

객체 탐지 기술을 이용한 돌발해충 감지 및 분류 시스템 구현

정 윤 아*, 김 세 하*, 김 동 회^o

Implementation of Detection and Classification System for Sudden Pest Using Object Detection Algorithm

Yuna Jeong*, Se-Ha Kim*, Dong-Hoi Kim^o

요 약

최근 기후변화로 인해 급증하는 돌발해충으로 인한 피해를 줄이기 위해 라즈베리 파이를 이용하여 돌발해충 감지 및 분류 시스템을 구현하였다. 이를 통해 해충의 종류를 판별하기 어려운 비전문가도 돌발해충의 발생을 인지할 수 있으며 농가에 나타난 돌발해충에 대해 신속하고 적절하게 대응할 수 있다. 본 논문에서는 돌발해충 탐지를 수행하기 위하여 객체 탐지 알고리즘 YOLOv5s와 YOLOv5x에 돌발해충 4종류로 갈색날개매미충, 열대거세미나방, 미국선녀벌레, 꽃매미를 학습을 진행하였다. 두 모델의 mAP(mean Average Precision) 및 PR 곡선(Precision-Recall curve)을 통해 정밀도 측면에서 YOLOv5x가 YOLOv5s보다 더 우수함을 확인하였고 최종 모델을 기반으로 한 예측 결과를 도출하였다.

키워드 : YOLOv5, 객체 탐지, 라즈베리파이, 돌발해충

Key Words : YOLOv5, Object detection, Raspberry pi, Sudden pest

ABSTRACT

To reduce the damage caused by the recent surge in Sudden pest due to climate change, we have built a detection and classification system of Sudden pest using raspberry Pi. Through this, even non-experts who are difficult to determine the type of pest can recognize the occurrence of Sudden pest and respond quickly and appropriately to Sudden pests appearing in farmers. In this paper, we trained YOLOv5s and YOLOv5x on a dataset consisting of four types of Sudden pest: Ricania sublimata, fall armyworm, Citrus flatid planthopper, and Spotted lanternfly to perform detection of Sudden pests. Through the mean Average Precision and Precision-Recall curve of the two models, it was confirmed that YOLOv5x was superior to YOLOv5s in terms of precision, and prediction results based on the final model were derived.

* First Author : Hanyang University, Department of Artificial Intelligence, dbsdk@hanyang.ac.kr, 학생회원

^o Corresponding Author : Kangwon National University, Department of Electrical and Electronics Engineering, donghk@kangwon.ac.kr, 정회원

* Kangwon National University, Department of Electrical and Electronics Engineering, 1155622@kangwon.ac.kr

논문번호 : 202301-012-C-RN, Received January 25, 2023; Revised March 3, 2023; Accepted April 10, 2023

I. 서론

매년 돌발해충이 발생하여 농가에 비상이 걸렸거나 피해가 발생했다는 기사 혹은 뉴스를 볼 수 있다. 돌발해충은 장소나 시기에 한정되지 않고 돌발적으로 발생하여 농작물에 피해를 주는 토착 또는 외래 해충이다. 돌발해충의 한 종류인 갈색날개매미충은 줄기, 잎 등에 붙어 그을음병을 유발하고 미국선녀벌레는 기주식물을 흡즙하여 피해를 준다. 최근 기후변화로 인하여 국내에 외래해충 및 돌발해충의 발생이 증가하고 있는 추세이다. 돌발해충으로 인한 피해의 확산을 줄이기 위해서는 돌발해충의 발생 초기에 신속하게 방제해야 한다¹⁾.

하지만 사람의 힘으로 돌발해충의 발생에 대하여 신속하고 정확하게 대응하는 데에는 한계가 있다. 객체 탐지 알고리즘과 실시간 모니터링 기술을 사용하면 더 빠르고 정확하게 돌발해충의 발생을 인지할 수 있다. 인공지능의 딥러닝(Deep Learning)은 여러 층으로 구성된 인공신경망으로, 학습 데이터에서 특징을 스스로 추출하여 학습한다. 객체 탐지(Object Detection)는 특정 이미지에 속한 관심 객체를 인식하는 기술로, 컴퓨터 비전 분야 중 하나이다. 객체 인식 기술은 사람의 시각 정보를 컴퓨터가 분석하고 해석할 수 있도록 하는 연구 분야로, 산업 전반에서 핵심 기술로 활용되고 있다²⁾. 객체 탐지 알고리즘에는 대표적으로 YOLO(You Only Look Once)가 있다. 그 중 YOLOv5는 YOLO의 version 5 모델로 2020년에 개발되어 많은 객체 검출 연구에 사용되고 있다. YOLO는 다른 객체 검출 알고리즘보다 빠른 수행 속도를 가지고 있다³⁾.

본 논문에서는 돌발해충 4종류 갈색날개매미충, 열대겨세미나방, 미국선녀벌레, 꽃매미를 카메라에 촬영되는 장면에서 감지 및 분류하는 시스템을 기술한다. 돌발해충 네 종류에 대한 이미지 데이터를 객체 감지 알고리즘 YOLOv5 에 학습시킨 후 도출된 가중치 파일을 기반으로 해충의 종류를 판별하기 어려운 비전문가도 돌발해충의 발생을 파악할 수 있고, 돌발해충 분류기 및 실시간 모니터링을 구현하여 돌발해충을 이른 시기에 대처 및 방제할 수 있다.

본 논문의 II장에서는 객체 탐지 기술을 바탕으로 YOLO 기술과 라즈베리 파이를 설명하였고 III장에서는 돌발해충 감지 및 분류 시스템의 구현에 대해 설명하였다. IV장에서는 구현 시스템의 성능 분석을 기술하였으며 V장에서는 본 논문에서 진행한 결과를 정리

하였다.

II. 객체 탐지 기술

2.1 객체 탐지 알고리즘

객체 탐지는 이미지에서 타겟이 되는 객체와 배경을 구분해서 식별화하는 자동화 기법이다. 올바른 객체를 탐지하기 위해서는 객체마다 경계 박스(Bounding Box)를 설정해서 각각의 객체를 카테고리화 시켜야 한다. 이때 활용되는 것이 CNN(Convolutional Neural Network)알고리즘이다. CNN을 사용하면 각 객체에 대한 회귀 및 분류 문제를 다룰 수 있다⁴⁾.

객체 탐지 모델은 1-stage Detector와 2-stage Detector로 구분할 수 있다⁵⁾. 2-stage Detector는 위치를 찾는 문제와 이미지 분류 문제를 순차적으로 진행한다. 한 이미지에 대해서 객체가 있을 법한 위치를 제안한 후에 각각의 위치에 대해서 특징을 추출하여 이것을 바탕으로 분류를 수행한다. 2-stage의 알고리즘으로는 R-CNN, Fast R-CNN 등이 있다^{6)[7]}. 1-stage Detector는 위치를 찾는 문제와 이미지 분류 문제를 한 번에 해결한다. 1-stage Detector는 2-stage보다는 속도는 빠르지만 정확도가 비교적 낮다는 특징이 있으며 대표적인 알고리즘으로는 본 논문에서 다루는 YOLO가 있다.

2.2 YOLO

YOLO는 2-stage Detector의 대표적인 객체 탐지 모델이다. YOLO는 객체 인식에 대한 전체적인 구조를 간소화하여 훈련 및 객체 탐지 속도를 크게 향상시켰다. 입력된 이미지 데이터 전체를 일련의 통합 네트워크를 통해 수행하기 때문에 속도가 빠르다. 2016년에 YOLO의 첫 번째 version이 공개되었고, 현재까지 성능을 개선한 후속 모델이 연구되고 있다⁸⁾. 본 논문에서는 YOLOv5를 사용하여 돌발해충 탐지를 수행하

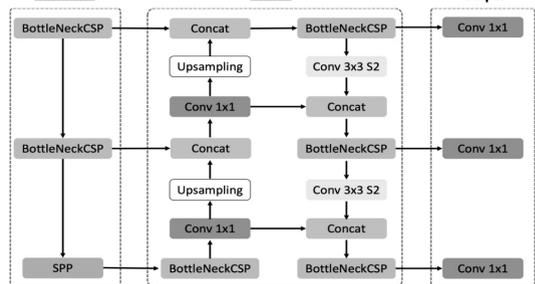


그림 1. YOLOv5의 구조
Fig. 1. Structure of YOLOv5

였다.

그림 1은 YOLOv5 모델의 구조를 보여준다. YOLO의 신경망 구조는 CNN으로 디자인된 모델이다. YOLO 알고리즘의 24개의 컨벌루션 계층은 백본망으로, 특징을 추출하는 역할을 한다. 2개의 전결합 계층을 통해 컨벌루션 계층에서 추출된 특징을 바탕으로 전결합 계층에서 클래스 확률과 경계 박스를 예측한다. 백본망은 특징을 추출하는 것이 주된 목적이기 때문에 특징 추출에 최적화된 모델인 GoogLeNet의 모델을 본따서 사용한다⁹⁾.

2.3 라즈베리 파이

라즈베리 파이(Raspberry Pi)는 영국에서 개발된 싱글 보드 컴퓨터이다¹⁰⁾. 라즈베리 파이에서 무선 인터넷 연결, USB 포트 연결 등 일반 PC에서 수행되는 작업을 할 수 있다. 라즈베리 파이는 교육용 도구로 개발되었기 때문에, 다양한 프로그래밍 언어를 사용할 수 있도록 컴파일러가 내장되어있다. 또한 다양한 입출력 장치를 연결할 수 있어서 넓은 범위에서 활용되고 있다¹¹⁾.

본 논문에서는 실시간 객체 탐지를 수행하기 위해 분류 모델을 적용할 하드웨어로 라즈베리 파이를 선정하였다. 라즈베리 파이에 카메라를 연결하여 촬영되는 화면에서 모델이 학습한 돌발해충이 등장하면 탐지를 수행하여 경계 박스가 나타날 수 있도록 하였다.

III. 돌발해충 감지 및 분류 시스템 구현

그림 2는 본 논문에서 제안한 시스템을 구현하기 위해 YOLOv5s와 YOLOv5x에 학습을 진행한 순서도이다. 이미지 분류를 위하여 사전에 설정한 네 종류의 돌발해충 이미지를 크롤링하고, LabelImg 프로그램을 통한 이미지 라벨링으로 훈련 데이터셋을 준비하였다. YOLOv5의 분류 클래스 정보를 돌발해충의 네 가지 클래스로 변경한 후, YOLOv5s 모델에 훈련을 수행하였다. YOLOv5x 모델에 대하여 같은 과정을 반복하고 결과를 확인하였다.

3.1 학습 데이터 준비

우리나라에서 빈번하게 나타나는 열대거세미나방, 갈색날개매미충, 꽃매미 그리고 미국 선너벌레를 모델에 학습시키기 위하여 클래스마다 100장의 이미지 데이터를 크롤링하였다. 그림 3과 같은 데이터 증강기법을 이용하면 이미지를 분류할 때 다양한 잡음에 대비해서 올바른 분류를 수행할 수 있다¹²⁾. 기존의 이미지

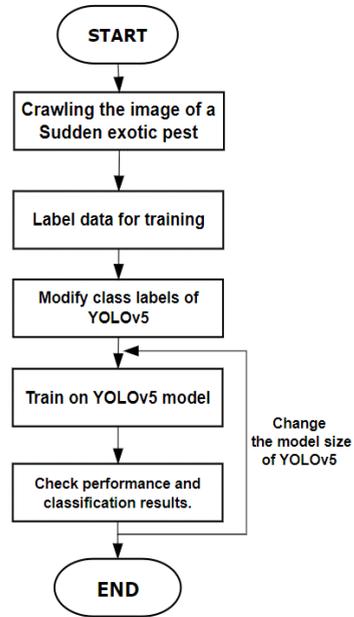


그림 2. YOLOv5 훈련 과정 순서도
Fig. 2. Flowchart of YOLOv5 training Process

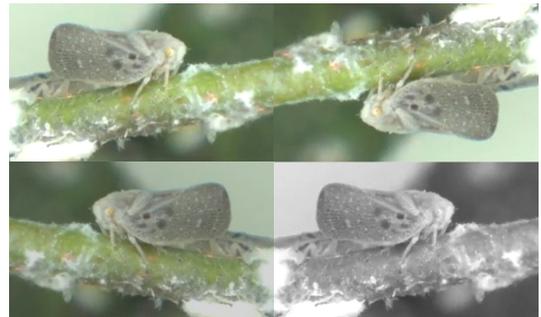


그림 3. 데이터 증강 기법을 적용한 미국선너벌레 이미지
Fig. 3. Image of citrus flatid planthopper with data augmentation

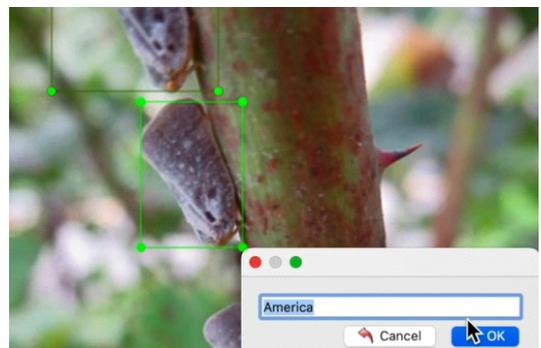


그림 4. 데이터 라벨링
Fig. 4. Data Labeling

에 최우 반전 및 상하 반전을 적용하여 각 클래스당 300장의 학습 데이터를 구축하였다.

돌발해충 이미지를 YOLOv5 모델에 학습시키기 위해 LabelImg를 통해 데이터에서 돌발해충이 위치한 영역에 바운딩 박스를 설정하고, 라벨링을 진행하였다. 미국선녀벌레, 꽃매미, 열대거세미나방, 갈색날개 매미충을 각각 America, Flower, Geosemi, Brown으로 라벨링하였다. 아래 그림 4는 LabelImg를 사용한 라벨링 과정을 보여준다.

3.2 YOLOv5 모델에 학습 진행

모델 학습은 구글에서 제공하는 구글코랩(Google Colab; Google Colaboratory)에서 수행하였다. 구글 코랩은 구글에서 제공하는 주피터 노트북(Jupyter Notebook)을 기반으로 하는 가상 개발 환경이다. 구글 코랩은 GPU를 일정 시간 동안 무료로 사용이 가능하며 아래의 그림 5는 구글 코랩의 구조를 나타낸다¹³⁾.

YOLOv5는 n, s, m, l, x 사이즈의 모델로 구분되며, 이는 백본을 구성하는 depth_multiple과 width_multiple 변수의 값으로 결정된다. depth_multiple은 모델의 깊이를 결정하는 변수로, 값이 클수록 모델의 깊이도 증가한다. width_multiple은 컨볼루션 필터의 개수를 결정하는 변수로, 값이 증가함에 따라 필터의 개수도 증가한다. YOLOv5 모델의 사이즈가 증가함에 따라 depth_multiple과 width_multiple의 값도 증가하며,

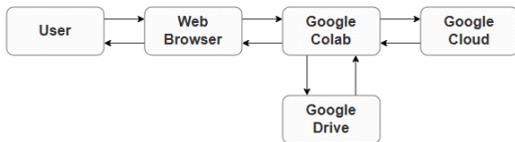


그림 5. 구글 코랩 구조
Fig. 5. Google colab structure

표 1. YOLOv5 사이즈 별 depth_multiple와 width_multiple
Table 1. depth_multiple and width_multiple by size of YOLOv5

parameter size of YOLOv5	depth_multiple	width_multiple
n	0.33	0.25
s	0.33	0.5
m	0.67	0.75
l	1.0	1.0
x	1.33	1.25

모델의 사이즈에 따른 두 변수의 설정값은 표 1과 같다.

본 논문에서는 YOLOv5s 모델과 YOLOv5x 모델에 돌발해충 데이터셋을 학습시킨 후, 두 모델의 성능을 비교하였다. 모델 학습 시 이미지 데이터를 640×640으로 resizing 했고, Epochs는 300, batch size는 16으로 설정하여 학습을 진행하였다.

3.3 라즈베리 파이 연결 및 구동

카메라에 촬영되는 화면에 나타나는 돌발해충을 탐지하기 위하여 라즈베리 파이와 웹캠을 사용하였다. 본 논문에서 사용된 라즈베리 파이의 사양은 다음 표 2와 같다.

라즈베리 파이의 USB 포트에 웹캠을 연결하여 실시간으로 카메라가 구동될 수 있도록 하였다. 그림 6은 카메라가 연결된 라즈베리 파이를 보여주고 있다.

라즈베리 파이의 화면을 PC에서 원격 제어하기 위하여 VNC(Virtual Network Computing) Viewer를 이용하였다. VNC Viewer는 동일 IP 주소를 사용하며 네트워크에 접속된 컴퓨터에 원격으로 접속 및 제어

표 2. 라즈베리 파이 4의 사양
Table 2. Specifications of Raspberry Pi

Raspberry Pi 4 model B	
Memory	8GB LPDDR4
CPU	1.5GHz ARM Cortex-A72
GPU	Broadcom Video Core VI MP2 500MHz
Size	85.60 x 56.5mm
Wi-Fi	802.11g Dual-Band
USB support	USB 3.0 2 port
Sound	3.5mm jack, 2x micro HDMI
Video	composite 2x micro HDMI



그림 6. 카메라가 연결된 라즈베리 파이
Fig. 6. Raspberry Pi with Camera Connected

를 가능하게 하는 소프트웨어이다. 라즈베리 파이에 돌발해충이 학습된 모델의 가중치 파일을 비롯한 YOLOv5 구성 요소를 내려받아 연결된 카메라를 통해 돌발해충 탐지를 수행할 수 있게 하였다.

3.4 돌발해충 감지 및 분류 수행

카메라를 통해 실시간으로 돌발해충 감지 및 분류를 수행하기 위하여 라즈베리 파이에 연결된 카메라와 YOLOv5x에 돌발해충을 학습하고 도출된 가중치 파일을 함께 실행하였다. 라즈베리 파이에 연결된 카메라에 촬영되는 화면을 기반으로 네 가지 돌발해충에 대한 객체 탐지가 실행된다. 그림 7은 촬영되는 화면에서 돌발해충을 감지 및 분류하는 결과를 보여주고 있다. 모델에 학습된 네 가지 돌발해충이 촬영되는 화면에 나타나면, 가중치 파일을 기반으로 돌발해충이 감지된다. 감지된 객체를 중심으로 경계 박스가 표시되고, 경계 박스 상단에 객체의 클래스와 정확도가 나타난다. 정적인 객체 및 움직이는 객체를 대상으로 실시간 감지 및 분류 작업을 수행할 수 있다.

위와 같이 카메라 모듈이 연결된 라즈베리 파이는 휴대용 돌발해충 분류기로 사용할 수 있다. 라즈베리 파이와 호스트의 PC를 동일한 네트워크에 접속시킨다면 실시간 모니터링을 통해 농가에서 떨어져 있는 상황에도 농가에 돌발해충이 나타났음을 빠르게 인지할 수 있다. 나아가 어플리케이션에 적용한다면 접근성이 용이한 돌발해충 감지 및 분류 시스템을 구현할 수 있다.

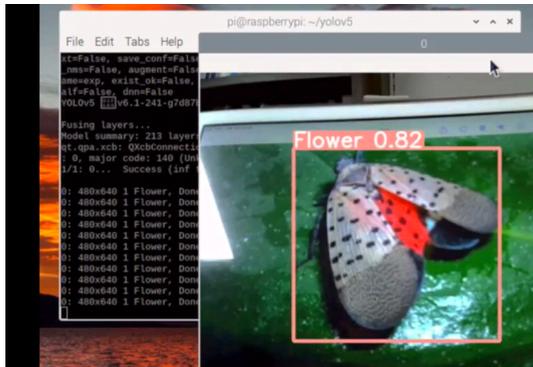


그림 7. 돌발해충 감지 및 분류
Fig. 7. Detection and classification of sudden pest

IV. 제안 시스템의 성능 분석

본 논문에서는 객체 탐지 모델인 YOLOv5의 YOLOv5s와 YOLOv5x에 돌발해충 데이터를 학습시

		Predicted Values		
		1	2	3
Actual Values	1	a	b	c
	2	d	e	f
	3	g	h	i

그림 8. 다중 분류의 혼동행렬
Fig. 8. Confusion Matrix for Multi-class classification

켜 돌발해충 탐지 모델을 제작하고, 라즈베리 파이에 연결된 카메라를 통해 실시간 돌발해충 탐지를 수행하였다.

혼동행렬(Confusion Matrix)은 예측 모델 성능의 평가 지표 중 하나이다. 혼동행렬에서는 각 클래스에 대한 정밀도(Precision)와 재현율(Recall)을 구할 수 있다. 정밀도와 재현율은 각각 수식 (1), (2)와 같이 정의된다.

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

각 class의 TP, TN, FP, FN은 혼동행렬로부터 구할 수 있다. 그림 8은 세 가지 클래스 class 1, class 2, class 3을 분류하는 경우의 혼동행렬이다. class 1의 TP는 class 1을 정확하게 분류한 경우로, 그림 8의 a에 해당한다. class 1의 TN은 class 1이 아닌 class 즉, class 2와 class 3에 해당하는 값으로, e+f+h+i에 해당한다. class 1의 FP는 class 1이라고 예측했으나 잘못 분류한 경우로, d+g이다. class 1의 FN은 class 1을 다른 class로 잘못 예측한 경우로, b+c에 해당한다. 따라서 그림 8에서 class 1의 정밀도는 a/(a+d+g)가 되고, 재현율은 a/(a+b+c)가 된다

그림 9와 그림 10은 모델 학습 후 도출된 YOLOv5s와 YOLOv5x의 혼동행렬이다. 각 값은 행에 해당하는 클래스의 객체를 열에 해당하는 클래스로 예측한 비율이다. 즉, 행과 열의 클래스가 같은 위치의 값은 해당 클래스의 정밀도와 같다.

YOLOv5s 모델의 혼동행렬에서 미국선녀벌레, 꽃매미, 열대거세미나방, 갈색날개매미충의 정밀도는 순서대로 0.35, 0.18, 0.22, 0.21로 측정되었다. YOLOv5x 모델의 혼동행렬에서 꽃매미, 열대거세미나방, 갈색날개매미충의 정밀도는 각각 1.00, 1.00, 1.00,

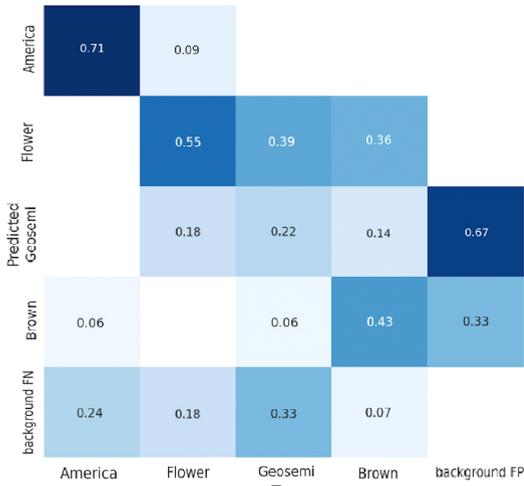


그림 9. YOLOv5s의 혼동행렬
Fig. 9. Confusion matrix of YOLOv5s

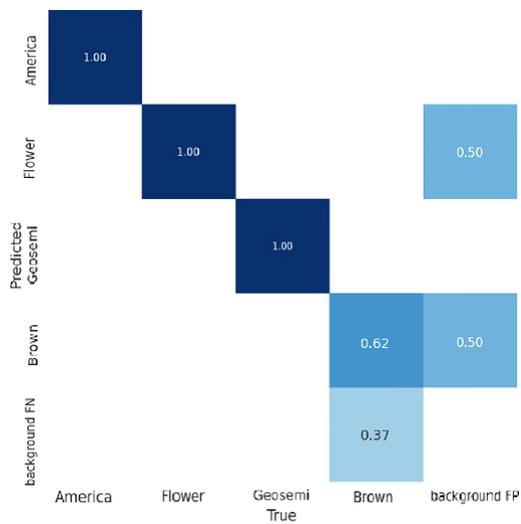


그림 10. YOLOv5x의 혼동행렬
Fig. 10. Confusion matrix of YOLOv5x

표 3. 모델에 따른 각 클래스의 정밀도
Table 3. Precision of each class according to the model

	America	Flower	Geosemi	Brown
YOLOv5s	0.71	0.55	0.22	0.43
YOLOv5x	1.00	1.00	1.00	0.62

0.62로 측정되었다. 표 3은 그림 9과 그림 10에 나타난 혼동행렬로 측정된 각 클래스의 정밀도를 정리하여 나타낸 것이다.

PR 곡선(Precision-Recall curve)은 설정한

confidence 레벨에 대한 threshold 값에 따라 변화하는 정밀도 및 재현율을 나타낸다. AP(Average Precision)는 PR 곡선에서 그래프 아래의 면적에 해당하는 값이다. mAP(mean Average Precision)는 객체 탐지 모델의 성능 지표로서, 각 클래스의 AP에 대한 평균이다¹⁴⁾. 그림 11과 그림 12는 각각 돌발해충을 학습한 YOLOv5s 모델과 YOLOv5x 모델의 PR 곡선이다.

표 4와 표 5는 YOLOv5s와 YOLOv5x의 PR곡선에서 나타난 mAP와 각 클래스의 AP 결과를 정리한 표이다. YOLOv5s 모델의 mAP는 0.589로,

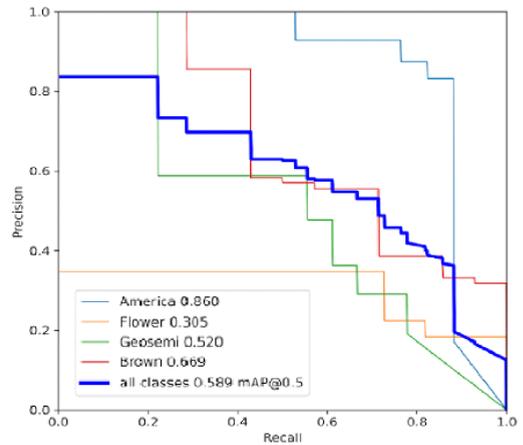


그림 11. YOLOv5s의 PR 곡선
Fig. 11. PR curve of YOLOv5s

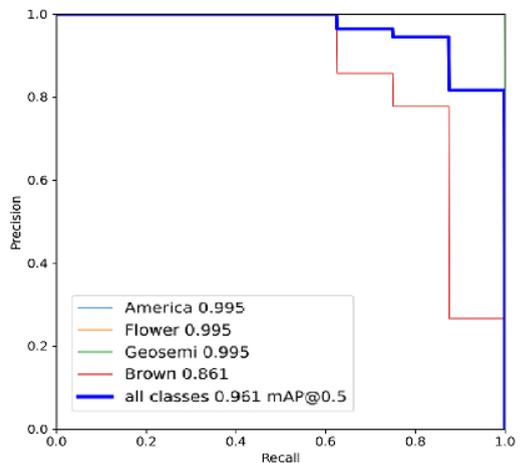


그림 12. YOLOv5x의 PR 곡선
Fig. 12. PR curve of YOLOv5x

표 4. YOLOv5s의 mAP와 각 클래스의 AP
Table 4. mAP and AP of each class of YOLOv5s

America	Flower	Geosemi	Brown	mAP
0.860	0.305	0.520	0.669	0.589

표 5. YOLOv5x의 mAP와 각 클래스의 AP
Table 5. mAP and AP of each class of YOLOv5x

America	Flower	Geosemi	Brown	mAP
0.995	0.995	0.995	0.861	0.961

YOLOv5x 모델의 mAP는 YOLOv5s 모델보다 약 0.372만큼 더 높은 0.961로 나타났다.

표 6은 YOLOv5s 모델과 YOLOv5x 모델의 학습에 소요되는 시간이다. YOLOv5x 모델이 YOLOv5s 모델보다 약 5.3배의 시간이 더 소요된다.

그림 13은 학습이 완료된 YOLOv5x 모델을 사용하여 돌발해충 이미지를 대상으로 탐지를 수행한 결과이다.

표 6. YOLOv5s와 YOLOv5x의 학습시간
Table. 6. training time of YOLOv5s and YOLOv5x

	YOLOv5s	YOLOv5x
time for training	1H 30m	8H

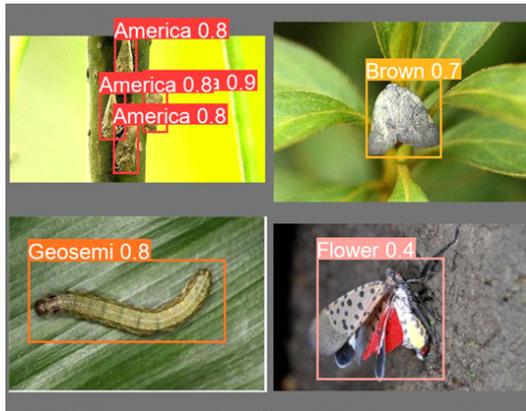


그림 13. validation data의 예측
Fig. 13. prediction of Validation data

V. 결 론

본 논문에서는 YOLOv5s와 YOLOv5x에 네 가지 돌발해충의 이미지 데이터셋을 학습시키고, 두 모델의 성능을 비교하였다. YOLOv5x의 학습시간이

YOLOv5s보다 더 길었으나, mAP 및 각 클래스의 정밀도 성능은 YOLOv5x 모델이 더 높게 나타났다. 네 가지 돌발해충을 학습한 YOLOv5x 모델을 라즈베리 파이에 옮긴 후, 연결된 카메라를 통해 실시간 탐지를 수행하도록 하였다.

돌발해충 감지 및 분류 시스템을 사용하면 해충의 종류를 육안으로 판별하는 데에 어려움이 있는 비전문가도 돌발해충의 발생 여부를 빠르게 알 수 있다. 또한 초기 방제가 중요한 돌발해충에 대해 알맞은 농약을 적절한 시기에 살포할 수 있다.

본 논문의 돌발해충 분류 모델은 학습 데이터가 풍부하지 않았기 때문에 특정 클래스에 대한 정밀도가 다소 낮은 경향을 보였다. 이후 양질의 돌발해충 이미지 데이터가 더 확보된다면 높은 정밀도로 다양한 돌발해충을 탐지하는 모델이 도출되어 더욱 발전된 돌발해충 탐지를 구현할 수 있을 것으로 기대된다.

References

- [1] M. J. Kong, K. H. Kim, S. W. Jeon, K. H. Kwon, and S. I. Song, "Prediction of the time of occurrence and timely control of exotic sporadic pests in agricultural land," in *Proc. KAIS Spring Conf.*, pp. 707-708, Jeju Island, Korea, Jul. 2021.
- [2] Z.-Q. Zhao, P. Zheng, S. -T. Wu, and X. Wu, "Object detection with deep learning : A review," *IEEE Trans. Neural Netw. and Learn. Syst.*, vol. 30, no. 11, pp. 3212-3232, Nov. 2019. (<https://doi.org/10.1109/TNNLS.2018.2876865>)
- [3] J. S. Lee, S. K. Lee, D. W. Kim, S. J. Hong, and S. I. Yang, "Trends on object detection techniques based on deep learning," *Electron. and Telecommun. Trends*, vol. 33, no. 4, pp. 23-32, Aug. 2018.
- [4] J. Gu, Z. Wang, L. Ma, A. Shahroudy, B. Shuai, T. Lui, X. Wang, G. Wang, J. Cai, and T. Chen, "Recent advances in convolutional neural networks," *Pattern Recognition*, vol. 77, pp. 354-377, May 2018. (<https://doi.org/10.1016/j.patcog.2017.10.013>)
- [5] L. Du, R. Zhang, and X. Wang, "Overview of two-stage object detection algorithms," *J. Physics: Conf. Series*, vol. 1544, Mar. 2020.

238, Jeonnam, Korea, Oct. 2021.

(<https://doi.org/10.1088/1742-6596/1544/1/012033>)

- [6] H. J. Kim, J. M. Lee, K. H. Bae, and Y. D. Eo, "Application research on obstruction area detection of building wall using R-CNN technique," *J. Cadastre & Land InformatiX*, vol. 48, no. 2, pp. 213-225, Dec. 2018. (<https://doi.org/10.22640/lxsiri.2018.48.2.213>)
- [7] R. Girshick, "Fast R-CNN," in *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*, pp. 1440-1448, Santiago, Chile, Dec. 2015. (<https://doi.org/10.1109/ICCV.2015.169>)
- [8] H. J. Lee, J. H. Lee, and H. C. Jung, "Implementation of recyclable trash object detection model based on YOLOv5," in *Proc. IEIE 2021 Autumn Annu. Conf.*, pp. 1066-1069, Incheon, Korea, Nov. 2021.
- [9] Y. G. Kim and E. Y. Cha, "Streamlined GoogLeNet algorithm based on CNN for Korean character recognition," *J. KIICE*, vol. 20, no. 9, pp. 1657-1665, Sep. 2016. (<https://doi.org/10.6109/jkiice.2016.20.9.1657>)
- [10] C. W. Zhao, J. Jegatheesan, and S. C. Loon, "Exploring IOT application using raspberry pi," *Int. J. Comput. Netw. and Appl.*, vol. 2, no. 1, pp. 27-34, Jan. 2015.
- [11] Y. S. Park, S. J. An, and Y. J. Lee, "A study on the programming education using raspberry pi," in *Proc. Korean Soc. Comput. Inf. 2014 Winter Conf.*, pp. 451-453, Daejeon, Korea, Jan. 2014.
- [12] M. G. Kim and H. J. Bae, "Data augmentation techniques for deep learning-based medical image analyses," *J. Korean Soc. Radiology*, vol. 81, no. 6, pp. 1290-1304, Nov. 2020. (<https://doi.org/10.3348/jksr.2020.0158>)
- [13] M. J. Nelson and A. K. Hoover, "Notes on using Google colab in AI education," in *Proc. 2020 ACM Conf. ITiCSE '20*, pp. 533-534, New York, United States, Jun. 2020. (<https://dl.acm.org/doi/10.1145/3341525.3393997>)
- [14] T. K. Kim and H. C. Cho, "A research on the fainting monitoring system using deep learning," in *Proc. 2021 CICS'21*, pp. 237-

정 윤 아 (Yuna Jeong)



2023년 2월 : 강원대학교 전기전
자공학과 졸업
2023년 3월~현재 : 한양대학교
인공지능학과 석사과정
<관심분야> 인공지능, 컴퓨터 비
전, 멀티모달

김 세 하 (Se-Ha Kim)



2023년 2월 : 강원대학교 전기전
자공학과 재학 중
<관심분야> 인공지능, 딥러닝,
음질 향상, 음성인식

김 동 회 (Dong-Hoi Kim)



2005년 2월 : 고려대학교 전파공
학과 박사
1989년 1월~1997년 1월 : 삼성
전자 전임연구원
2000년 8월~2005년 8월 : 한국
전자통신연구원 선임연구원
2006년 3월~현재 : 강원대학교 IT
대학 전기전자공학과 정교수
<관심분야> 인공지능, 이동통신공학, 차세대네트워크