에 접근하고 예측 결과를 사용자에게 표시한다.

### 4.3 데이터베이스 모듈

벼 해충 데이터베이스는 벼 해충에 대한 다양한 종류의 정보를 포함하고 있다. 그중에는 해충을 통제하기 위해 사용할 수 있는 살충제 정보도 포함되어 있다. 탐지 후, 시스템은 테스트 이미지에서 탐지된 해충의 이름, 권

장 살충제 등을 사용자에게 제공하기 위해 이 데이터베이스에 질의할 수 있다. Fig. 3에서 보듯이, 데이터베이스 모듈은 딥러닝 모듈에서 탐지된 해충의 이름과 추천 살충제 정보 등을 제공한다.

#### 4.4 평가 메트릭

객체 인식 방법에서 탐지 결과는 모델의 성능을 계산하는 데 사용되는 주요 지표이다. IoU, 정밀도( precision), 재현율(recall) 및 mAP(mean Average Precision)는 바운딩 박스의 위치에 있는 객체의 탐지 결과를 평가하는 데 사용된다. 혼동 행렬(confusion matrix)은 분류기 성능을 분석하는 표준 도구이다. 모델 인식에서 IoU는 기대되는 바운딩 박스와 실제 바운딩 박스의 겹침을 Eq. (1)을 통해 계산하는 비율이다. IoU는 실제 박스와 예상 박스의 교집합과 합집합의 비율로 계산된다. 분류된 객체 탐지 결과는 IoU 값이 0.5 이상일 경우 TP(True Positive)로, 0.5 미만일 경우 FN(False Negative)으로 간주된다.

$$IoU = \frac{A \cap B}{A \cup B} \quad (1)$$

객체 탐지에서 FN은 모델이 긍정적인 결과를 탐지하지 못했음을 의미한다. IoU의 결과를 기반으로 계산되는 정밀도, 재현율 및 mAP는 객체 인식 모델의 전반적인 성능을 평가하는 중요한 지표들이다. 이들 지표는 각각 Eq.(2)-(4)로 정의되며, 얻어진 값인 TP, TN(True Negative), FP(False Positive), FN을 활용하여 계산된다.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (4)$$

$N$ : number of queries

$AP_i$ : average precision of class  $i$

## 5. 실험

### 5.1 실험 환경

실험에서 사용한 입력 이미지의 크기는 원본 이미지

크기인 312×312픽셀을 32의 배수로 조정하여 320×320픽셀로 변환하였다. 모델은 베타 해충 데이터셋을 사용하여 100 에폭(epoch) 동안 학습되었다. 자르기, 흐림, 밝기 조정, 모자이크 등 8가지 이미지 증강 기법을 적용하였다. 최적화기로는 SGD를 사용하였으며, 초기 학습률은 0.01, 모멘텀은 0.9로 설정하였다. 데이터셋은 총 3,156개의 이미지로 구성되어 있으며, 이를 학습, 검증, 테스트용으로 7:2:1의 비율로 분할하였다. 이미지 애노테이션은 Roboflow Annotate[22]를 사용하여 바운딩 박스 및 다각형 분할 기법으로 수행되었다. 이러한 과정을 통해 YOLOv8 알고리즘 학습에 적합한 데이터셋을 구성하였다. 사용된 YOLOv8 모델은 다섯 가지 유형(n, s, m, l, x)으로 나누어져 있다. 학습 데이터셋의 2,210개 이미지에 8가지 이미지 증강 기법을 적용하여 이미지 수를 6,630개로 확장하였다. 확장된 데이터셋으로 학습시킨 모델의 명칭은 YOLOv8(n, s, m, l, x)\_3x로 지정하였다.

### 5.2 알고리즘 비교

Table 1과 2는 베타 해충 데이터셋을 기반으로 한 학습 셋과 그 셋을 3배로 증강한 데이터셋에서 실험한 다섯 가지 YOLOv8 모델의 결과를 보여준다. 모델의 견고성을 평가하기 위하여 정밀도(P), 재현율(R), 그리고 mAP 지표가 사용되었다. mAP@0.5, 즉 IoU 임계값이 0.5를 초과할 때의 평균 정밀도를 나타낸다. Params(M)은 모델의 학습 결과로 얻은 가중치(파라미터)의 크기이다. Table 1과 2에서, YOLOv8x\_3x 모델은 바운딩 박스로 애노테이션된 데이터셋에서 최상의 탐지 정확성을 보여주며, 고성능 실시간 해충 탐지 모델로서의 가능성을 입증하였다.

Table 1. Comparison of evaluation results for bounding box annotation using five YOLOv8 algorithms on rice pests dataset and its threefold augmented version. P: Precision, R: Recall.

Model	Params (M)	P (%)	R (%)	mAP@0.5 (%)
YOLOv8n	6.2	75.2	72.3	76.5
YOLOv8n_3x	6.2	87.7	84.4	90.3
YOLOv8s	22.5	74.9	73.5	77.8
YOLOv8s_3x	22.5	91.3	85.2	92.2
YOLOv8m	52.0	77.0	74.7	76.0
YOLOv8m_3x	52.0	91.6	90.4	93.4
YOLOv8l	87.6	78.7	72.5	77.3
YOLOv8l_x	87.6	91.5	89.6	94.0
YOLOv8x	136.7	78.5	72.3	76.8
YOLOv8x_3x	136.7	91.8	91.0	<b>95.2</b>

Table 2. Comparison of evaluation results for polygon annotation using five YOLOv8 algorithms on rice pests dataset and its threefold augmented version. P: Precision, R: Recall.

Model	Params (M)	P (%)	R (%)	mAP@0.5 (%)
YOLOv8n	6.8	73.4	61.4	67.2
YOLOv8n_3x	6.8	86.8	76.0	82.5
YOLOv8s	22.5	76.2	63.6	68.4
YOLOv8s_3x	22.5	89.2	81.7	86.0
YOLOv8m	52.0	88.0	72.8	67.7
YOLOv8m_3x	52.0	90.1	81.9	87.4
YOLOv8l	87.6	79.4	58.0	67.4
YOLOv8l_x	87.6	86.1	85.3	89.1
YOLOv8x	136.7	73.9	62.7	66.5
YOLOv8x_3x	136.7	88.8	84.9	88.9

### 5.3 최상 모델에 대한 혼동 행렬

혼동 행렬은 학습된 신경망 모델의 성능을 시각화하고 분석하는 데 사용된다. 혼동 행렬에는 분류 시스템의 실제 및 예상 객체 분류에 관한 정보가 포함되어 있다. 혼동 행렬의 중앙에 있는 대각선은 예측 결과의 중요성을 보여준다. 세로선은 FP를 나타내고, 가로선은 FN을 나타낸다. Fig. 3의 데이터는 YOLOv8x\_3x 모델의 혼동 행렬을 보여준다.




Fig. 3. Confusion matrix.

### 5.4 YOLOv8의 탐지 결과

Fig. 4는 YOLOv8의 무작위로 선택된 검증 데이터셋에 대한 탐지 결과를 보여준다.

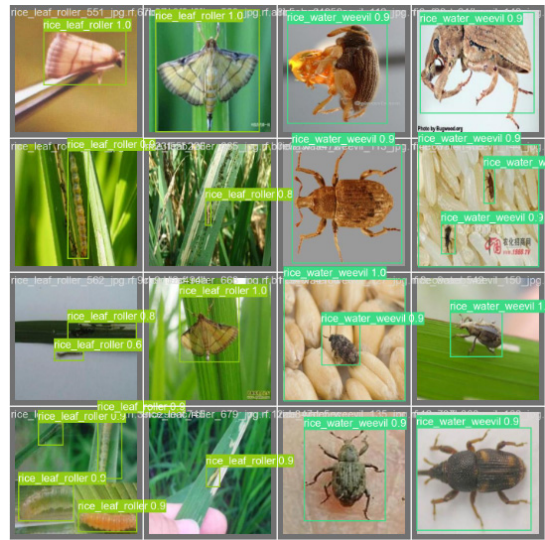


Fig. 4. Validation set prediction results.

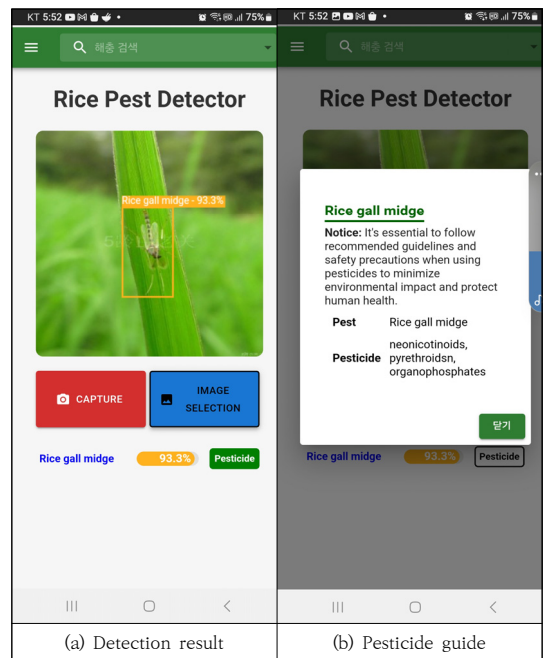


Fig. 5. User Interfaces (UI) of developed progressive web app for identifying rice pests with related pesticides.

### 5.5 웹 애플리케이션 UI

Fig. 5는 개발된 벼 해충 탐지 모바일 애플리케이션의 사용자 인터페이스를 보여준다. 이 모바일 애플리케이션은 작물 해충의 이미지를 실시간으로 입력받아 이미지



내의 해충을 탐지하고, 탐지된 해충의 종류 및 권장 살충제 정보를 사용자에게 제공한다. 이러한 제안된 방법은 스마트 농업 현장에서 실용적으로 활용될 수 있다.

## 6. 결론

본 논문에서는 10가지 잘 알려진 벼 해충 클래스를 성공적으로 분류하는 알고리즘을 개발함으로써, 농민들은 농작물에 피해를 줄 수 있는 해충을 정확히 식별하고 적시에 대응할 수 있게 되었다. 이는 작물 보호 및 생산성 향상에 직접적인 영향을 미칠 수 있다. 또한, 해충 탐지 결과를 기반으로 적절한 살충제 사용을 안내함으로써, 살충제의 남용을 줄이고 환경에 미치는 부정적 영향을 최소화할 수 있다. 이는 지속 가능한 농업 실천을 촉진하며, 농민들이 더 효율적이고 경제적인 방법으로 해충 문제를 관리할 수 있도록 돕는다. 마지막으로 기기 캐시와 서비스 워커를 활용하여 개발된 모바일 PWA는 네트워크 연결이 불안정하거나 전혀 없는 야외 환경에서도 작동할 수 있다. 이는 특히 원거리 농촌 지역에서 큰 이점을 제공하며, 해충 탐지와 관련 정보 접근성을 높여준다.

향후 연구과제로는 특정 작물에 권장되는 살충제를 포함한 새로운 농업 해충 클래스를 추가하는 것이다. 더 나아가, 개발된 모바일 기반 인식 시스템의 향후 작업으로는 실시간 해충 탐지를 위한 무선 동작 센서 네트워크를 구축하는 것이다.

## References

- [1] Adel Sarkozi, New standards to curb the global spread of plant pests and diseases, Food and Agriculture Organization of the United Nations (FAO), 2019. <https://www.fao.org/newsroom/detail/New-standards-to-curb-the-global-spread-of-plant-pests-and-diseases/en>. [Last Access: 04-07-2024].
- [2] S.T. Narendran, S.N. Meyyanathan, and B. Babu, "Review of pesticide residue analysis in fruits and vegetables. Pre-treatment, extraction and detection techniques," *Food Research International*, vol. 133, 2020. DOI: <https://doi.org/10.1016/j.foodres.2020.109141>
- [3] V Dankan Gowda, M Sandeep Prabhu, M Ramesha, Jayashree M Kudari and Ansuman Samal, "Smart Agriculture and Smart Farming using IoT Technology", *1st International Conference on Applied Mathematics, Modeling and Simulation in Engineering (AMSE)*, 2021. DOI: <https://doi.org/10.1088/1742-6596/2089/1/012038>
- [4] Jinyuan Xu, Baoxing Gu, and Guangzhao Tian, "Review of agricultural IoT technology", *Artificial Intelligence in Agriculture*, Volume 6, Pages 10-22, 2022. DOI: <https://doi.org/10.1016/j.aiia.2022.01.001>
- [5] Senthilkumar Mathi, R Akshaya, and K Sreejith, "An Internet of Things-based Efficient Solution for Smart Farming," *Procedia Computer Science*, vol. 218, pp. 2806-2819, 2023. DOI: <https://doi.org/10.1016/j.procs.2023.01.252>
- [6] S. N. M. Al-Faydi and H. N. Y. Al-Talb, "IoT and Artificial Neural Network-Based Water Control for Farming Irrigation System", *2022 2nd International Conference on Computing and Machine Intelligence (ICMI)*, IEEE, pp. 1-5, 2022. DOI: <https://doi.org/10.1109/ICMI55296.2022.9873650>
- [7] K. Thenmozhi and U. Srinivasulu Reddy, "Crop pest classification based on deep convolutional neural network and transfer learning", *Computers and Electronics in Agriculture*, Volume 164, 2019. DOI: <https://doi.org/10.1016/j.compag.2019.104906>
- [8] Yanfen Li, Hanxiang Wang, L. Minh Dang, Abolghasem Sadeghi-Niaraki, and Hyeonjoon Moon, "Crop pest recognition in natural scenes using convolutional neural networks", *Computers and Electronics in Agriculture*, Volume 169, 2020. DOI: <https://doi.org/10.1016/j.compag.2019.105174>
- [9] Xuqi Wang, Shanwen Zhang, Xianfeng Wang, and Cong Xu, "Crop pest detection by three-scale convolutional neural network with attention", *PLoS One*, 2023. DOI: <https://doi.org/10.1371/journal.pone.0276456>
- [10] Intan Nurma Yulita, Muhamad Farid Ridho Rambe, Asep Sholahuddin, and Anton Satria Prabuwo, "A Convolutional Neural Network Algorithm for Pest Detection Using GoogleNet", *AgriEngineering*, vol. 5, no. 4, pp.2366-2380, 2023. DOI: <https://doi.org/10.3390/agriengineering5040145>
- [11] Heang-Ping Chan, Ravi K. Samala, Lubomir M. Hadjiiski and Chuan Zhou, "Deep Learning in Medical Image Analysis," *Advances in Experimental Medicine and Biology*, vol. 1213, pp 3-21, 2020. DOI: [https://doi.org/10.1007/978-3-030-33128-3\\_1](https://doi.org/10.1007/978-3-030-33128-3_1)
- [12] Samir S. Yadav and Shivajirao M. Jadhav, "Deep convolutional neural network based medical image classification for disease diagnosis", *Journal of Big Data*, vol. 6:113, 2019. DOI: <https://doi.org/10.1186/s40537-019-0276-2>
- [13] Hang Yu, Laurence T. Yang, Qingchen Zhang, David Armstrong, and M. Jamal Deen, "Convolutional neural networks for medical image analysis: State-of-the-art, comparisons, improvement and perspectives", *Neurocomputing*, vol. 444, pp. 92-110, 2021. DOI: <https://doi.org/10.1016/j.neucom.2020.04.157>

- [14] Zhuyun Chen, Konstantinos Gryllias, and Weihua Li, "Intelligent Fault Diagnosis for Rotary Machinery Using Transferable Convolutional Neural Network," *IEEE Transactions on Industrial Informatics*, vol. 16, no. 1, pp. 339-349, 2020.  
DOI: <https://doi.org/10.1109/TII.2019.2917233>
- [15] Cao Vu Dung and Le Duc Anh, "Autonomous concrete crack detection using deep fully convolutional neural network," *Automation in Construction*, vol. 99, pp.52-58, 2019.  
DOI: <https://doi.org/10.1016/j.autcon.2018.11.028>
- [16] Jacob Solawetz and Francesco, "What is yolov8? the ultimate guide," *Roboflow*, 2024.  
<https://blog.roboflow.com/whats-new-in-yolov8/>. [Last Access: 04-20-2024].
- [17] Luyi-Da Quach, Quoc Khang Nguyen, Quynh Anh Nguyen, and Le Thi Thu Lan, "Rice pest dataset supports the construction of smart farming systems," *Data in Brief*, vol. 52, 2024.  
DOI: <https://doi.org/10.1016/j.dib.2024.110046>
- [18] Iftikhar Ahmad, Yayun Yang, Yi Yue, Chen Ye, Muhammad Hassan, Xi Cheng, Yunzhi Wu and Youhua Zhang, "Deep Learning Based Detector YOLOv5 for Identifying Insect Pests," *Applied Science*, vol. 12, no. 19, 2022.  
DOI: <https://doi.org/10.3390/app121910167>.
- [19] Yuqi Hu, Xiaoling Deng, Yubin Lan, Xin Chen, Yongbing Long, and Cunjia Liu, "Detection of Rice Pests Based on Self-Attention Mechanism and Multi-Scale Feature Fusion," *Insects*, vol. 14, no. 3, 2023. DOI: <https://doi.org/10.3390/insects14030280>.
- [20] Mohamed Esmail Karar, Fahad Alsunaydi, Sultan Albusaymi, and Sultan Alotaibi, "A new mobile application of agricultural pests recognition using deep learning in cloud computing system", *Alexandria Engineering Journal*, vol. 60, Issue 5, pp. 4423-4432, 2021.  
DOI: <https://doi.org/10.1016/j.aei.2021.03.009>.
- [21] Xiaoping Wu, Chi Zhan, Yu-Kun Lai, Ming-Ming Cheng, and Jufeng Yang, "IP102: a large-scale benchmark dataset for insect pest recognition," *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, *IEEE*, pp. 8779-8788, 2019.  
DOI: <https://doi.org/10.1109/CVPR.2019.00899>
- [22] Roboflow Annotate. <https://roboflow.com/annotate> [Last Access: 04-20-2024].

김 삼 근(Sam-Keun Kim)

[중신회원]



- 1988년 2월 : 숭실대학교 대학원 전자계산학과 (공학석사)
- 1998년 2월 : 숭실대학교 대학원 전자계산학과 (공학박사)
- 1992년 3월 ~ 현재 : 한경국립대학교 컴퓨터응용수학부 (컴퓨터시스템연구소) 교수

<관심분야>

인공지능, 데이터마이닝, 기계학습, IoT, 최적화

안 재 근(Jae-Geun Ahn)

[중신회원]



- 1994년 2월 : 서울대학교 대학원 산업공학과 (공학석사)
- 1997년 8월 : 서울대학교 대학원 산업공학과 (공학박사)
- 1997년 9월 ~ 현재 : 한경국립대학교 컴퓨터응용수학부 (컴퓨터시스템연구소) 교수

<관심분야>

최적화, 경영정보시스템, 데이터베이스, 데이터마이닝