

신고배 병해충 분류를 위한 공용 및 현장 이미지 데이터셋 기반 분류 성능 비교 연구

(Classification Performance of *Pyrus pyrifolia* Pest and Disease Images Using Public and Field Datasets)

이진*, Le Hoang Anh*, 이현주**, 조정안***, 유광현***, 김진영****

(Jin Lee, Le Hoang Anh, Heonzoo Lee, JunagAnh Jo, GwangHyun Yu, JinYoung Kim)

요약

본 연구에서는 동양배(신고 품종)의 병해충 분류를 위해 공용데이터셋과 현장용데이터셋을 직접 구축하고, 데이터 환경 차이가 인공지능 분류모델의 학습 적합성과 일반화 성능에 미치는 영향을 비교·분석하였다. 순천 농산물유통센터에서 구매한 정상 및 비품 신고배를 전문가 1·2차 검수로 8개 클래스로 라벨링한 뒤, 동일 개체를 공용(정제된 촬영 환경)과 현장 조건에서 각각 촬영하여 두 데이터셋을 구성하였다. 이후 사전학습된 ResNet, MobileNetV2, EfficientNet, DeiT 분류 모델을 대상으로 시나리오별 데이터 조합에 따른 분류 성능을 평가하였다. 그 결과, 공용·현장 혼합 데이터셋으로 학습한 시나리오 B에서 모든 모델의 평균 정확도가 93.34%로 가장 높았으며, 공용데이터셋만으로 학습한 시나리오 A는 도메인 차이로 인해 현장 데이터 기준 평균 72.11%에 머물렀다. 이는 공용데이터만 사용하는 것보다 현장데이터를 혼합하여 학습하는 방식이 실제 선별장 환경에 대한 적응성과 모델 신뢰도 향상에 효과적임을 보여준다. 아울러 YOLOv11 기반 전처리를 통해 과실 영역을 자동 추출함으로써 라벨링 부담을 줄인 경량 분류모델 구조가 현장 병해충 분류기로 활용 가능함을 보였으며, 이를 통해 향후 실제 선별장에 적용 가능한 자동 병해충 분류 장비와 도메인 적응 기반 통합형 병해충 인식 모델 개발을 위한 기반을 마련하였다.

■ 중심어 : 동양배 ; 병해충 분류 ; 공용 데이터셋 ; 현장 데이터셋 ; 분류모델

Abstract

This study constructs public and field image datasets for pest and disease classification of Asian pear *Pyrus pyrifolia* 'Nittaka' and evaluates pretrained ResNet, MobileNetV2, EfficientNet and DeiT models under different data compositions to examine how data environments affect training suitability and generalization performance. Mixed public plus field training Scenario B achieved the highest mean accuracy of 93.34 percent on field data, whereas public only training Scenario A achieved 72.11 percent, indicating that combining field with public data together with YOLOv11 based fruit region preprocessing and a lightweight classifier is effective for reliable pest and disease recognition and for designing automatic sorting systems and domain adaptive integrated models in real packing facilities.

■ keywords : Oriental pear ; pest and disease classification ; public dataset ; on-site dataset ; classification model

I. 서론

최근 농업 분야에서는 스마트팜(Smart Farm)

및 스마트농업 솔루션이 보편화되면서 작물 생육, 병해충 진단, 품질관리 등에 인공지능 기반 컴퓨터비전 기술이 적극적으로 도입되고 있다[1,

* 정회원, 전남대학교 지능전자컴퓨터공학과

** 정회원, 주식회사 에이아이시드 기업부설연구소

*** 정회원, 전남대학교산학협력단

**** 정회원, 전남대학교 지능전자컴퓨터공학과

이 논문은 과학기술정보통신부와 정보통신산업진흥원으로부터 '2024년 지역디지털기초체력지원(전남 SW서비스)(S-2001-24-1008)'과 농림축산식품부의 재원으로 농림식품기술기획평가원의 노지스마트농업활용모델개발사업의 지원을 받아 연구되었음(RS-2025-02307408).

접수일자 : 2025년 10월 31일

수정일자 : 2025년 11월 21일

게재확정일 : 2025년 11월 23일

교신저자 : 유광현, 김진영 e-mail : sayney1004@gmail.com, beyondi@jnu.ac.kr

2]. 특히 과수 산업에서는 병해충 피해가 과실의 상품성, 저장성, 수출가능성에 직결되며, 자동화된 이미지 기반 분류 및 검수 시스템 구축이 산업적 과제로 부상하고 있다. 기존에는 육안 판별이나 전문가 경험에 의존한 품질 및 병해충 판별이 일반적이었으나, 숙련도 차이 및 작업자 피로도에 따른 검수 속도 저하 등의 한계가 지속적으로 제기되어 왔다. 이러한 배경 하에, 인공지능 기반 자동 병해충 분류 기술은 과수 선별장 자동화, 인건비 절감, 품질 신뢰성 향상 등의 측면에서 매우 중요한 역할을 하고 있다[3].

본 연구 대상인 ‘신고’ 품종의 동양배(신고배, *Pyrus pyrifolia*)는 소비자가 선호하는 큰 과실 생산이 가능하고, 수량이 많으며, 전정 등 다른 품종에 비해 재배가 용이한 특성이 있을 뿐만 아니라, 과실의 시장가격이 높아 농가소득을 올릴 수 있어 재배면적이 최대이다. 통계청 자료에 따르면 국내 배 재배면적은 약 9,394ha로, 신고 품종 재배면적은 전체 재배면적에서 약 84.5%를 차지한다[4]. 또한 2005년 배 수출물량은 매년 25,000톤~30,000톤으로 미국에 50%, 대만이 28%, 베트남이 10%, 기타 국가에 12%가 수출되고 있다[5].

신고배는 9월 중순부터 10월 중순까지 수확하며, 수확된 배는 품질에 따라 선별된다. 비품 배를 판매하지 않기 위해 포장과 검수 과정에서 하나하나 캡(망)으로 포장하여 신선도를 유지하며, 상품성이 떨어지는 배는 농산물 외에 가공용으로 사용될 수 있다. 따라서 선별장에서 배 품질을 정확히 판별하여 정품과 비품으로 구별하는 것이 중요하며, 비품 중에서도 클래스를 구분하여 농산물 외에 가공용으로 사용될 수 있는 것이 중요하다.

이에 본 연구에서는 직접 구축한 공용데이터셋(public dataset)과 현장용데이터셋(on-site dataset)을 기반으로 신고배 병해충 이미지 분류에 적용하여 다음과 같은 연구목적을 달성하고자 한다.

첫째, 공용데이터셋은 흰색 판넬을 3면으로 감싸서 흰색 배경과 균일한 조명 환경에서 스마트폰 및 태블릿 카메라 고해상도로 촬영하여 8개 클래스(정상, 깎지벌레, 복숭아나방류, 흑성병, 잎말이나방류, 과피얼룩, 과피흑변, 기타)로 구성하였다.

둘째, 현장용데이터셋은 실제 선별장 컨베이어 벨트 환경에서 산업용 카메라로 촬영하여 조명, 반사, 노이즈등을 포함한 동일 클래스로 구성하였다.

셋째, 구축된 두 데이터셋을 각각 정제된 촬영 환경을 갖는 소스 도메인과 실제 선별장 환경을 반영하는 타깃 도메인으로 설정하고, 각 도메인 내부를 학습용·테스트용으로 분할하여 데이터셋 환경의 차이가 분류모델의 학습 적합성 및 타깃 도메인에서의 일반화 성능에 미치는 영향을 분석하고자 한다.

또한, 본 연구는 현장 상황을 고려하여 현장에 적용하여 사용하게 될 신고배 병해충 분류모델 추론 중 축적될 데이터에 대하여 라벨링 재사용 비용을 최소화하고, 재학습 가능한 자동화 시스템 구조를 염두에 두어 사전학습 분류모델인 ResNet, MobileNetV2, EfficientNet, DeiT를 성능 비교한다.

본 논문의 구성은 다음과 같다. 제2장에서는 병해충 이미지 기반 탐지·분류 연구와 같은 관련 선행연구를 살펴본다. 제3장에서는 공용 및 현장 데이터셋 구축 절차를 상세히 설명한다. 제4장에서는 모델 구성, 학습 조건, 실험 설계 및 방법을 기술한다. 제5장에서는 정량적 성능 비교 결과 및 정성분석을 포함한 논의를 제시한다. 마지막으로 제6장에서는 결론 및 향후 연구 방향을 제시한다.

II. 관련 연구

1. 과수 병해충 이미지 인식 기술 동향
인공지능 컴퓨터비전 기반 과수 병해충 연구에

서는 주로 과수원 생육 환경에서 촬영된 이미지 데이터셋으로 생육 단계[6,7] 및 병해충 탐지[8-10] 중심의 연구가 다수 진행되어 왔다. 컴퓨터 비전을 이용한 병해충 인식 연구는 기존 전통 이미지처리 기반 접근에 비해 특징 자동추출 및 일반화 성능 측면에서 월등한 진전을 보였다[11]. 또한 과수원 내부에서 3D 스테레오 카메라로 동양배를 인식한 연구가 보고된 바 있다[12]. 최근에는 경량 모델과 트랜스포머(Transformer) 기반 구조의 적용도 활발히 이루어지고 있는데, Zhang et al.[10]은 합성곱 신경망(CNN)에서 트랜스포머로 전환을 “작물 병해충 인식에는 CNN-Transformer 하이브리드 또는 순수 트랜스포머 구조가 향후 유망하다”고 분석하였다. 과수 병해충 이미지 인식을 위해서는 조명, 배경 복잡성 등 현실 환경에서의 시각적 노이즈를 극복하는 것이 중요하며, 엣지 디바이스 적용 가능성을 염두에 둔 경량 분류모델 성능 비교연구가 필요하다.

2. 과수 병해충 데이터셋 구축 연구

데이터셋은 인공지능 모델 성능 및 현장 적용 가능성에 결정적인 요인이다. 많은 병해충 인식 연구는 공공 데이터셋 또는 실험실 환경에서 수집된 이미지에 기반해 왔으며, 대표적인 예시로 Liu et al.[11]은 실험실 환경과 실제 자연환경의 차이를 여러번 주장하면서 실험실 환경이 아닌 데이터가 중요하다고 지적하였다. 또한, 대형 병해충 인식 데이터셋 연구[14]에서는 대규모 병충해 이미지 데이터 확보가 모델 향상의 핵심이라서 데이터셋 규모 및 다양성 부족이 모델 일반화 성능 개선의 병목으로 언급되었다. 반면에 Hao et al.[15]는 선별장 실시간 분류용 온라인 모델을 제안하였지만 이는 적외선 및 분광 기반이며 대규모 유통선별 분야에서의 이미지 기반 일반화 연구는 부족하였다. 따라서 선별장 환경에서의 실제 조명, 반사, 배경, 노이즈 조건을 반영한

이미지 데이터셋 구축과 이를 기반으로 한 분류 성능 비교연구가 필요하다.

3. 본 연구의 차별성

기존 연구들을 종합하면, 과수 병해충 탐지 및 분류 기술은 빠르게 발전하고 있으나 다음과 같은 한계가 존재한다.

첫째, 대부분의 데이터셋이 생육단계 과수원 촬영에 치우쳐 있으며, 선별장 환경에 맞춘 데이터셋은 부족하다.

둘째, 경량화 연구가 증가하고 있으나, 실제 선별장 조건을 고려한 분류모델 연구는 상대적으로 드물다.

따라서 본 연구는 위 한계들을 극복하기 위해 신고배 병해충 데이터셋을 공용데이터셋과 현장용데이터셋으로 구분하여 직접 수집한다. 그리고 이를 선별장 조건에 맞게 전처리 및 사전학습 분류모델을 통해 학습하고, 모델간 성능 비교를 통해 현장에 실제 투입할 수 있는 파이프라인을 제시하는 연구로서 차별성을 가진다.

Ⅲ. 데이터셋 구축 및 전처리

1. 데이터셋 구축 절차

본 연구에서 사용된 신고배 병해충 데이터는 공용데이터셋과 현장용데이터셋으로 구분하여 직접 구축하였다. 그림 1과 같이 순천 농산물유통센터에서 구매한 신고배를 대상으로 전문가의 육안검수를 거쳐 1차적으로 클래스를 분류하였고, 분류된 클래스는 정상, 흑성병, 복숭아나방류, 깍지벌레, 잎말이나방류, 과피얼룩, 과피흑변, 기타로 8개 클래스이다. 기타 클래스는 물리적 상처, 압상, 열과, 오염등 손상을 포함한다.



그림 1. 전문가 1차 육안검수

1차 분류된 클래스를 각각 공용데이터셋 환경과 현장용데이터셋 환경에 이동하여 촬영을 하였다. 그림 2와 같이 공용데이터셋 촬영 환경은 공공데이터 AI-HUB의 농산물 품질(QC) 이미지 [16]와 비슷한 환경을 조성하여 촬영하였다.



그림 2. 공용데이터셋 환경 신고배 이미지 촬영

공용데이터셋은 흰색 판넬을 3면으로 감싸서 흰색 배경과 균일한 조명 환경에서 스마트폰 및 태블릿 카메라를 초고해상도로 설정한 후, 정면, 측면, 상부 등으로 회전하면서 정상 및 병해충 부위를 집중적으로 촬영하였다.

그림 3과 같이 현장용데이터셋 촬영 환경은 실제 선별장 컨베이어벨트 배경에서 선별기 조명 환경에서 산업용 카메라(Basler acA2440-75um)을 3면에서 화각의 합이 360도가 될 수 있는 각도에서 촬영하였다.

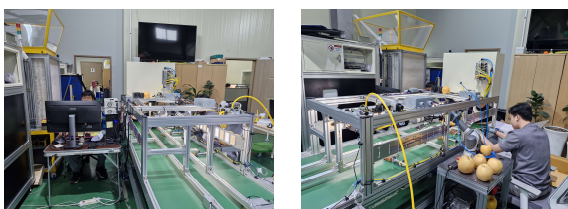


그림 3. 현장용데이터셋 환경 신고배 이미지 촬영

최종적으로 공용데이터셋과 현장용데이터셋의 전체 이미지 수는 표 1과 같다.

표 1. 공용데이터셋과 현장용데이터셋 원본 이미지 수

	공용데이터셋	현장용데이터셋
이미지 수	12,097	8,726

2. 데이터셋 전처리 및 검수

공용데이터셋과 현장용데이터셋 원본 이미지를 그림 4와 같이 전처리를 수행하였다. 신고배 병해충 이미지는 한 프레임 내에서 과실 영역이 전체 이미지의 약 30~50%에 불과하고, 나머지 영역은 배경 및 노이즈로 구성되어 있기 때문에, 이러한 배경 및 노이즈는 분류모델의 특징(feature) 학습을 방해하고 클래스간 경계를 불명확하게 만드는 주요 원인으로 작용하게 된다.

이에 본 연구에서는 YOLOv11 기반 객체 검출(Object Detection) 모델을 이용하여 과실 영역만을 잘라내기(crop) 하는 전처리(pre-processing) 단계를 수행하였다.

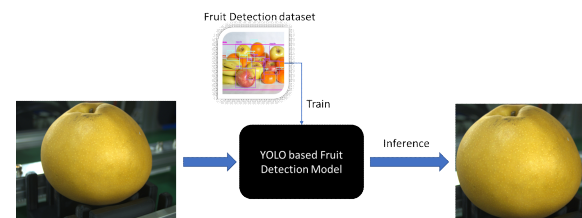


그림 4. YOLOv11기반 잘라내기 전처리 파이프라인

이때 사용된 YOLOv11 모델은 기존 저자가 학술대회[17]로 발표한 모델 가중치를 그대로 활용하여 추가 재학습 없이 오로지 전처리 단계에 한정하여 재사용함으로써 신고배의 정확한 잘라내기 추출을 필요로 하는 파이프라인에 적합하다.

YOLOv11을 신고배 병해충 이미지 분류에 End-to-End로 사용하지 않고 전처리에만 사용하는 이유는 현장에서 대규모 데이터를 지속적으로 수집해야 하는 상황에서 객체 탐지 모델 라벨링은 분류모델 라벨링보다 데이터 확장과 재

학습이 어렵고, 선별장 현장에 설치되는 분류 장비는 소형 임베디드 보드 또는 엣지 디바이스에서 구동되기 때문에 고성능 GPU나 대용량 메모리를 탑재하기 어렵기 때문에 단순한 합성곱 신경망을 통해 성능을 비교하고자 한다.

최종적으로 신고배 영역만 잘라내기 된 전처리된 공용데이터셋과 현장용데이터셋은 그림 5와 같이 전문가가 전처리된 이미지를 모니터에서 검수하여 각 클래스별로 확실한 이미지만을 데이터셋으로 확정한다.



그림 5. 전문가 2차 이미지 검수

전문가 2차 이미지 검수한 공용데이터셋과 현장용데이터셋은 표 2와 같다.

표 2. 최종 공용데이터셋과 현장용데이터셋

	클래스	공용데이터셋	현장용데이터셋
1	정상	730	146
2	흑성병	1,864	87
3	깍지벌레	375	548
4	복숭아나방류	121	82
5	앞말이나방류	65	87
6	과피열록	60	30
7	과피흑변	30	28
8	기타	5,235	3,705
	합계	8,480	4,713

표 2의 공용데이터셋과 현장용데이터셋 전체 이미지 수가 표 1의 공용데이터셋과 현장용데이터셋 전체 이미지 수보다 줄어든 이유는 전문가 2차 검수 때 클래스별로 확실한 특징이 있는 이미지만을 선정하였기 때문이다.

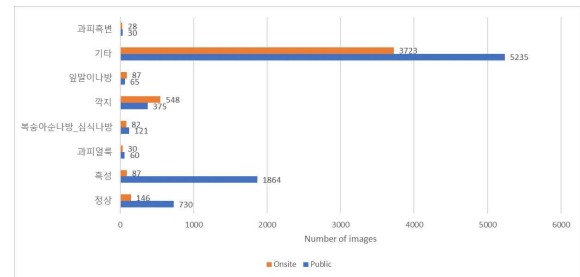


그림 6. 최종 공용데이터셋과 현장용데이터셋 비교

또한 그림 6과 같이 공용데이터셋이 현장용데이터셋보다 많은 이유는 공용데이터셋은 촬영자가 병해충 부위를 집중적으로 다수 촬영한 반면, 현장용데이터셋은 컨베이어벨트 선별기에 설치된 고정된 카메라를 통해서 촬영을 하였기 때문에 병해충 부위 외에 병해충 특징이 두드러지지 않은 부위도 많이 촬영되어 전문가 2차 검수 때 많이 제외되었기 때문이다.

IV. 실험 방법 및 모델 구성

1. 실험 방법

본 연구의 실험은 데이터 구성 및 학습 조합에 따라 세 가지 시나리오로 설계된다. 모든 시나리오에서 테스트 데이터셋은 현장용데이터셋의 20%로 고정하였으며, 학습용 및 검증용 데이터셋은 나머지 80% 내에서 비율에 따라 구성하였다. 평가 지표는 테스트 세트에서 올바르게 분류된 샘플 수를 전체 샘플 수로 나눈 전체 분류 정확도(overall accuracy)를 사용하였다.

가. 시나리오 A

학습 데이터셋은 최종 공용데이터셋 전체를 사용하고, 테스트 데이터셋은 최종 현장용데이터셋의 20%를 사용한다. 이는 공용데이터셋으로 학습한 모델이 실제 현장 환경에 얼마나 적응할 수 있는지를 평가한다.

나. 시나리오 B

학습 데이터셋은 최종 공용데이터셋 50%와 최종 현장용데이터셋 50%를 혼합해서 사용하고, 테스트 데이터셋은 최종 현장용데이터셋의 20%를 사용한다. 이는 두 데이터 도메인을 절반씩 혼합하여 학습함으로써 분류모델이 공용데이터의 일반적인 특징과 현장데이터의 현실적 특징을 동시에 학습하도록 하여 데이터 다양성이 모델의 일반화 및 강건성에 미치는 영향을 분석한다.

다. 시나리오 C

학습 데이터셋은 최종 현장용데이터셋 전체를 사용하고, 테스트 데이터셋은 최종 현장용데이터셋의 20%를 사용한다. 이는 실제 운영 환경에서 취득한 데이터만으로 학습한 모델이 현장 조건에서 최적화된 분류 성능을 보이는지를 검증한다.

2. 모델 구성

본 연구에서는 사전학습 모델 기반 분류모델을 사용한다. 모든 모델은 ImageNet-1K 가중치로 초기화한 후, 마지막 분류층만 신고배 병해충 클래스 수 8개로 교체하였다. 신고배 병해충 이미지 분류 성능 비교를 위한 분류모델은 표 3과 같다.

표 3. 분류모델 구성

	모델명	파라미터수(M)
1	ResNet-101[18]	42.53
2	MobileNetV2[19]	2.24
3	EfficientNet-B0[20]	4.02
4	DeiT[21]	85.81

모든 모델은 PyTorch[22] 프레임워크로 구현되었으며, 표 4와 같이 Optimizer, Loss, Learning Rate Scheduler 등은 모델 간 비교의

일관성을 위해 동일하게 적용하였다.

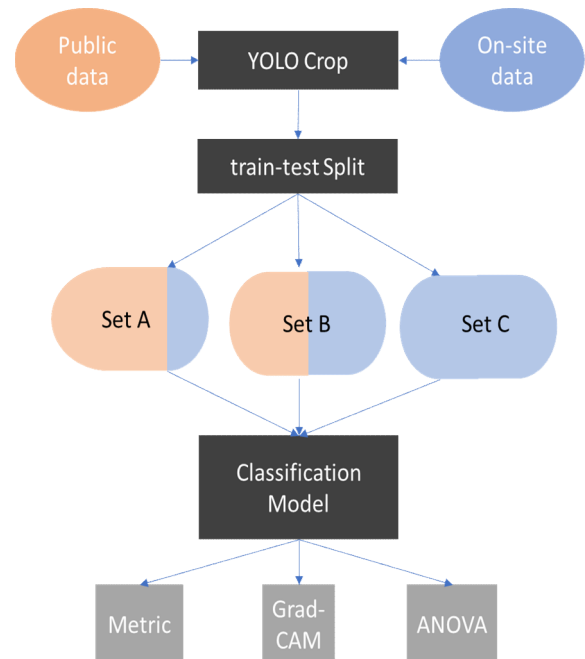


그림 7. 전체 실험 방법 및 모델 구성

표 4. 딥러닝 모델 학습설정

항목	설정값
optimizer	AdamW
base learning rate	1e-3
weight decay	5e-2
batch size	512
learning rate schedule	cosine decay
warmup epochs	10
training epochs	100
augmentation	Random Augmentation
mixup[23]	0.8
cutmix[24]	1.0

최종적으로 그림 7은 전체 실험 방법 및 모델 구성을 요약한 블록 다이어그램이다.

V. 실험 결과 및 분석

1. 시나리오별 분류 성능 비교

본 연구에서는 4장에서 정의한 세 가지 실험 시나리오(A - C)를 기준으로 각 사전학습 분류 모델 ResNet-101, MobileNetV2,

EfficientNet-B0, DeiT를 학습하였다. 모든 실험은 현장용 테스트셋 20%를 공통 평가 데이터로 사용하였다. 표 5는 각 모델의 시나리오별 평균 정확도(Accuracy)를 비교한 결과이다.

표 5. 시나리오별 모델 분류 성능 비교

모델	시나리오 A	시나리오 B	시나리오 C
	정확도	정확도	정확도
ResNet-101	76.78%	93.94%	85.25%
MobileNetV2	61.38%	92.62%	83.27%
EfficientNetB0	68.97%	93.39%	84.15%
DeiT	81.29%	93.39%	86.35%

시나리오 A(공용→현장 평가)는 모델 평균 정확도 72.11%로 가장 낮게 나타났다. 이는 공용 데이터와 현장 데이터 간 도메인 갭으로 인해 배경 질감, 조명, 노이즈 스펙트럼, 촬영·전처리 파이프라인 차이가 누적되어 공용 분포에 적응된 표현이 현장 분포에서 일반화되지 못한 결과로 해석된다. 시나리오 B(공용+현장 혼합 학습)는 평균 93.34%로 A 대비 +21.23%p 향상을 보였고, 이는 분포 커버리지 확장 및 배경·노이즈 변이 학습이 불변 표현을 강화함을 정량적으로 입증한다. 시나리오 C(현장 전용 학습)는 평균 84.76%로 A 대비 +12.65%p 개선되었으나 B 대비 -8.58%p 낮아, 분포 일치의 이점은 확인되되 데이터 규모·다양성의 제약으로 일반화 폭은 혼합 학습에 미치지 못함을 보여준다.

모델별로는 DeiT 87.01%로 가장 높은 정확도를 보이고, ResNet-101 85.32%, EfficientNet-B0 82.17%, MobileNetV2 79.09% 순이었으며, 다만 DeiT는 정확도는 높지만 saliency-map 시각화에서 판단 근거의 타당성이 낮은 경향을 보인다. 자세한 분석은 후속 절에서 설명한다.

종합하면, 세 시나리오 간 성능은 $B > C > A$ 의 순서를 명확히 보이며, 혼합 학습이 정확도와 도메인 적응의 관점에서 가장 우수함을 수치로 입증한다.

3. Saliency Map을 통한 정성 분석

정확도뿐 아니라 의사결정의 투명성과 해석가능성을 확보하기 위해 saliency 기반 정성 분석을 병행하였다. 합성곱 신경망 계열은 Grad-CAM으로, 트랜스포머 계열(DeiT)은 자체 어텐션 맵으로 추론 시 활성화되는 핵심 영역을 시각화하였고, 이를 통해 모델이 예측에 활용한 시각적 근거가 어디에 집중되는지 일관되게 확인된다.

그림 10-16은 각 클래스별 대표 이미지에 대해 산출한 saliency 기반 히트맵으로, 빨간색일수록 모델 예측에 기여한 활성 영역을, 파란색 또는 저채도 영역일수록 기여가 미미한 비활성 영역을 나타낸다. 이를 통해 모델이 어떤 시각적 근거에 의존해 결론에 도달하는지가 정량·정성적으로 시각화되며, 클래스별 주목 영역의 차이가 명확히 드러난다.

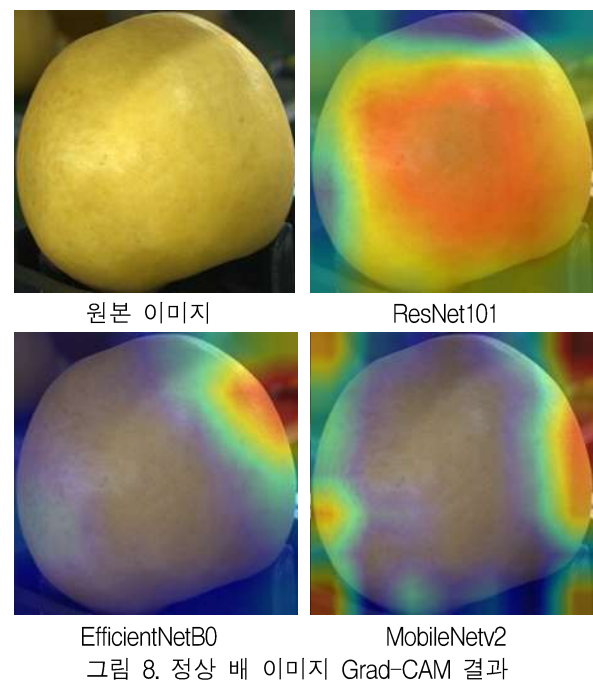
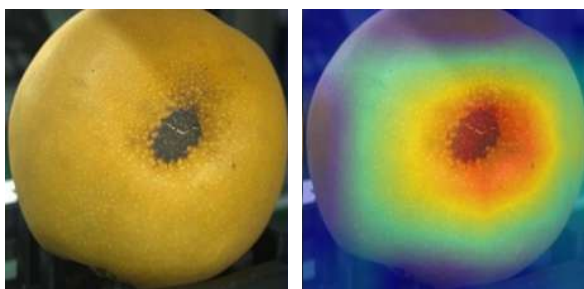
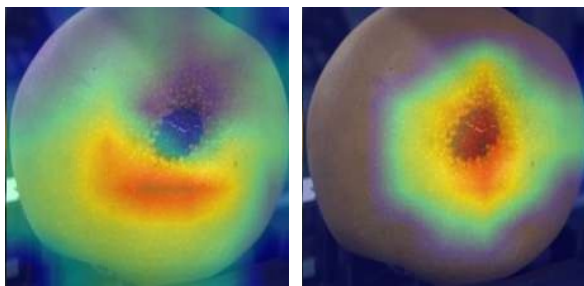


그림 8. 정상 배 이미지 Grad-CAM 결과



원본 이미지

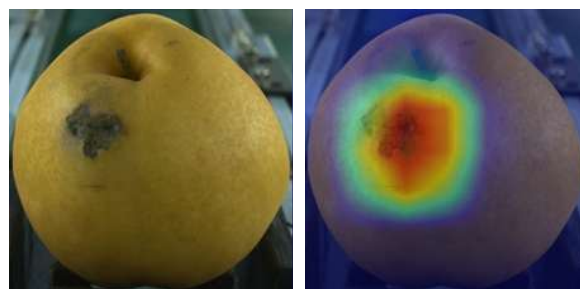
ResNet101



EfficientNetB0

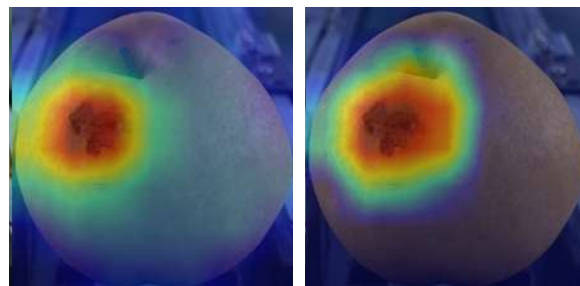
MobileNetv2

그림 9. 흑성병 배 이미지 Grad-CAM 결과



원본 이미지

ResNet101



EfficientNetB0

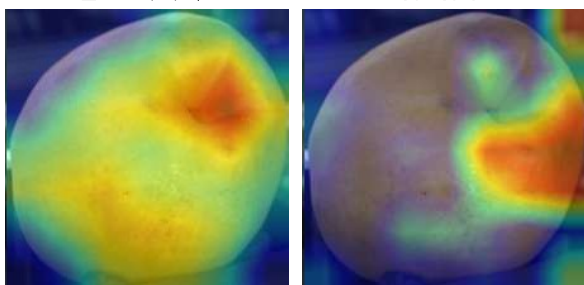
MobileNetv2

그림 11. 복숭아나방류 배 이미지 Grad-CAM 결과



원본 이미지

ResNet101



EfficientNetB0

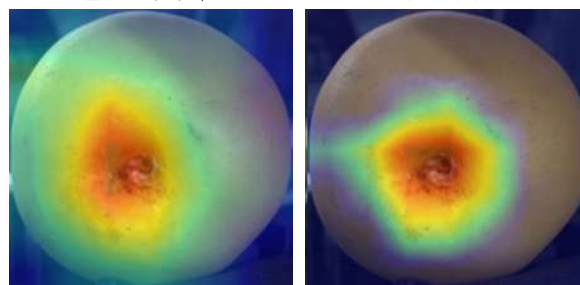
MobileNetv2

그림 10. 과피얼룩 배 이미지 Grad-CAM 결과



원본 이미지

ResNet101



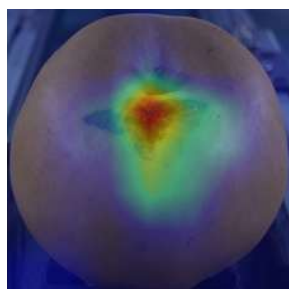
EfficientNetB0

MobileNetv2

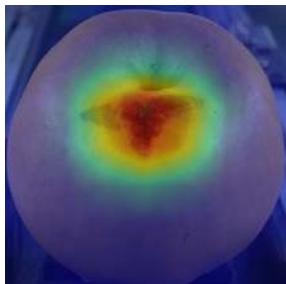
그림 12. 깍지벌레 배 이미지 Grad-CAM 결과



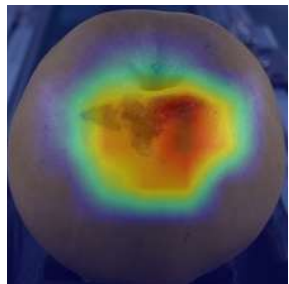
원본 이미지



ResNet101



EfficientNetB0

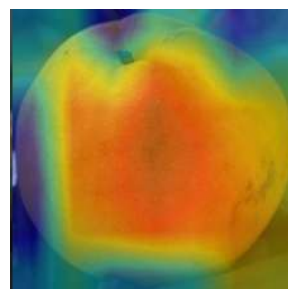


MobileNetv2

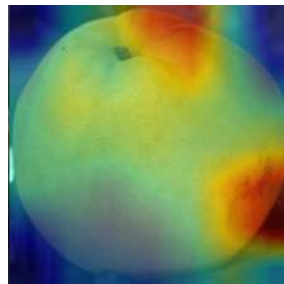
그림 13. 앞말이나방류 배 이미지 Grad-CAM 결과



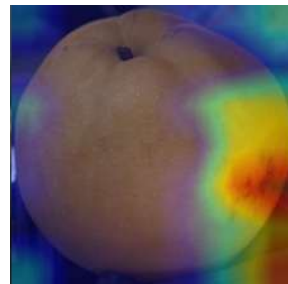
원본 이미지



ResNet101



EfficientNetB0

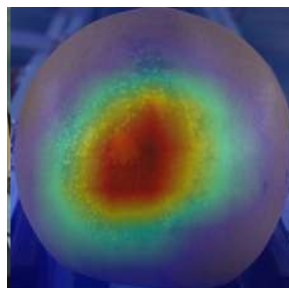


MobileNetv2

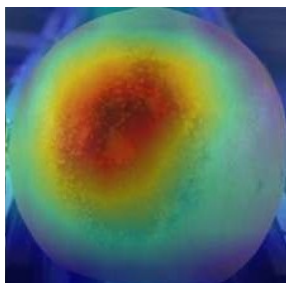
그림 15. 기타사유 손상 배 이미지 Grad-CAM 결과



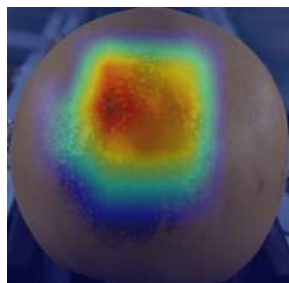
원본 이미지



ResNet101

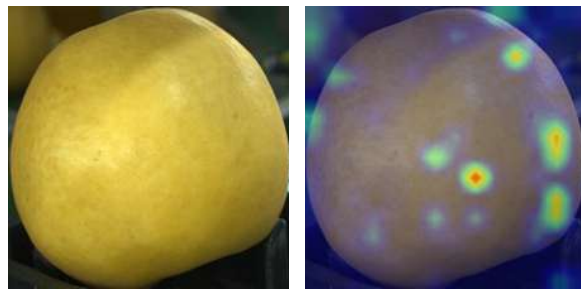


EfficientNetB0



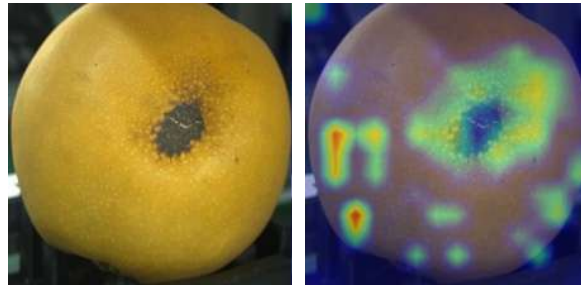
MobileNetv2

그림 14. 과피흑변 배 이미지 Grad-CAM 결과



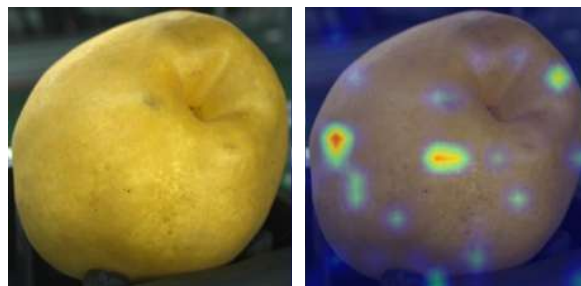
원본 이미지

정상 배



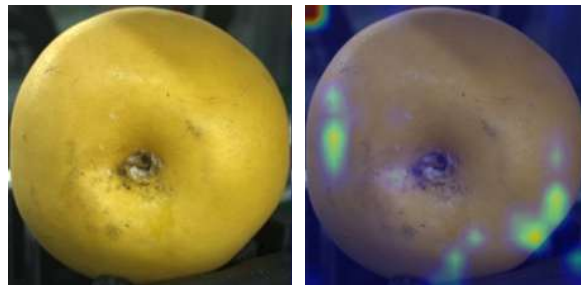
원본 이미지

흑성병



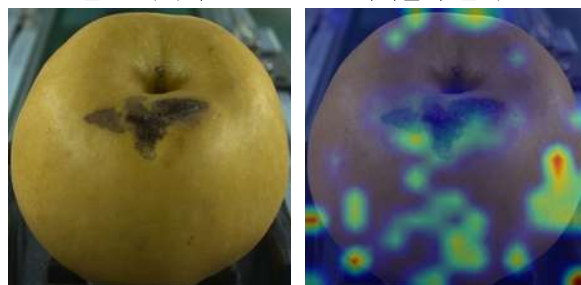
원본 이미지

과피얼룩 클래스



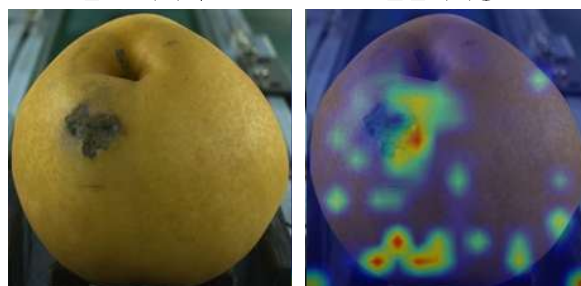
원본 이미지

꼭지벌레 클래스



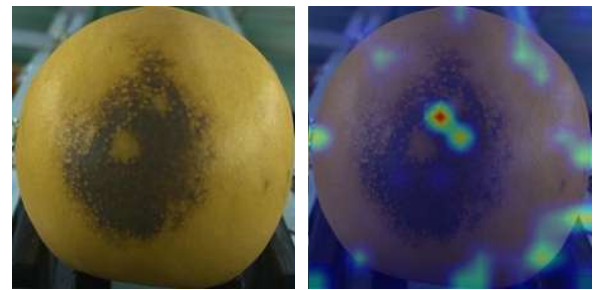
원본 이미지

앞말이나방



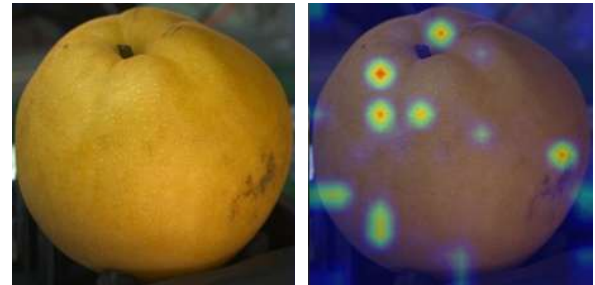
원본 이미지

복숭아나방류



원본 이미지

과피흑변



원본 이미지

기타

그림 16. DeiT모델 클래스별 어텐션맵 시각화

합성곱 신경망 기반 모델 전반은 saliency (Grad-CAM) 기준으로 병변 중심의 활성화가 안정적으로 나타났으며, 성능과 시각화 일관성을 종합하면 MobileNetV2가 가장 우수하고 그다음이 ResNet-101, 이어서 EfficientNet-B0 순으로 평가된다. MobileNetV2는 병변 영역에 뚜렷히 집중해 배경 의존을 최소화했고, ResNet-101은 비교적 넓은 병변 주변 컨텍스트를 활용하는 경향, EfficientNet-B0는 간헐적으로 배경 단서를 참조하는 패턴을 보였다.

한편 트랜스포머 계열인 DeiT는 최종 어텐션 맵이 병변 위주로 수렴하지 못하고 산개하는 양상이 반복되어, 정확도는 높지만 판단 근거의 타당성이 낮고 데이터셋 규모 대비 과적합의 가능성이 크다고 해석한다..

4. 통계적 유의성 검증

모델 및 시나리오 간 성능 차이가 통계적으로 유의한지 검증하기 위해 각 모델의 Accuracy 값을 대상으로 단일요인 분산 분석(One-Way ANOVA)을 수행하였다. 유의수준 $\alpha = 0.05$ 에서 집단 효과가 통계적으로 유의하게 나타났으며

$F(2, 9) = 17.30$, $p = 0.0008$ 로 세 시나리오 간 평균 정확도의 차이가 존재함을 보였다. 전역 검정의 유의성이 확인된 후 Tukey HSD 사후분석을 실시한 결과 시나리오 A는 시나리오 B와 시나리오 C 대비 유의하게 낮은 정확도를 보였고 각각 $p < 0.001$, 평균 차이 21.23% 및 $p = 0.0175$, 평균 차이 12.65%로 확인되었다. 한편 상위 두 집단인 시나리오 B(평균 93.34%)와 시나리오 C(평균 84.76%)의 비교에서는 통계적으로 유의한 차이가 관찰되지 않았으며 $p = 0.0945$ 로, 관측된 평균 차이가 $\alpha = 0.05$ 에서 시나리오 B의 우월성을 단정하기에 충분하지 않음을 입증한다. 결과적으로 시나리오 A가 세 집단 중 가장 낮은 정확도를 보인다는 점은 명확하며, 혼합 학습을 적용한 시나리오 B가 평균적으로 가장 높은 정확도를 보이나 시나리오 C와의 차이는 통계적으로 결정적이지 않다는 점을 확인하였다.

이 결과는 현장용 데이터 기반 학습이 단순히 정확도를 향상시킬 뿐만 아니라, 데이터 도메인 적응 측면에서도 정량적으로 우수함을 입증한다.

VI. 결 론

본 연구에서는 동양배(신고 품종)의 병해충 분류를 위한 공용데이터셋과 현장용데이터셋을 직접 구축하고, 데이터 환경 차이에 따른 인공지능 분류모델의 학습 적합성과 일반화 성능을 비교·분석하였다. 데이터는 순천 농산물유통센터에서 구매한 정상 및 비품용 신고배를 대상으로 전문가의 1·2차 검수를 거쳐 8개 클래스로 분류한 후, 공용데이터셋(스마트폰·균일 조명)과 현장용데이터셋(산업용 카메라·현장 조명 환경)으로 각각 촬영하였다. 이후 사전학습된 ResNet, MobileNetV2, EfficientNet, DeiT 모델을 적용하여 시나리오별 분류 성능을 평가하였다.

실험 결과, 시나리오 B(혼합 데이터셋 학습)에서 모든 모델이 평균 정확도 93.34%로 가장 우수한 성능을 나타냈다. 반면 시나리오 A(공용데

이터셋 학습 → 현장 테스트)에서는 도메인 차이로 인해 정확도가 평균 72.11% 수준으로 낮게 나타났다. 이는 배경 및 노이즈 등의 실제 현장 요인이 모델의 특징 학습에 직접적인 영향을 미친다는 점을 시사한다. Grad-CAM과 어텐션맵 분석을 통해 병해충 부위에 대한 모델의 집중도가 개선된 것을 확인하였다.

이러한 결과는 공용데이터 기반 모델보다 현장용데이터와 같이 혼합된 데이터 기반 학습 모델이 실제 환경 적응성과 신뢰도가 높으며, 실제 선별장 적용을 위한 자동 병해충 분류기 설계 시 데이터셋 수집 단계부터 현장 환경을 반영하는 것이 필수적임을 보여준다. 또한 본 연구에서 제안한 구조는 YOLOv11 기반 전처리를 통해 탐지 모델의 라벨링 부담을 최소화하고, 경량 분류모델을 활용하여 소형 엣지 디바이스에서도 재학습 가능한 구조를 구현할 수 있다는 점에서 산업적 활용 가능성이 크다.

그러나 본 연구는 전남 순천 지역 선별장의 신고배를 대상으로 한 제한된 환경 실험이라는 한계가 있다. 향후 연구에서는 타 지역(예: 나주 등)의 배 재배지에서 다양한 조명, 습도, 기기 환경을 반영한 다지역 데이터셋을 구축하고, 이를 통해 도메인 적응 기반의 통합형 병해충 분류모델을 확장할 계획이다. 또한, 단일 클래스 기반 분류에서 나아가 멀티라벨 병해충 분류 체계를 도입함으로써, 실제 현장 환경에 더 가까운 지능형 품질검수 시스템을 구현하고자 한다.

REFERENCES

- [1] M.K. Park and H. Sim, "Development of AI and IoT-based smart farm pest prediction system: Research on application of YOLOv5 and Isolation Forest models," *The Journal of The Korea Institute of Electronic Communication Sciences*, vol. 19, no. 4, pp. 771-780, 2024
- [2] Y.H. Kim, B.H. Cho, D. Seo, H.Y. Song and K.C. Kim, "The study on crop detection robot system for hydroponic green house," *Journal of Korea Academia-Industrial cooperation Society*, vol. 23, no. 6 pp. 315-322, 2022
- [3] 이지훈, 김진술, "스마트농업 ICT 융합기술 연구 동향 분석," *한국통신학회지*, 제 38권, 제 8호, 19-25쪽, 2021년 7월
- [4] 2024년 배 재배면적조사 결과(2024). https://kostat.go.kr/board.es?mid=a10301010000&bid=229&list_no=431472&act=view&mainXml=Y (accessed Oct., 30, 2025).
- [5] 박홍용, "미국 수출 1위 국가... 한국 배 많이 사랑해주세요", *한국일보*, 2024년 11월
- [6] M.E. Sakka, M. Ivanovici, L. Chaari, and J. Mothe, "A Review of CNN Applications in Smart Agriculture Using Multimodal Data," *Sensors*, vol. 25, no. 2, pp. 472, Jan. 2025.
- [7] LI YU, NamHo Kim, "Research on a system for determining the timing of shipment based on artificial intelligence-based crop maturity checks and consideration of fluctuations in agricultural product market prices," *Smart Media Journal*, Vol. 13, No.1, pp. 9-17, Jan. 2024
- [8] E.J. Lee and J.I. Min, "Explore Influential Color Channels for Quality Classification of Apples Based on CNN," *Journal of Digital Contents Society*, vol. 23, no. 8, pp. 1477-1484, 2022.
- [9] YuJin Ko, HyunJun Lee, HeeJa Jeong, Li Yu, NamHo Kim, "Deep Learning-based system for plant disease detection and classification," *Smart Media Journal*, Vol. 12, No. 7, pp. 9-17, Aug. 2023.
- [10] Han Suk Choi, "Fruit's Defective Area Detection Using Yolo V4 Deep Learning Intelligent Technology," *Smart Media Journal*, Vol. 11, No. 4, pp. 46-55, May, 2022.
- [11] J. Liu and X. Wang, "Plant diseases and pests detection based on deep learning: a review," *Plant Methods*, vol. 17, no. 22, 2021.
- [12] S. Pan and T. Ahamed, "Pear Recognition in an Orchard from 3D Stereo Camera Datasets to Develop a Fruit Picking Mechanism Using Mask R-CNN," *Sensors*, vol. 22, no. 11, pp. 4187, 2022.
- [13] M. Zhang, C. Liu, Z. Li, and B. Yin, "From Convolutional Networks to Vision Transformers: Evolution of Deep Learning in Agricultural Pest and Disease Identification," *Agronomy*, vol. 15, no. 5, pp. 1079, 2025.
- [14] K. Wang, W. Li, X. Wu, J. Xu, Z.W. Wang, and S. Yang, "AP162: A large-scale dataset for agricultural pest recognition," *Computers and Electronics in Agriculture*, vol. 237, Part B, 2025.
- [15] Y. Hao, C. Zhang, X. Li, and Z. Lei, "Establishment of online deep learning model for insect-affected pests in "Yali" pears based on visible-near-infrared spectroscopy," *Frontiers in Nutrition*, vol. 9, 2022.
- [16] 농산물 품질(QC) 이미지(2020). <https://aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=data&dataSetSn=149> (accessed Oct., 30, 2025).
- [17] 당탄부, 장진호, 김순천, 이현주, "클래스 밸런싱을 통한 YOLO11 기반 배 결함 검출 성능 향상," *2025 한국디지털콘텐츠학회 하계종합학술대회*, pp. 617-618, 2025년 7월
- [18] He, K., Zhang, X., Ren, S., & Sun, J. Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition* pp. 770-778, Jun. 2016.
- [19] Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. Mobilenetv2: Inverted residuals and linear bottlenecks. *In Proceedings of the IEEE conference on computer vision and pattern recognition*. pp. 4510-4520, Jun. 2018.
- [20] Tan, M. et al. Efficientnet: Rethinking model scaling for convolutional neural networks. *In International conference on machine learning* pp. 6105-6114. May 2019.
- [21] Touvron, Hugo, et al. "Training data-efficient image transformers & distillation through attention." *International conference on machine learning*. PMLR, 2021.
- [22] Paszke, Adam, et al. "Pytorch: An imperative style, high-performance deep learning library." *Advances in neural information processing systems*. 32 (2019).
- [23] Carratino, Luigi, et al. On mixup regularization.. *Journal of Machine Learning Research* , Vol.23, No.325 pp. 1-31, 2022.
- [24] Yun, S., Han, D., Oh, S. J., Chun, S., Choe, J., & Yoo, Y. (2019). Cutmix: Regularization strategy to train strong classifiers with localizable features. *In Proceedings of the IEEE/CVF international conference on computer vision* pp. 6023-6032, Nov. 2019.

저 자 소 개

**이 진(정회원)**

2021년 전남대학교 전자정보통신공학
학사 졸업.

2025년 전남대학교 지능전자컴퓨터공
학과 석사 졸업.

<주관심분야 : 인공지능, 컴퓨터비
전>

**김진영(정회원)**

1986년 서울대학교 전자공학과 학사
졸업.

1988년 서울대학교 전자공학과 석사
졸업.

1994년 서울대학교 전자공학과 박사
졸업.

<주관심분야 : 디지털 신호처리, 영상
처리, 음성 신호처리, 머신러닝, 딥러닝>

**Le Hoang Anh(정회원)**

2020년 호치민시티 과학대학교 수하
과 학사 졸업.

2023년 전남대학교 ICT융합시스템공
학과 석사 졸업.

<주관심분야 : 인공지능, 시계열예
측>

**이헌주(정회원)**

2018년 전남대학교 컴퓨터정보통신공
학 학사 졸업.

2025년 전남대학교 지능전자컴퓨터공
학과 박사 졸업.

<주관심분야 : 센서시스템, 신호처리,
의생명공학>

**조정안(정회원)**

2000년 전남대학교 응용식물학부 학
사 졸업.

2002년 전남대학교 원예학과 석사 졸
업.

2006년 전남대학교 원예학과 박사 졸
업.

<주관심분야 : 과수 시설재배, 과수
수확후관리, 아열대 과수 재배>

**유광현(정회원)**

2015년 조선대학교 전자공학과 학사
졸업.

2018년 전남대학교 전자공학과 석사
졸업.

2023년 전남대학교 ICT융합시스템공
학과 박사 졸업.

<주관심분야 : 디지털 신호처리, 영상
처리, 머신러닝, 딥러닝>