

데이터 증강 기술을 활용한 딥러닝 기반의 노린재 탐지 연구

임지선¹, 최윤성², 박종혁^{3*}

¹국민대학교 데이터사이언스학과, ²(주)온투인, ³국민대학교 시빅데이터융합경영학과

Deep Learning-Based Hemiptera:Heteroptera Detection Using Data Augmentation

Ji-Sun Lim¹, Yun-Sung Choi², Jong-Hyuk Park^{3*}

¹Department of Data Science, Kookmin University

²Ontwoin

³Department of AI, Big Data & Management, Kookmin University

요약 병충해 예방 및 관리는 농업 분야에서 중요한 주제이다. 본 연구는 농작물에 피해를 주고 있는 노린재목(Hemiptera)을 탐지하여 병충해로 인한 피해를 최소화하고, 지속 가능한 농업 생산을 위한 딥러닝 알고리즘을 개발하고자 수행되었다. 이에 YOLOv5s와 YOLOv8n과 같은 객체 탐지(Object Detection)의 대표적인 모델을 활용하여 종이 다양하고 작은 객체인 노린재를 효과적으로 탐지하는지 실험하였다. 또한 클래스 간의 불균형 상황에서의 오탐지를 감소시키기 위한 방법으로 데이터 증강(Data Augmentation) 기법 중 뒤집기, 회전, 크기 조정, 곱하기 그리고 대비와 같은 기법을 도입하여 모델의 성능을 비교하였다. 종합적으로, YOLOv8n을 사용한 전체 클래스에 대한 데이터 증강 시 '곱하기'와 '대비' 기법을 사용했을 때 mAP50 0.992로 성능이 가장 높게 나왔다. 특히, 이 기법은 유독 오탐지가 잦았던 '먹노린재' 클래스 대상으로도 mAP50 0.995로 가장 높게 나왔다. 이어 '먹노린재' 데이터만 증강하여 추가한 실험과 YOLOv5s 모델에서도 유사한 결과를 얻었다. 이러한 실험 결과를 통해 데이터 증강기법을 적용한 인공지능 모델이 노린재 탐지에서 성능 향상에 기여할 수 있음을 확인할 수 있었으며, 이러한 연구 결과는 농업 분야의 병충해 예방과 관리에서 인공지능을 활용하는 데 도움이 될 것으로 기대한다.

Abstract Pest prevention and management are critical topics in the field of agriculture. This study was conducted to determine ways to minimize damage caused by pests, specifically focusing on detection of the Hemiptera that harm crops, and to develop a deep learning algorithm for sustainable agricultural production. In this context, object detection models such as YOLOv5s and YOLOv8n were utilized to experiment with effective detection of Hemiptera, which are diverse and small in size. Additionally, to reduce false detection in situations of class imbalance, data augmentation techniques were introduced, including flipping, rotating, resizing, multiplying, and adjusting contrast, and the performance of the models was compared. Using YOLOv8n, the application of multiply-and-contrast techniques in data augmentation for all classes achieved the highest performance overall (mAP50 of 0.992). Notably, this approach yielded the highest score for the Meok Norinjae class (*Scotinophara lurida*), which was prone to frequent false detection (mAP50 of 0.995). Subsequently, similar results were obtained in the experiment with YOLOv5s, added by augmenting only the Meok Norinjae data. These experimental outcomes demonstrate that artificial intelligence models enhanced with data augmentation techniques can contribute to performance improvements in detecting Hemiptera. Such findings are expected to assist in the utilization of artificial intelligence for pest prevention and management in agriculture.

Keywords : Hemiptera:Heteroptera, Deep Learning, Object Detection, Data Augmentation, Data Imbalance

본 논문은 국민대학교와 (주)온투인의 연구과제로 수행되었음.

*Corresponding Author : Jong-Hyuk Park(Kookmin Univ.)

email: jonghyuk@kookmin.ac.kr

Received January 15, 2024

Revised March 7, 2024

Accepted April 5, 2024

Published April 30, 2024

1. 서론

매년 농가에서는 노린재로 인한 경제적 손실이 매우 큰 것으로 평가되고 있다[1]. 노린재목은 파리목(Diptera), 딱정벌레목(Coleoptera), 벌목(Hymenoptera), 나비목(Lepidoptera)에 이어 다섯 번째로 큰 곤충 그룹으로, 식물성과 포식성, 외부 기생 및 혈액 섭취와 같은 다양한 급식 습성을 가지고 농작물에 부착하여 피해를 준다[2]. 세부적으로 노린재류 곤충(Hemipteroid)은 총 140여 개과에 8만 3천여 종이 알려져 있으며, 이중 각지벌레류, 진딧물류, 방패벌레류, 노린재류가 피해를 주로 일으키는 해충들로 주목받고 있다. 특히, 노린재아목(Heteroptera)은 주로 벼, 농작물, 과수 등의 다양한 부위에서 기생하여 조직 변형, 식물 병 매개, 광합성 및 생장 저해를 일으킨다[3]. '국가농작물병해충관리시스템(NCPMS)'의 '병해충별 도감정보'에 따르면 노린재는 가지, 감, 감귤, 강낭콩, 고구마, 고추, 논벼, 들깨, 무, 배추, 보리, 복숭아, 블루베리, 사과, 수수, 아욱, 완두 등 국내에서 생산 중인 약 60여 가지 농작물에 서식하며 해를 입힌다. 예를 들어 애무늬고리초록장님노린재의 경우 입에서 즙액을 흡즙하는데, 이는 잎의 표면에 반점을 발생시키고 그 상처 부위에 구멍을 만들면서 잎의 생육이 위축되고 기형으로 변하게 만든다[4]. 이러한 노린재에 의한 피해를 예방하는 것은 농업의 안전성, 수익성 및 품질을 보장하기 위해서 필수적이다[5]. 현재 농가에서는 해충 방제 및 퇴치를 위해 대부분 농약에 의존하고 있으나, 농약은 해충의 저항성, 환경 오염, 건강 문제 등 다양한 문제를 일으킨다. 이러한 문제에 대한 해결책 중 하나는 해충 모니터링을 통해 해충을 조기에 발견하고 농약의 과도한 사용을 방지하는 것이다. 이 시스템은 해충을 모니터링하고 필요할 때 정확한 양의 농약을 살포함으로써 농약 사용을 최소화하는 데 중요한 역할을 한다[6]. 본 연구에서는 이러한 해충 모니터링 시스템에 인공지능을 활용하는 것을 제안한다.

현재는 인공지능과 사물인터넷(IoT:Internet of Things)의 발전으로 스마트 해충 모니터링(SPM: Smart Pest Monitoring)이 등장하여 효율적인 해충 감지를 돕고 있다[6]. 해충 분야의 경우 이미지 기반 딥러닝 객체 탐지 및 분류 기술을 활용하여 해충 자체를 탐지하거나 유사한 종을 구분하는 연구가 이루어지고 있다[6,8-17]. 노린재의 경우 외국에서는 2022년 '장님노린재과(Miridae)'를 활용하여 매우 유사한 종에 대한 이미지 기반 분류(Classification) 연구가 이루어진 것으로 확인되었지만

[7] 국내에서는 아직 인공지능 기술 활용 연구가 미흡한 실정이다. 이에 본 연구는 해충 분야 연구에서 노린재를 대상으로 한 인공지능 객체 탐지 연구가 이루어지지 않은 점을 고려하여 이를 새롭게 도입하고, 노린재에 대한 정확한 탐지가 가능한 모델을 제안한다. 노린재는 앞서 살펴본 것과 같이, 여러 농작물에 심각한 피해를 입히는 데 이를 효과적으로 관리하고 대응하기 위한 정확한 탐지 기술이 필요하다. 본 연구는 이러한 연구를 통해 농업 분야에서 농작물의 품질과 생산량 향상에 기여할 수 있는 것으로 기대한다. 또한, 이 기술은 농업 분야뿐만 아니라 병원성 벌레나 해충을 조기에 감지하여 질병 전파를 방지하고 치료에 대한 조치를 취하거나, 생태계의 균형을 유지하고 생물 다양성을 보호하기 위한 유해충의 감시와 관리 등 공공 보건 및 환경 보호에도 적용될 수 있다는 점에서 확장 가능성을 더하고 있다.

이 연구의 최종 목표는 농촌 현장에 출현한 노린재를 신속하게 탐지하고, 관련 담당자에게 알려 병충해를 예방하는 데 활용할 수 있는 인공지능 모델을 개발하는 것이다. 실험은 노린재 이미지를 수집하고, 객체 탐지 모델의 성능을 비교하고 데이터 증강 실험을 통해 최종적으로 클래스 불균형과 작은 객체에 강건한 노린재 탐지 모델을 구축한다. 실험 과정은 Fig. 1과 같이 전개된다.

본 논문의 구성은 다음과 같다. 이어지는 2장에서는 데이터셋 수집과 사용할 딥러닝 객체 탐지 모델을 제안한다. 3장에서는 모델의 성능 비교와 데이터 증강 및 성능 평가 결과를 제시한다. 마지막으로 4장에서는 본 연구의 결론과 한계, 그리고 향후 연구 방향 및 실제 응용 가능성에 대해 논의한다.

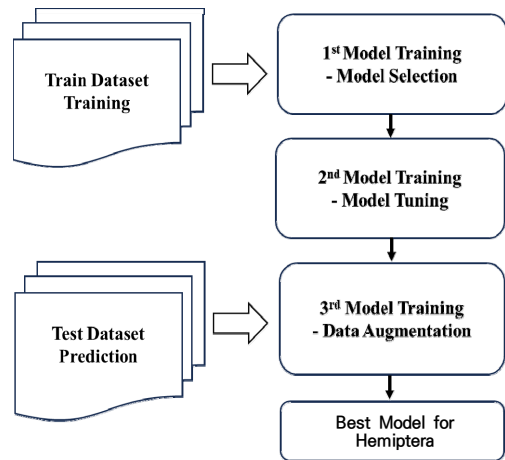


Fig. 1. Overall flow of proposed method

2. 노린재 탐지 준비

2.1 데이터 준비

본 연구에서는 노린재 데이터 세트를 직접 수집하여 사용하였다. 수집된 데이터는 국내에서 주로 발견되는 18종의 노린재를 대상으로 하였으며, Table 1과 Fig. 2와 같이 인스턴스 간의 불균형이 크고 사이즈가 전반적으로 작은 특징을 가지고 있다. 수집된 18개는 Fig. 3과 같으며 각 종을 하나의 클래스로 정의하였다. 수집된 데이터는 다양한 환경에서 실제 상황을 반영하기 위해 농촌 지역의 농작물 입과 줄기, 농작물이 심어진 바닥, 노린재가 쉬어가는 바위와 모래 등에서 발견되었거나, 채집 후 실험실에서 촬영된 이미지를 웹에서 검색하여 수집했다. 이에 따라 이미지의 크기, 조명, 배경, 각도 등이 다양하게 나타나며, 이는 모델의 강인성과 일반화 성능을 높이는 데 도움이 될 수 있다. 전체 데이터 수는 총 8,405개로, 이를 각각 학습, 검증, 그리고 테스트에 8:1:1의 비율로 사용하였다.




Fig. 2. Image size of dataset

Table 1. 18 classes in the dataset

No.	학명(Class)	개수	비율
1	가시점동글노린재(EA)	248	2.95
2	갈색날개노린재(PS)	618	7.35
3	파리허리노린재(AS)	337	4.01
4	먹노린재(SL)	67	0.80
5	북쪽비단노린재(EG)	642	7.64
6	비단노린재(ED)	840	9.99
7	소나무허리노린재(LO)	617	7.35
8	시골가시허리노린재(CP)	541	6.44
9	씩덩나무노린재(HH)	558	6.44
10	알락수염노린재(DB)	848	10.09
11	애기노린재(RI)	246	2.93
12	애기무늬고리장님노린재(AP)	55	0.65
13	애긴노린재(NP)	229	2.72
14	애무늬고리초록장님노린재(AG)	441	5.25
15	툽다리개미허리노린재(RF)	874	10.40
16	플색노린재(NA)	190	2.26
17	홍출노린재(GR)	360	4.28
18	흑다리긴노린재(PE)	694	8.26
합계		8,405	100

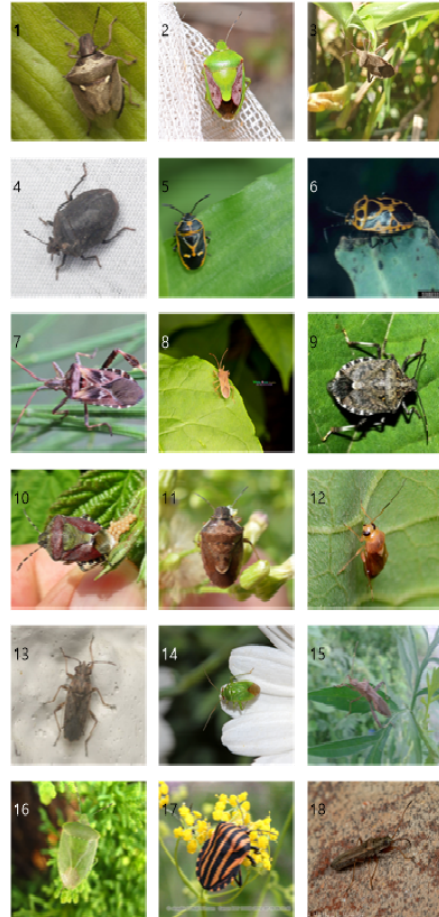


Fig. 3. Examples of 18 Classes

2.2 객체 탐지 모델 제안

본 절에서는 농촌에서의 실시간 노린재 탐지를 위한 딥러닝 모델을 학습하기 위한 방법을 제안한다. 객체 탐지 모델은 크게 1단계 검출기(One-Stage Detector)와 2단계 검출기(Two-Stage Detector)로 구분된다. 보통 1단계는 속도면에서, 2단계는 정확도 면에서 성능이 조금 더 나은 것으로 알려져 있는데, 본 연구에는 이 두 가지가 모두 좋은 것으로 입증된 YOLO 계열을 제안한다 [18,19]. YOLO는 2015년에 제안된 최초의 1단계 검출기(One-Stage Detector) 모델로 전체 이미지에 단일 신경망을 적용하여 빠른 검출 속도를 보여준다[18]. YOLO의 기본적인 알고리즘은 Fig. 4와 같이 이미지를 그리드(Grid)로 나눈 뒤, 각 그리드 셀(Grid Cell)에서 객체의 경계 상자(Bounding Box)와 클래스에 대한 확률을 동시에 예측한다[19]. YOLO가 등장하기 전까지 1단계 검출기의 경우 빠른 속도 대비 성능이 2단계 검출기에 비해 낮은 것으로 알려져 왔지만, YOLO가 공개된 이후 개선을 거듭하며 8개 버전의 YOLO 모델이 공개되었고, 이 과정에서 정확도가 개선되어 지금은 속도와 정확도 측면에서 모두 우수한 성능을 보이고 있어 실시간으로 객체를 탐지해야하는 환경에서 적절한 모델이다.

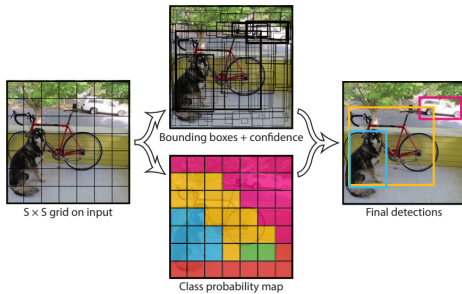


Fig. 4. YOLO Model's basic algorithm [19]

해충 분야에서 YOLOv3[11,13,17], YOLOv4[8], YOLOv5[10,12,14-17] 등이 활용된 사례가 있지만, 노린재를 대상으로 한 연구 사례는 찾기 어려워 본 연구에서는 노린재 대상 YOLO 모델의 활용 가능성을 확인하고자 한다. 여러 모델 중 노린재와 유사한 특성을 보인 해충 분야에서 가장 많이 활용된 YOLOv5를 기준으로, 실험일 기준 가장 최신 모델인 YOLOv8을 비교 모델로 선택하고, 또 이 두 가지 YOLO 계열 모델과의 비교를 위해 또 다른 경량 모델로 알려진 SSD 에 MobileNet

V2를 백본으로 사용하여 실험 초기에 함께 비교한 결과, 최종 모델을 YOLOv8n로 제안한다.

3. 실험 및 실험 결과

3.1 세부 모델의 선택

가장 적절한 노린재 탐지 모델을 선택하기 위한 첫 과정으로 YOLOv5[20], YOLOv8[21], SSD[22]의 성능을 1차로 비교하였다. YOLOv5와 YOLOv8은 여러 가지 세부 버전을 가지고 있어, 실시간 활용을 고려하여 파라미터 수가 적으면서 속도가 빠르고 그 수준이 비슷한 두 모델 YOLOv5의 s 버전과 YOLOv8의 n 버전을 선택하였다. 모델 학습은 모두 구글 코랩 프로(Google Colaboratory PRO)의 GPU v100을 사용하여 epoch 100, batch 16, learning rate 0.01의 같은 동일한 조건으로 진행하였다.

모델 평가는 일반적으로 객체 탐지에서 가장 많이 사용하는 평가 지표인 정밀도(Precision), 재현율(Recall), mAP(mean Average Precision)를 사용하여 정량적으로 비교하였다. 정밀도는 실제로 탐지한 객체 중 실제로 객체가 있는 비율을 말하며, 재현율은 실제로 있는 객체 중에서 모델이 정확하게 탐지한 비율을 말한다. mAP는 여러 클래스에 대한 평균 정밀도(AP: Average Precision)의 평균값으로 객체 탐지 분야에서 주로 사용하는 성능 평가 지표이다.

다만, 이들 중 어느 하나만 좋다고 좋은 모델이라 평가하기 어려우므로 함께 사용하였으며 세 지표는 아래 수식과 같이 계산되었다[23].

$$precision = \frac{TP}{TP + FP} = \frac{TP}{All\ Detections} \quad (1)$$

$$recall = \frac{TP}{TP + FN} = \frac{TP}{All\ Ground\ Truth} \quad (2)$$

$$mAP = \frac{1}{N} \sum_{i=1}^n AP_i \quad (3)$$

모델의 학습 결과, 우선 SSD MobileNet V2는 mAP50이 0.803으로 YOLO 계열의 두 모델보다 상대적으로 성능이 낮아 1차적으로 최종 모델에서 제외했다. 다음으로 YOLO 계열 두 모델을 비교했을 때는 Table 2, Table 3의 A파트 Basic과 같이 mAP50이 0.96~0.97로 높았

Table 2. Overall training results of YOLOv8n

Condition		Precision	Recall	mAP50	mAP95
A. Before Augmentation	Basic	0.959	0.903	0.968	0.868
	Hyper-parameter Tuning Case1	0.957	0.944	0.970	0.873
B. All Classes Augmentation	Flip	0.976	0.974	0.986	0.927
	Rotation 10	0.977	0.983	0.990	0.907
	Scale +1.2	0.953	0.949	0.977	0.802
	Multiply +1.3	0.980	0.982	0.991	0.936
	Contrast 0.5~1.5 random	0.983	0.981	0.992	0.939
	Multiply + Contrast	0.980	0.972	0.991	0.927
	Multiply + Contrast + Rotation	0.964	0.966	0.987	0.881
	Multiply + Contrast + Rotation + Flip	0.972	0.955	0.984	0.877
C. Augmentation only for SL	Multiply + Contrast + Rotation + Flip + Scale	0.946	0.936	0.976	0.778
	C. contrast 0.5~1.5 random	0.955	0.946	0.980	0.887
	M. multiply +1.3	0.951	0.961	0.983	0.902
	Multiply + Contrast	0.927	0.928	0.964	0.858
	Multiply + Contrast + Rotation	0.955	0.955	0.979	0.893
	Multiply + Contrast + Rotation + Flip	0.949	0.938	0.980	0.881
Multiply + Contrast + Rotation + Flip + Scale	0.966	0.936	0.978	0.872	

Table 3. Overall training results of YOLOv5s

Condition		Precision	Recall	mAP50	mAP95
A. Before Augmentation	Basic	0.929	0.929	0.964	0.752
	Hyper-parameter Tuning Case1	0.949	0.947	0.969	0.828
B. All Classes Augmentation	Flip	0.959	0.978	0.979	0.873
	Rotation 10	0.956	0.981	0.986	0.812
	Scale +1.2	0.979	0.972	0.988	0.645
	Multiply +1.3	0.977	0.978	0.991	0.884
	Contrast 0.5~1.5 random	0.975	0.985	0.992	0.887
	Multiply + Contrast	0.974	0.974	0.990	0.858
	Multiply + Contrast + Rotation	0.957	0.981	0.986	0.804
	Multiply + Contrast + Rotation + Flip	0.976	0.961	0.985	0.791
C. Augmentation only for SL	Multiply + Contrast + Rotation + Flip + Scale	0.955	0.963	0.978	0.691
	Contrast 0.5~1.5 random	0.942	0.953	0.978	0.842
	Multiply +1.3	0.941	0.966	0.984	0.855
	Multiply + Contrast	0.946	0.940	0.975	0.822
	Multiply + Contrast + Rotation	0.948	0.947	0.978	0.843
	Multiply + Contrast + Rotation + Flip	0.954	0.924	0.973	0.815
Multiply + Contrast + Rotation + Flip + Scale	0.947	0.940	0.976	0.808	

다. 최종적으로 YOLOv8n이 YOLOv5s보다 파라미터 수가 약 400개 더 적으면서, mAP50, mAP95, 정밀도에서 앞선 성능을 보여 최종 모델로 선택하였다. 따라서 본 논문에서는 YOLOv8n 모델을 최종 실험 모델로 선택하고, 해당 모델을 통해 얻은 결과를 보고한다.

이어 YOLOv8n의 성능을 조금 더 높이기 위해 하이

퍼파라미터를 조정하였다. YOLOv8n의 하이퍼파라미터는 총 98개로, 여러 실험을 통해, 그중에서 가장 좋은 성능을 보이는 모델의 하이퍼파라미터 조합을 선택하였다. 그 결과, Table 4의 Case 1과 같이 IoU(Intersection of union) 임계값을 0.7에서 0.8로, 최대 감지 개수(max_det)를 300에서 500으로 증가시키고, 노멀 배치

사이즈(nbs) 값을 64에서 128로 조정하여 성능이 약간 더 향상된 결과를 얻을 수 있었다. 이러한 조정은 Fig. 5와 같이 작은 객체나 배경과 보호색을 띤 경우에도 성능을 유지하기 위함이다.

Table 4. Training Results of YOLOv8n's Hyper-parameters Tuning

Case	Precision	Recall	mAP50	mAP95
1*	0.957	0.944	0.970	0.873
2*	0.954	0.915	0.963	0.868
3*	0.954	0.908	0.963	0.871
4*	0.954	0.912	0.961	0.869
5*	0.946	0.937	0.963	0.872

*1: iou=0.8, max_det=500, nbs=128
 *2: 1 + box=6.5, cls=0.6, dfl=2.5, scale=0.4
 *3: 1 + box=6.5, mosaic=0.5
 *4: 1 + hsv_s: 0.8, hsv_v: 0.5
 *5: hsv_s: 0.8, hsv_v: 0.5

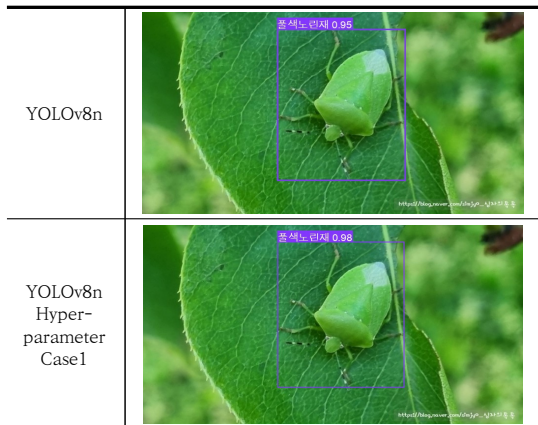


Fig. 5. Before and after Hyper-parameters Tuning

하이퍼파라미터 조정까지 마친 모델은 학습에 사용되지 않은 테스트 세트에서 예측 테스트를 하였고, 그 결과 Fig. 6의 첫 번째 열 이미지들과 같이 '먹노린재(SL: Scotinophara Lurida)'를 다른 노린재로 잘못 탐지하는 사례가 발견되었다. 이는 실제 현장에서 오탐지가 발생할 가능성을 나타내므로 개선이 필요하다. 이러한 성능 차이는 Table 1에서 보는 것과 같이 데이터 세트가 클래스별로 불균형을 갖는데 기인한 것으로 생각되며, 데이터 증강 방식을 활용하여 불균형 문제를 완화했다. 데이터 증강은 부족한 클래스의 데이터양을 늘리는 방법으로, 모델의 성능 향상과 과적합 방지에 도움을 줄 수 있다[24,25].

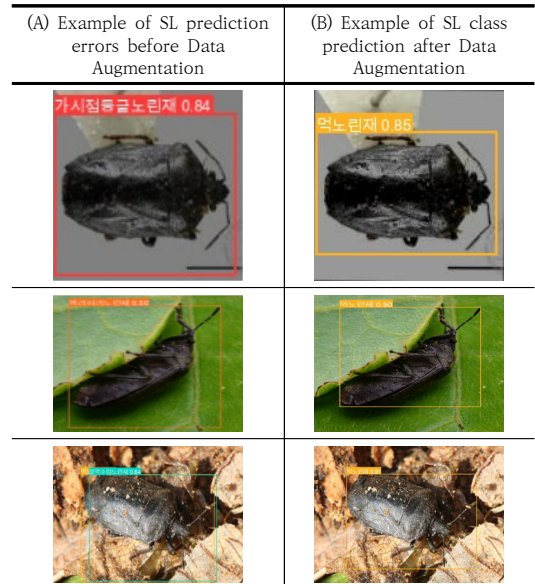


Fig. 6. Comparison of prediction results before and after augmentation



Fig. 7. Exsample Images of Data Augmentation : Original, Flip, Rotation, Scale, Multiply, Contrast

3.2 데이터 증강 실험

데이터 증강은 다양한 방법이 존재하며, 본 연구에서는 뒤집기, 회전(10도), 크기 조정(1.2배), 곱하기(1.3배 밝게) 그리고 대비(0.5~1.5배 랜덤) 등 5가지 기본적인 방법을 개별 및 조합으로 활용하였다(Fig. 7 참조). 이러한 다양한 증강 방법을 적용한 결과는 Table 2의 B파트에 나와 있다. 전반적으로, 증강기법을 사용함으로써 성능이 향상되었으며, 특히 곱하기와 대비를 적용했을 때 mAP50 기준 0.991 ~ 0.992로 최고의 성능을 달성하였다. 이러한 성능은 2가지 이상 기법을 함께 사용한 조합 실험에서도 확인되었고, 곱하기와 대비를 함께 사용했을 때 mAP50이 0.991로 가장 높은 성능을 보였다.

다만, 전체 데이터 세트에 대한 증강은 성능 향상에 기여하지만, 데이터 생성 및 학습에 소요되는 시간이 증가하는 리소스 측면에서는 비효율적이다. 이를 고려하여,

유독 성능이 떨어지는 특정 클래스에 대해서만 증강 데이터를 추가하는 실험을 수행하였다. 이 실험에서는 앞서 언급한 곱하기와 대비를 중심으로 진행되었고, 결과적으로 Table 5에서 확인할 수 있는 것과 같이 곱하기에 데이터 증강 전의 성능을 넘어 mAP50 0.983을 달성하면서 오탐지했던 ‘떡노린재’ 클래스에서도 mAP50 0.995로 최고 성능을 달성하였다. Fig. 7의 두 번째 열의 결과와 같이 데이터 증강 전, 오탐지한 이미지들을 테스트한 결과에서도 모두 ‘떡노린재’로 정상적으로 탐지하였다. 이는 Table 2 및 Table 3의 결과 B와도 일치하며 그 세부 내용은 Table 2 및 Table 3의 C에 정리하였다. 이와 같은 추가 실험을 통해 리소스를 고려해야 하는 상황에서는 데이터 불균형이 심한 특정 클래스에만 데이터를 추가하는 것도 성능 향상이 가능함을 확인할 수 있다.

3.3 일반화 적용의 가능성 검토

마지막으로, 본 연구에서 얻은 결과가 YOLOv8n에서만 해당하는지 확인하기 위해 초기에 함께 비교한 YOLOv5s 모델에도 동일한 조건으로 실험을 진행하였다. Table 3에서 확인할 수 있듯이, YOLOv5s 모델에서도 곱하기와 대비에서 mAP50이 0.990~0.992로 가장 높은 성능을 나타내며 YOLOv8n과 같은 결과를 얻었다. 이는 특정 모델에 국한되지 않고, 곱하기와 대비 기법이 불균형한 데이터에 대한 효과를 발휘할 수 있다는 가능성을 시사하고 있다.

Table 5. Training Results of Data Augmentation for SL Classes Only

Condition	YOLOv8n		YOLOv5s	
	SL	All	SL	ALL
Contrast 0.5~1.5	0.925	0.980	0.986	0.978
Multiply +1.3	0.995	0.983	0.995	0.984
Multiply + Contrast	0.984	0.964	0.995	0.974
Multiply + Contrast + Rotation	0.995	0.979	0.995	0.978
Multiply + Contrast + Rotation + Flip	0.925	0.980	0.979	0.973
Multiply + Contrast + Rotation + Flip + Scale	0.977	0.978	0.976	0.976

4. 결론

본 연구에서는 YOLO 계열 딥러닝 모델을 활용한 노린재 탐지에 대한 다양한 실험을 수행하였다. 실험 결과, YOLOv8n 모델을 선택하고 일부 하이퍼파라미터를 조

정한 후, 데이터 증강기법을 활용하여 클래스의 불균형 상황에서도, 실시간 탐지가 가능한 FPS 40 이상의 속도를 유지하며 모든 클래스에 대한 탐지 성능이 향상되었다. 이는 결과적으로 노린재에 대한 효과적인 탐지 모델을 제안하여 실제 농업 현장에서의 인공지능을 활용한 농작물 보호 및 병충해 예방의 가능성을 제시하였다. 본 연구는 인공지능을 활용한 노린재 탐지 도구를 처음으로 제공함으로써, 해당 분야에 인공지능 도입의 가능성을 확인하였으며 농업 생산성 향상과 작물 보호에 기여할 것으로 기대된다. 또한, 이러한 연구 흐름을 통해 노린재 뿐 아니라 공공 보건 및 환경 보호로 그 대상을 넓혀 다양한 분야 이바지할 것으로 예상되는 바, 본 연구의 중요성과 가치는 더욱 강조될 수 있다.

향후 이어질 연구에서는 더 다양한 노린재 클래스에 대한 분류 성능 개선, 동적인 환경에서의 탐지 모델 확장, 다양한 지역과 조건에서의 농작물 피해를 주는 해충에 대한 일반화 성능 향상을 목표로 할 것이다. 이러한 노력을 통해 정확하고 강건한 노린재 탐지 모델을 개발하여 농업 생산성과 작물 보호에 기여 할 것으로 기대한다.

References

- [1] S. Bae, H. Kim, Mainali, Y. Yun, & I. Oh. "Development and Application of New Concept Multipurpose Nore Trap", *Proceedings of the 2013 Annual Meeting and Spring Conference of the Korean Society of Applied Entomology*, SL-1, p.11, 2013
DOI: <https://db.koreascholar.com/Article/Detail/288401>
- [2] C. A. Viraktamath, "The systematics of the Hemiptera", *Oriental Insects*, Vol.42, No.1, pp.69-155, 2008.
DOI: <https://doi.org/10.1080/00305316.2008.10417547>
- [3] H. Park, "Investigation of Nematocera Damage and Ecological Characteristics of Major Trees in the Living Area", *National Institute of Forest Science, Research Report*, No.975, 2021
- [4] National Crop Pest Management System (NCPMS), "National Crop Pest Management System (NCPMS)", Ministry of Agriculture, Food and Rural Affairs, Information on pests, Information on illustrations by pests, 2023
DOI: <https://ncpms.rda.go.kr/npms/CropPreventionInfoR.np/>
- [5] C. Kang, H. Heo, J. Park, "Review on True Bugs Infesting Tree Fruits, Upland Crops, and Weeds in Korea", *Korea Journal of Applied Entomology*, Vol.42, No.3, pp.269-277, 2003.
- [6] A. C. Teixeira, J. Ribeiro, R. Morais, J. J. Sousa, A. Cunha, "A Systematic Review on Automatic Insect Detection Using Deep Learning", *Agriculture*, Vol.13,

- No.3, p.713, 2023.
DOI: <https://doi.org/10.3390/agriculture13030713>
- [7] A. Popkov, F. Konstantinov, V. Neimorovets, A. Solodovnikov, "Machine learning for expert-level image-based identification of very similar species in the hyperdiverse plant bug family Miridae (Hemiptera: Heteroptera)", *Systematic Entomology*, Vol.42, No.3, pp.269-277, 2022.
DOI: <https://doi.org/10.1111/syen.12543>
- [8] S. Dong, J. Zhang, F. Wang, X. Wang, "YOLO-pest: a real-time multi-class crop pest detection model", *Proceedings of the SPIE*, Vol.1226003, 2022.
DOI: <https://doi.org/10.1117/12.2637467>
- [9] L. Butera, A. Ferrante, M. Jermini, M. Prevostini, C. Alippi, "Precise Agriculture: Effective Deep Learning Strategies to Detect Pest Insects", *IEEE/CAA Journal of automatica Sinica*, Vol.9, No.2, 2022
DOI: <https://doi.org/10.1109/CIBCB52306.2021.9601235>
- [10] N. Kumar, N. Nagarathna, F. Flammini, "YOLO-Based Light-Weight Deep Learning Models for Insect Detection System with Field Adaption", *Agriculture*, Vol.13, No.3, p.741, 2023.
DOI: <https://doi.org/10.3390/agriculture13030741>
- [11] Z. Tang, Z. Chen, F. Qi, L. Zhang, S. Chen, "Pest-YOLO: Deep Image Mining and Multi-Feature Fusion for Real-Time Agriculture Pest Detection", *IEEE International Conference on Data Mining (ICDM)*, Auckland, New Zealand, 07-10 December 2021.
DOI: <https://doi.org/10.1109/ICDM51629.2021.00169>
- [12] Q. Xiang, X. Huang, Z. Huang, X. Chen, J. Cheng, X. Tang, "Yolo-Pest: An Insect Pest Object Detection Algorithm via CAC3 Module", *Sensors*, Vol.23, No.6, 2023.
DOI: <https://doi.org/10.3390/s23063221>
- [13] Q. Wang, S. Zhang, S. Dong, G. Zhang, J. Yang, R. Li, H. Wang, "Pest24: A large-scale very small object data set of agricultural pests for multi-target detection", *Computer and Electronics in Agriculture*, Vol.175, 2020
DOI: <https://doi.org/10.1016/j.compag.2020.105585>
- [14] W. Li, T. Zhu, X. Li, J. Dong, J. Liu, "Recommending Advanced Deep Learning Models for Efficient Insect Pest Detection", *Agriculture*, Vol.12, No.7, 2022
DOI: <https://doi.org/10.3390/agriculture12071065>
- [15] I. Ahmad, Y. Yang, Y. Yue, C. Ye, M. Hassan, X. Cheng, Y. Wu, Y. Zhang, "Deep Learning Based Detector YOLOv5 for Identifying Insect Pests", *Applied Sciences*, Vol.12, No.19, 2022
DOI: <https://doi.org/10.3390/app121910167>
- [16] M. Tannous, C. Stefanini, D. Romano, "A Deep-Learning-Based Detection Approach for the Identification of Insect Species of Economic Importance", *Insects*, Vol.14, No.148, 2023
DOI: <https://doi.org/10.3390/insects14020148>
- [17] K. Bjerge, J. Alison, M. Dyrmann, C. E. Frigaard, H. M. Mann, T. T. Hoye, "Accurate detection and identification of insects from camera trap images with deeplearning", *Plos Sustainability and Transformation*, Vol.2, No.3, 2023
DOI: <https://doi.org/10.1371/journal.pstr.0000051>
- [18] Z. Zou, K. Chen, Z. Shi, Y. Guo, J. Ye, "Object Detection in 20 Years: A Survey", *Proceedings of the IEEE*, Vol.111, No.3, 2023
DOI: <https://doi.org/10.1109/JPROC.2023.3238524>
- [19] R. Joseph, D. Santosh, G. Ross, F. Ali, "You Only Look Once: Unified, Real-Time Object Detection," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, 27-30 June 2016.
DOI: <https://doi.org/10.1109/CVPR.2016.91>
- [20] Ultralytics, "Ultralytics YOLOv5 Docs" Ultralytics, Oct. 2021, <https://docs.ultralytics.com/models/yolov5/>, Dec 2023
- [21] Ultralytics, "Ultralytics YOLOv8 Docs" Ultralytics, Jan. 2023, <https://docs.ultralytics.com/models/yolov8/>, Dec 2023
- [22] W. Liu, D. Anguelov, D. Erhan, C. Szegedy, S. Reed, C.Y. Fu, A.C. Berg, "SSD:Single Shot MultiBox Detector", *ECCV*, Vol. 9905, Sep 2016.
https://link.springer.com/chapter/10.1007/978-3-319-46448-0_2
- [23] J. Davis, M. Goadrich, "The relationship between Precision-Recall and ROC curves", *Proceedings of the 23rd International Conference on Machine Learning (ICML '06)*, p.233-240, 2006
DOI: <https://doi.org/10.1145/1143844.1143874>
- [24] C. Shorten, T. M. Khoshgoftaar, "A survey on Image Data Augmentation for Deep Learning", *Journal of Big Data*, Vol.6, p.60, 2019.
DOI: <https://doi.org/10.1186/s40537-019-0197-0>
- [25] J. M. Johnson, T. M. Khoshgoftaar, "Survey on deep learning with class imbalance", *Journal of Big Data*, Vol.6, p.27, 2019.
DOI: <https://doi.org/10.1186/s40537-019-0192-5>

임지선(Ji-Sun Lim)

[정회원]



• 2021년 3월 ~ 현재 :
국민대학교 데이터사이언스학과
(석박사통합 박사과정)

<관심분야>

딥러닝 객체 탐지, 컴퓨터 비전, 경량화

최 윤 성(Yun-Sung Choi)

[정회원]



- 2015년 2월 : 서강대학교 공과대학 컴퓨터공학과 (컴퓨터공학 학사)
- 2018년 2월 : 서강대학교 공과대학 컴퓨터공학과 (컴퓨터공학 석사)
- 2019년 1월 ~ 2020년 10월 : (주)대유 경영기획실
- 2020년 11월 ~ 현재 : (주)온투인 AILAB 연구소장

<관심분야>

인공지능, 빅데이터 분석

박 종 혁(Jong-Hyuk Park)

[정회원]



- 2015년 2월 : 서울대학교 공과대학 산업공학과(산업공학 학사)
- 2021년 8월 : 서울대학교 공과대학 산업공학과(산업공학 박사)
- 2015년 1월 ~ 2016년 2월 : 삼성전자 메모리사업부
- 2021년 9월 ~ 현재 : 국민대학교 AI빅데이터융합경영학과 조교수

<관심분야>

머신러닝, 딥러닝, 컴퓨터 비전, 빅데이터 분석