

토마토 잎 병해 분류를 위한 최소 라벨 데이터 활용: YOLOv8 기반 재귀적 학습 방식을 통한 접근

Utilizing Minimal Label Data for Tomato Leaf Disease Classification:
An Approach through Recursive Learning Based on YOLOv8

이준혁 · 김남형[†]

가천대학교 응용통계학과

요약

클래스 불균형은 딥러닝 작업에서 중요한 문제 중 하나이며, 이는 특히 데이터가 제한적인 분야에서 두드러진다. 본 연구에서는 토마토 잎의 병해를 효과적으로 분류하기 위해 최소한의 라벨 데이터만을 활용하는 새로운 접근법을 제안한다. 이를 위해 YOLOv8 모델을 사용한 재귀적 학습 방식을 도입하였다. 학습 데이터에 대한 이미지 탐지 예측 결과를 다시 학습 데이터로 활용함으로써 라벨 데이터의 개수를 점진적으로 증가시켰다. 이 방식은 기존의 데이터 증강 및 업-다운 샘플링 기법과는 달리 실제 데이터의 활용도를 극대화하여 클래스 불균형 문제를 보다 근본적으로 해결하려 한다. 이를 통해 확보된 라벨 데이터를 바탕으로, 토마토 잎을 추출하고 EfficientNet 모델을 이용해 병해를 분류했다. 이 과정을 통해 98.92%라는 높은 정확도를 달성하였다. 특히, 가장 적은 데이터를 가진 클래스인 잎마름역병 병해에서 기존 대비 12.9% 향상된 결과를 확인할 수 있었다. 이 연구는 데이터 불균형 문제를 해결하는 동시에, 높은 정확도로 병해를 분류할 수 있는 방법론을 제시함으로써 다른 작물에서도 적용될 수 있을 것으로 기대된다.

■ 중심어 : 클래스 불균형, 재귀적 학습, YOLOv8, EfficientNet, 토마토 병해

Abstract

Class imbalance is one of the significant challenges in deep learning tasks, particularly pronounced in areas with limited data. This study proposes a new approach that utilizes minimal labeled data for effectively classifying tomato leaf diseases. We introduced a recursive learning method using the YOLOv8 model. By utilizing the detection predictions of images on the training data as additional training data, the number of labeled data is progressively increased. Unlike conventional data augmentation and up-down sampling techniques, this method seeks to fundamentally solve the class imbalance problem by maximizing the utility of actual data. Based on the secured labeled data, tomato leaves were extracted, and diseases were classified using the EfficientNet model. This process achieved a high accuracy of 98.92%. Notably, a 12.9% improvement compared to the baseline was observed in the detection of Late blight diseases, which has the least amount of data. This research presents a methodology that addresses data imbalance issues while offering high-precision disease classification, with the expectation of application to other crops.

■ Keyword : Class Imbalance, Recursive Learning, YOLOv8, EfficientNet, Tomato Disease

2024년 05월 23일 접수; 2024년 06월 17일 수정본 접수; 2024년 06월 18일 게재 확정.

* 이 논문은 2023년도 가천대학교 교내연구비 지원에 의한 결과임.(GCU-202303450001) 본 연구는 과학기술정보통신부의 지원으로 한국지능정보사회진흥원의 지원을 받아 구축된 “노지 작물 질병 진단 이미지 데이터”, “시설 작물 질병 진단 이미지 데이터”, “식물 병 유발 통합 데이터”를 활용하여 수행된 연구입니다. 본 연구에 활용된 데이터는 AI Hub(ahub.or.kr)에서 다운로드 받으실 수 있습니다.

[†]교신저자 (nhkim@gachon.ac.kr)

I. 서론

인공지능 기술의 급속한 발전이 전통적인 학문 영역과의 융합을 촉진함에 따라 특히 생존과 밀접하게 연결된 스마트팜 분야에서는 많은 연구가 진행되고 있다[1,2].

기존의 토마토 병해 진단과 관련된 PlantVillage 데이터셋[3]은 낮은 해상도와 한국에 특화된 토마토 품종 및 병해 정보의 결여로 인해 한국 농가에서 실제 적용하기에 어려운 문제가 있었다. 이러한 문제에 대응하기 위하여 2017년부터 시작된 정부 주도의 지능정보산업 인프라 조성사업을 통해 획득된 스마트팜 관련 데이터는 국내 상황에 적합한 고해상도 이미지와 보다 상세한 어노테이션 정보를 제공함으로써 데이터의 품질을 고도화할 수 있었다[4].

한국의 토마토 병해 진단과 분류를 위한 연구는 AI Hub를 통해 국내 농가 데이터[5]가 확보됨에 따라서 활발히 이루어졌다. 그러나 AI Hub에서 제공되는 토마토 병해 이미지 데이터셋은 예산 및 시간의 제약으로 이미지 당 하나의 일만 바운딩 박스로 라벨링이 되어 있으며 이미지 내 다른 잎에 대한 라벨링 작업이 수행되지 않았다. 본 연구는 AI Hub 데이터셋의 한계를 극복하기 위해 이미지 객체 탐지 모델을 활용한 재귀적 학습(Recursive Learning) 방법론을 적용하였다. YOLOv8 모델을 학습하여 한 이미지에 다수의 잎을 탐지하고 이를 다시 학습에 활용하는 재귀적 학습 방식을 적용하여 이미지 내 다수의 잎에 대한 라벨 정보를 확보함으로써 이러한 제약을 극복하였다. 이는 전체 데이터의 수를 증가시키는 것뿐만 아니라 소수의 이미지를 가진 병해 클래스에 대한 예측 성능을 향상시키는 효과를 보였다. 또한 이미지 객체 탐지 모델을 적용하여 탐지된 개별 잎들을 추출하여 학습에 사용하였을 때 예측 성능이 향상되는 것을 확인할 수 있었다.

본 연구에서 제안한 방법론은 한국 토마토 병해의 정밀 진단 및 분류에 있어 중요한 기술적 발전을 대표한다. 본 연구에서는 AI Hub 데이터셋의 고해상도 이미지와 포괄적인 정보를 활용하여 토마토 병해 문제에 더욱 적합한 정밀하고 신뢰성 높은 병해 진단 및 분류 기법의 개발을 통해 일반화 성능을 향상시키는 것을 목표로 하였다. 이러한 연구 방향과 결과는 스마트팜 기술의 발전뿐만 아니라 농업 분야에 인공지능을 적용하는 방식에 있어 중요한 기여를 할 것으로 기대된다. 특히, 본 연구의 차별화된 접근법은 한정된 자원 내에서도 연구의 범위와 품질을 향상시킬 수 있는 가능성을 제시하며, 이 방식은 농업 분야뿐만 아니라 다른 분야에서도 데이터 활용의 최적화와 모델 성능의 개선을 추구하는 연구에 적용될 수 있는 잠재력을 가지고 있다.

따라서 본 연구의 재귀적 학습 방식은 YOLOv8을 활용한 객체 탐지 연구의 새로운 방향을 제시하며 향후 다양한 응용 분야에서의 연구로 그 가능성이 더욱 확장될 것으로 기대된다.

II. 관련 연구

2.1 토마토잎 병해층 예측 관련 선행 연구

2.1.1 국내 동향

최근 연구에서는 딥러닝 기술을 활용하여 토마토 잎의 병해층을 정확하고 신속하게 분류 및 탐지하는 다양한 방법이 제안되었다. 이러한 연구는 농업 분야에서 딥러닝의 적용 가능성을 크게 확장시켰으며, 특히 토마토 잎 병해층 예측 분야에 중요한 기여를 하였다.

채종욱과 신영학(2022)은 Grad-CAM 기술을 통해 모델의 판단 근거를 시각화하여 제공함으로써 사용자가 분류 결정을 이해할 수 있도록 하였다. 실험에서는 EfficientNet-B0 모델을 사용하였고, 99.16%의 높은 분류 정확도와 0.032

초의 빠른 추론 속도를 달성했다[6].

나명환 외 2인(2020)은 사전 학습된 CNN(Convolutional Neural Networks) 모델들과 결합된 Faster R-CNN 형태의 딥러닝 알고리즘을 사용하였다. 토마토 식물에서 발생하는 주요 4가지 병해의 이미지 데이터를 기반으로 웹 애플리케이션 플랫폼을 제안하여 농부들이 촬영한 이미지를 업로드하면 병해에 대한 식별 및 관리 정보를 제공하였다[7].

합현식 외 6인(2020)에서 사용된 Inception V3 모델은 98.9%의 높은 정확도를 보였다. 하지만 데이터 수가 적은 클래스는 소량의 데이터 차이로도 성능 수치가 급격히 변화하는 경향을 나타내었다[8].

이전 연구들은 대체로 2019년에 개방된 AI Hub의 초기 데이터셋을 활용하거나[5], 제한된 범위에서 직접 수집한 영상 자료에 의존하였다[7]. 이러한 연구는 데이터의 대표성 측면에서 한계를 지니며, 실제 농업 환경의 복잡한 조건들을 충분히 반영하지 못할 가능성이 있음을 시사한다. 본 연구는 이러한 문제의식을 바탕으로 더 광범위하고 다양하며 실제 조건의 반영이 가능한 최신 데이터의 활용에 중점을 두었다. 본 연구에서는 AI Hub에서 2021년과 2022년에 개방된 토마토 잎 병해 관련 국내 이미지 데이터셋을 사용하였다[9, 10, 11]. 이와 같은 접근은 토마토 잎 병해 예측의 정확도 및 신뢰성을 제고하며, 실제 농업 환경에서의 적용 가능성을 크게 향상시킬 것으로 기대된다.

2.1.2 해외 동향

해외에서는 PlantVillage 데이터셋을 기반으로 식물 병해에 관한 다양한 연구가 지속적으로 이루어지고 있다. 이 연구들은 기계학습과 딥러닝 기술을 이용하여 대규모 농장에서 식물 병해를 자동으로 탐지하고 분류하는 데 중점을 두고 있다.

Ahmed & Yadav(2023)은 SVM(Support Vector Machines), GLCM(Gray-Level Co-occurrence Matrices), CNN을 사용하여 예측 모델을 개발하였다[13].

Ulutaş & Aslantas(2023)와 He et al.(2023)는 다양한 기계학습 모델과 CNN 모델을 사용하였는데, 특히 앙상블 분류 접근 방식을 사용하여 토마토 병해를 분류하였다[14,15].

Lim & Attallah(2023)와 Ahmed et al.(2022)는 compact CNN 모델 중 하나인 MobileNet과 사전 학습된 모델을 적용하는 전이 학습(Transfer Learning) 기반 방법을 사용하여 저성능 디바이스에서도 적용 가능한 효율적인 시스템을 제공하였다[16,17].

Ullah et al.(2023)는 경량화된 DeepPlantNet 모델을 제안하여 식물 잎 병해를 예측하였다. 총 28개의 학습된 레이어로 구성되어 있으며, 이중 25개는 컨볼루션 레이어(Convolutional, ConV)이고 3개는 완전 연결 레이어(Fully Connected, FC)이다. 이 모델은 Leaky ReLU(LReLU) 활성화 함수, 배치 정규화(Batch Normalization, BN), Fire 모듈, 그리고 3×3 및 1×1 필터를 혼합하여 프레임 워크를 구성하였다[18].

Gangwar et al.(2023)는 이미지 세그멘테이션(image segmentation) 모델을 사용하여 토마토 병해 탐지를 위한 딥러닝 기반 접근법을 제안한다. 이미지 세그멘테이션 모델의 대표적인 모델인 U-Net을 사용하여 잎의 이미지를 세분화한 후, CNN 모델을 통해 98.12%의 높은 정확도를 달성하여 자동화된 토마토 병해 탐지에 있어 유망한 기술임을 증명하였다[19].

Abbas et al.(2021)는 조건부 생성적 적대 신경망(C-GAN)을 사용하여 합성 이미지(synthetic images)를 생성하고, 이를 이용해 토마토 잎 병해를 탐지하는 딥러닝 기반 방법을 제안하였다. 이 연구는 전이 학습을 사용하여 DenseNet121 모델을 학습시켜 병해 예측을 수행하였다[20].

최근 연구는 성능과 효율성을 모두 향상시키기 위해 경량화 모델과 전이학습, 앙상블 방법, 그리고 조건부 생성적 적대 신경망(C-GAN) 등을 활용하는 방향으로 진행되고 있다. 본 연구는 이러한 최신 동향을 반영하여, 경량화된 EfficientNet-B0 모델을 선택하였다. 또한 국내 농업 환경에 더욱 적합하도록 AI Hub에서 제공하는 국내 데이터를 사용함으로써 모델의 일반화된 성능을 개선하고자 하였다.

2.2 YOLOv8

본 연구에서 이미지 내 토마토 잎을 탐지하기 위해 활용한 YOLO(You Only Look Once)는 객체 탐지 분야에서 널리 인정받는 알고리즘으로 특히 YOLOv8은 이 시리즈의 최신 버전이다. YOLOv8은 end-to-end 객체 탐지 모델로서 고도로 최적화되어 이전 버전들에 비해 속도와 정확도 면에서 개선되었다고 알려져 있다[21].

이 모델은 파이썬 패키지 관리자인 pip을 통해 쉽게 설치할 수 있어, 복잡한 과정 없이 모델을 손쉽게 적용할 수 있게 한다.


YOLOv8은 높은 처리 속도와 효율성을 자랑하며, 이미지 내의 다양한 크기와 모양의 객체를 실시간으로 감지하는 데 효과적이다. 이는 토마토 잎과 같은 특정 대상을 다양한 조건에서 정확하게 식별할 수 있도록 한다.

<그림 1>을 보면 YOLOv8의 Backbone은 점진적인 다운샘플링을 통해 이미지에서 중요한 특징 정보를 추출한다. 이 과정에는 여러 계층

의 컨볼루션 레이어와 SPPF(Spatial Pyramid Pooling-Fast) 모듈이 포함되어 있다. SPPF는 다양한 커널 크기를 사용하는 최대 풀링을 통해 다양한 해상도의 정보를 효과적으로 통합하고, 스케일 불변성을 높여 더 풍부한 이미지 정보를 제공한다. C2f 모듈은 각 컨볼루션 레이어 이후에 배치되어, 두 개의 3x3 컨볼루션을 통해 처리되는 병목(Bottleneck) 구조를 포함한다. 이 병목 구조의 출력은 여러 부분으로 분할된 후 다시 연결되고, 최종 컨볼루션 레이어를 통해 처리되어 복잡한 특징을 나타낸다.

Head 부분은 Backbone에서 추출된 다양한 스케일의 특징맵을 활용하여 객체 감지를 수행한다. 각 스케일의 특징맵은 업샘플링과 이전 스케일의 특징맵과의 합성을 통해 고해상도의 감지 정보를 생성한다. 최종적으로 통합된 특징맵을 통해 객체의 위치, 크기 및 클래스를 예측한다. 이러한 YOLOv8의 멀티스케일 감지 능력은 작은 객체부터 큰 객체까지 다양한 크기를 효과적으로 처리할 수 있도록 한다.

특히, 기존의 앵커 기반 방식에서는 미리 정의된 다양한 크기와 비율의 앵커 박스(anchor boxes)를 사용하여 객체의 위치를 예측하였다. 반면, YOLOv8의 앵커 프리 방식에서는 객체 중심을 직접 예측할 수 있으므로 예측 매커니즘이 단순화되고 앵커 상자 계산과 관련된 복잡성이 모델에서 완화된다. 이러한 발전은 예측 상자 수의 감소로 이어져 NMS(Non-Maximum Suppression)의 후처리 단계를 간소화한다. 앵커

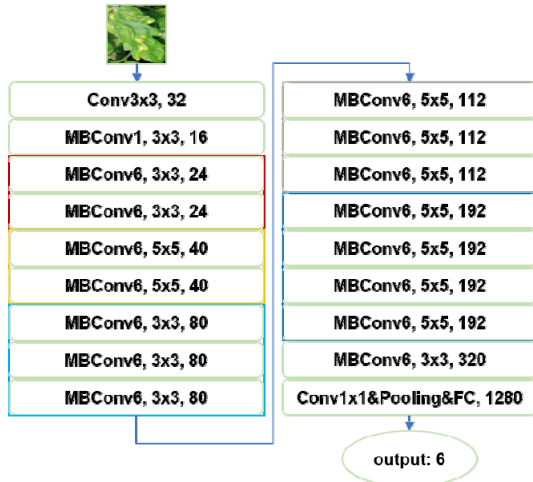


<그림 1> YOLOv8 Architecture[12]

프리 방식은 실시간 애플리케이션의 중요한 요소인 모델의 추론 속도를 향상시킨다.

2.3 EfficientNet

본 연구에서 토마토 잎 병해 예측을 위한 분류 모델로 사용된 EfficientNet은 이미지 분류를 위한 효율적인 딥러닝 모델이다[22]. 이 모델은 복합 스케일링 방식을 통해 네트워크의 깊이, 너비, 그리고 이미지 해상도를 균형 있게 조정하여 성능을 극대화한다.



<그림 2> EfficientNet-B0 Architecture

<그림 2>의 구조를 보게 되면, MBConv (Mobile Inverted Residual Bottleneck Convolution) 블록을 사용하여 특징을 추출한다. MBConv1은 expansion factor가 1인 구조로, 입력 채널을 확장하지 않는다. Depthwise 컨볼루션 레이어와 1x1 컨볼루션 레이어로 구성된다. 이 구조는 파라미터 수를 크게 줄이면서도 효율적인 특징 추출을 가능하게 한다. MBConv6은 expansion factor가 6인 구조로, 입력 채널 수를 임시적으로 6 배 확장한 후 다시 원래의 크기로 축소한다. 즉, 1x1 컨볼루션을 통해 채널을 확장하고, 3x3 Depthwise 컨볼루션을 사용하여 각 채널에서 특

징을 추출한 후, 다시 1x1 컨볼루션을 통해 채널 수를 원래대로 축소한다. 이 과정에서 복잡한 특징을 더 효과적으로 추출할 수 있다[23].

이 모델은 YOLOv8으로 추출해낸 토마토 잎 이미지의 병해를 분류하는 데 최적화되어 있으며 토마토 잎의 다양한 병해 패턴을 학습하여 구체적인 병해 유형을 정확히 예측할 수 있다.

우리는 두 모델을 결합함으로써 토마토 잎을 빠르고 정확하게 객체 감지할 수 있는 YOLOv8의 능력과 EfficientNet이 제공하는 정교한 이미지 분류 성능을 함께 활용할 수 있다. 이 두 모델의 시너지는 토마토 잎의 병해를 정확하게 예측하는 효과적인 시스템을 구축할 수 있게 해준다.

2.4 연구의 차별성

본 연구는 토마토 잎 병해 진단 및 분류의 정밀성을 향상시키기 위한 방법론으로 기존 연구들과 비교하여 다음과 같은 주요 차별성을 보인다.

우선, YOLOv8 모델을 활용한 재귀적 학습 방식은 신선한 접근 방식이라 할 수 있다. 대다수의 선행 연구가 고정된 데이터셋에 의존하는 반면, 본 연구는 모델의 성능을 지속적으로 개선할 수 있도록 학습 데이터셋을 동적으로 확장하는 방안을 제안한다. 이 방법은 데이터의 제한성이나 라벨링 비용 및 시간과 같은 문제들을 해결하는 데 특히 유용하다.

둘째, 본 연구는 최신 기술인 YOLOv8을 적용함으로써, 객체 탐지의 속도와 정확도 면에서 상당한 개선을 도모한다. YOLOv8의 고도로 최적화된 성능은 잎 이미지를 정확하게 감지하여 라벨링에 도움을 준다.

셋째, 본 연구에서 도입한 재귀적 학습 방식은 클래스 불균형 문제에 대한 효과적인 해결책을 제공한다. 기존에 라벨링된 데이터를 기반으로 모델이 점진적으로 다양한 데이터로부터 학습하게 함으로써, 분류 정밀도 및 모델의 일반화 능력을 향상시킨다. 이는 소수 클래스 데이

〈표 1〉 학습 및 검증 데이터셋 수량

데이터셋	병해	Base	YOLOv8 R1	YOLOv8 R2	YOLOv8 R3	YOLOv8 R4	YOLOv8 R5	YOLOv8 R6
학습 (Training)	정상	16,386	16,809	17,238	17,865	18,833	21,082	24,188
	흰가루병	10,351	10,626	10,869	11,152	11,516	12,453	13,636
	갯빛곰팡이병	8,071	8,147	8,229	8,351	8,615	9,123	9,770
	황화잎말이 바이러스병	985	1,240	1,463	1,641	1,796	2,133	2,418
	잎곰팡이병	745	792	860	970	1,098	1,342	1,598
	잎마름역병	190	255	353	454	523	646	757
	Total	36,728	37,869	39,012	40,433	42,381	46,779	52,367
검증 (Validation)	정상	2,235	2,294	2,371	2,457	2,602	2,959	3,437
	흰가루병	1,412	1,461	1,515	1,557	1,606	1,729	1,917
	갯빛곰팡이병	1,101	1,117	1,133	1,151	1,188	1,255	1,362
	황화잎말이 바이러스병	135	172	229	282	310	355	396
	잎곰팡이병	102	108	125	143	170	220	265
	잎마름역병	26	38	54	68	78	100	128
	Total	5,011	5,190	5,427	5,658	5,954	6,618	7,505

터에 대한 분류 능력을 개선하는 데 중요하다.

마지막으로 본 연구는 기존 연구들과 차별화되어 이미지의 신뢰성을 보장하는 메타데이터를 포함한 2021년과 2022년에 개방된 한국 특화 토마토 잎 병해 데이터를 사용한다. 이는 국내 지역적 특성을 반영한 진단 및 분류 방법론을 개발함으로써, 국내 스마트팜기술과 농업 분야에 인공지능 적용의 새로운 방향을 제시한다.

종합적으로 볼 때, 본 연구는 고성능 YOLOv8 모델 기반의 재귀적 학습 방식, 데이터셋의 동적 확장을 통한 성능 개선 전략, 클래스 불균형 문제 해결 능력, 그리고 지역적 특성에 기반한 병해 진단 방법론 개발이라는 점에서 기존 연구들과 차별화된다.

III. 연구 방법

3.1 데이터 구축


2019년 개방한 농업 지식베이스 데이터셋[5]

〈표 2〉 테스트 데이터셋 수량

병해	수량
정상	2,459
흰가루병	1,470
갯빛곰팡이병	1,145
황화잎말이 바이러스병	137
잎곰팡이병	109
잎마름역병	31
Total	5,351

은 초기에 구축되어 이미지 어노테이션 정보가 미비하고 정답 분류의 오류가 있는 이미지[6]가 포함되어 있어 신뢰성이 낮다고 판단되었다. 따라서 이후에 구축된 AI Hub 데이터[9,10,11]를 본 연구에 사용하였다.

AI Hub에서 제공된 데이터 라벨링은 촬영 부위에 바운딩 박스를 적용하여 진행하였으며, 완성된 이미지 파일은 두 명 이상의 전문가가 교차 검증을 통해 신뢰성을 확보하였다[9,10,11].



<그림 3> 각 클래스별 AI Hub 구축 이미지 예시

각 클래스별 원본 데이터의 예시는 <그림 3>에서 확인할 수 있다. 각 병해별 특징으로는 흰가루병의 경우 잎에 주로 흰가루 형태로 나타나며, 확산이 쉽기 때문에 초기 관리가 중요하다. 잿빛곰팡이병은 초기에 갈색의 작은 원형병반으로 나타나며, 병반이 확대되면 식물 전체가 마르고 죽을 수 있다. 황화잎말이바이러스병은 전생육기에 걸쳐 주로 잎과 가지에 먼저 발생하며, 잎은 정상보다 작아지고 곱슬거리며 노랗게 변한다. 잎곰팡이병은 초기에 잎 표면에 담황색의 작은 반점이 나타나고, 이 반점들은 시간이 지남에 따라 확대된다. 말기에는 잎이 연한 녹색이나 갈색으로 변하게 된다. 잎마름역병은 주로 잎과 잎자루에 발생하며, 뜨거운 물에 데친 것처럼 수침상의 병반이 나타난다.

AI Hub에서 제공된 총 105,671개의 이미지 중에서 이미지 파일명 형식 정보를 활용하여 잎이 아닌 부위 및 중복 이미지를 식별하고 제거하였다. 그 결과, 58,581개의 이미지를 제외하고 최종적으로 47,090개의 이미지 데이터를 선별하였다. 데이터셋을 구성하는 다음 단계에서는 선별된 이미지 데이터를 학습 및 검증 그리고 테스트 데이터셋으로 분리하였다. 이때, 계층적 샘플링

<표 3> 이미지 삭제 기준

병해	너비	높이
정상	125	111
흰가루병	200	392
잿빛곰팡이병	331	421
황화잎말이바이러스병	131	152
잎곰팡이병	313	204
잎마름역병	67	92

플링 방법을 적용하여 클래스별 데이터 분포가 균일하게 유지되도록 하였다. 학습 및 검증 데이터셋, 테스트 데이터셋의 비율은 89:11로 설정하였다.

최종적으로 재귀적 학습 방법론을 적용하여 구축된 데이터셋의 구성은 <표 1, 2>를 통해 확인할 수 있다. AI Hub에서 구축된 원본 이미지들은 각 이미지 당 하나의 바운딩 박스 라벨링 정보를 포함하고 있으며 이미지 내 나머지 잎들에 대한 라벨링 정보는 제공되지 않는다. <표 1>에서 'Base'가 AI Hub에서 제공된 라벨 데이터의 수이다. YOLOv8 R1은 객체탐지 모델을 Base 데이터에 적용하여 기존의 이미지에서 추가 잎을 추출한 결과이며, YOLOv8 R2는 YOLOv8 R1의 데이터를 가지고 객체탐지 모델을 학습한 후 새로 탐지된 잎을 추가한 결과이다. 모델을 재귀적으로 적용함에 따라 라벨 데이터의 수가 점진적으로 증가하고 있다. 특히 데이터 수가 적은 클래스의 라벨 개수가 증가하는 비율이 높은 것을 확인할 수 있다. 가장 수가 적은 클래스인 잎마름역병의 경우 학습 및 검증 데이터셋의 크기가 원본데이터에서 216이었던 것이 YOLOv8 R6까지 진행했을 때 885로 약 4배 정도 증가하였다. 이는 분류 문제에서 클래스 불균형 문제를 해결할 수 있는 방안을 제시한다. <표 2>의 테스트 데이터셋은 AI Hub에서 제공된 라벨 데이터만 사용하였다.

또한 분류 모델을 적용하는 단계에서 잎만 추출한 이미지를 사용하였을 때 예측 성능의 향상

이 이루어지는 확인해 보기 위하여 학습과 테스트에 앞 추출 이미지 데이터를 사용하였다. YOLOv8 모델을 통해 라벨링이 된 앞 이미지를 바운딩 박스로 잘라내어 앞만 추출한 이미지를 만들었다. 한 이미지에 여러 앞이 있는 원본 이미지를 학습에 사용하였을 때 분류 모델의 성능에 좋지 않은 영향을 미칠 것으로 예상하였다. 앞 추출 이미지를 사용하였을 때 예측 성능의 향상이 이루어지는지 확인해 보기 위하여 원본 이미지를 사용하였을 때의 성능과 비교해보았다.

3.2 학습 방법

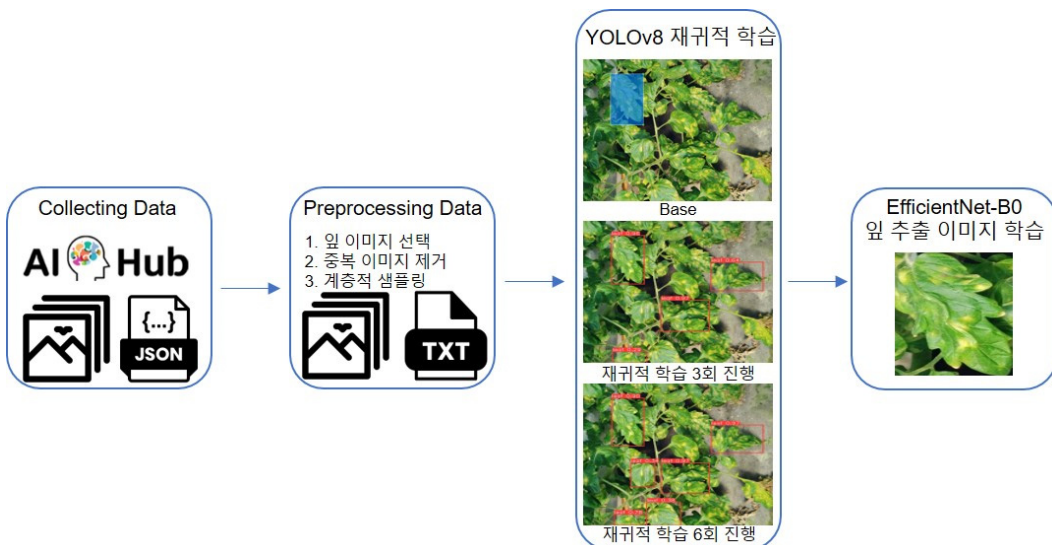
3.2.1 YOLOv8을 이용한 재귀적 학습 방법론

재귀적 학습 방식은 초기에 라벨링된 학습 데이터를 사용하여 YOLOv8 모델을 학습시킨 후, 모델이 학습 데이터에 대해 예측을 수행하게 한다. 이 예측 결과는 바운딩 박스의 크기가 Base 데이터셋의 클래스별 최소 바운딩 박스의 크기를 기준으로 이보다 작은 경우에 제거하는 절차를 거치고 다시 학습 데이터에 추가한다. 이때 예측에 실패한 이미지가 있을 경우에는 기존 라

벨 데이터를 유지한다. 이 과정은 모델이 더욱 다양하고 복잡한 데이터 패턴을 학습할 수 있게 함으로써 라벨 수를 증가시키는 데 기여한다. 각 병해 클래스 별 최소 바운딩 박스 기준은 <표 3>에 제시되어 있다.

이러한 재귀적 학습 방식은 특히 데이터가 제한적이거나 라벨링 비용이 높은 경우에 유용하다. YOLOv8 모델을 이용한 이 접근법은 소수의 라벨링된 이미지로부터 시작하여, 점진적으로 학습 데이터셋을 확장해 나가는 전략을 가진다. 이 과정에서 모델은 더 많은 앞 이미지 데이터를 학습하게 되며, 이는 특히 클래스 불균형이 있는 상황에서 데이터를 늘려 모델의 성능을 향상시키는 데 도움을 준다. <그림 4>의 연구 프레임워크를 보면 재귀적 학습 방식이 진행됨에 따라서 더 많은 이미지의 라벨을 확보하는 것을 알 수 있다. 이러한 재귀적 학습 방식의 도입은 딥러닝 모델의 학습 과정에 있어서 새로운 접근법을 제시한다.

본 연구에서는 토마토 앞 추출의 정확도를 극대화하기 위해 IoU(Intersection over Union) 임계값을 0.9로 설정했다. 높은 임계값은 모델이



<그림 4> 연구 프레임워크

〈표 4〉 YOLOv8 모델 하이퍼파라미터 설정

하이퍼 파라미터	설정값
IoU 임계값	0.9
학습 에포크 수(epochs)	300
조기 종료 설정값(patience)	30
배치 크기(batch size)	64
초기 학습률(lr0)	1e-4
최종 학습률 감소 비율(lrf)	1e-2
최적화 알고리즘(Optimizer)	AdamW

실제 잎의 영역과 가장 잘 겹치는 예측만을 선택하고, 이를 통해 더 정밀한 학습을 진행하도록 한다. <표 4>는 YOLOv8 모델 설정의 중요 옵션들을 보여준다.

3.2.2 EfficientNet-B0을 이용한 토마토 병해 분류 재귀적 학습 방식을 적용하여 나온 이미지가 효과가 있는지 보기 위해 EfficientNet-B0 아키텍처를 사용하여 토마토 잎의 다양한 병해를 분류하는 실험을 수행하였다. 대상 병해는 정상, 흰가루병, 잿빛곰팡이병, 황화잎말이바이러스병, 잎곰팡이병, 잎마름역병으로 총 6개의 클래스로 구성되었다.

<표 5>와 같이 그리드 서치(Grid Search)를 통해 Validation Loss가 가장 낮았던 에포크를 선택하여 각각의 실험 설정에서 우수한 조합을 선택하였다. 모델 초기화 과정에서는 EfficientNet-B0을 사전 학습된 가중치를 이용하여, 분류 대상 병해의 수에 맞게 최종 출력 계층을 조정하였다. 학습 과정은 100 에포크 동안 진행되었으며, 조기 종료 옵션으로 patience를 30으로 설정하였다.

손실 함수로는 클래스 불균형 문제를 고려한 Focal Loss를 사용하였다. Focal Loss는 특히 잘못 분류된 예시나 소수 클래스에 속하는 예시에 대한 손실을 증가시키도록 설계된 손실 함수로, 이는 일반적인 크로스 엔트로피 손실 함수에 비해 훨씬 더 효과적이다. 본 연구에서는 실험을 통해 잘 알려진 Focal Loss의 하이퍼파라미터로

〈표 5〉 EfficientNet-B0 모델 그리드 서치 하이퍼파라미터 설정

하이퍼 파라미터	설정값
배치 크기(batch size)	32, 64, 128
학습률(lr)	1e-3, 1e-4, 1e-5
최적화 알고리즘(Optimizer)	Adam, AdamW

alpha=0.25, gamma=2.0을 설정하였다[24].

3.3 학습 환경

본 연구의 학습 환경 구성은 <표 6>에 기술되어 있다. Ubuntu 20.04 서버 운영 체제를 기반으로 진행되었으며, CPU와 GPU는 각각 Intel i9-13900K와 NVIDIA GeForce RTX 4090이다. 서버 컴퓨터의 메모리는 총 128GB로, 32GB RAM 4개로 구성되어 있다.

서버에 구축된 도커 이미지(Docker Image)는 ‘nvidia/cuda:11.8.0-cudnn8-devel-ubuntu20.04’로, CUDA 및 cuDNN 라이브러리를 포함하여 고성능 계산을 지원한다. 계산 환경을 위해 Python 3.11 및 필수 Python 패키지들이 설치되었으며, 그 중 주요 패키지로는 PyTorch 기반의 ‘EfficientNet_PyTorch’와 ‘Ultralytics’가 포함되어 있다.

〈표 6〉 학습 환경

항목	설명
OS	Ubuntu Server 20.04.6 LTS
CPU	Intel i9-13900K
GPU	NVIDIA GeForce RTX 4090
RAM	32GB x 4
Docker Image	nvidia/cuda:11.8.0-cudnn8-devel-ubuntu20.04
Python	3.11.6
CUDA	11.8
cuDNN	8.9.6
Torch	2.1.1

IV. 연구 결과

EfficientNet-B0 모델을 사용하여 다양한 설정에서 이미지의 테스트 정확도 및 클래스별 정확도를 평가하였다. <표 7>을 보면, 기본 설정인 ‘Base’의 경우 원본 이미지에서 97.66%의 정확도를 보였으며, 잎만 추출한 테스트 이미지에서는 정확도가 93.63%로 나타났다. ‘Base + Leaf Crop’은 바운딩 박스로 잎 이미지만 추출한 데이터로 학습을 진행한 것으로 원본이미지에 대한 정확도는 감소하였지만 잎 추출 이미지에 대한 정확도는 증가하여 객체 탐지 알고리즘을 이용하여 이미지를 개체별로 잘라내어 학습하는 것만으로도 성능의 향상이 이루어지는 것을 확인할 수 있었다. 특히, ‘YOLOv8 R3(Recursive Learning 3회) + Leaf Crop(잎 추출)’ 설정은 두 이미지 유형 모두에서 가장 높은 정확도를 달성했다. 이는 재귀적 학습 방법론이 예측 모델의 성능 향상에 중요한 기여를 한 것으로 해석된다. 하지만 ‘YOLOv8 R4 + Leaf Crop’ 설정 이후로는 성능이 저하되는 경향을 보였는데, 이는 재

<표 7> 모델 테스트 정확도

실험 설정	원본 이미지 (EfficientNet)	잎 추출 이미지 (EfficientNet)
	Accuracy	Accuracy
Base	97.66%	93.63%
Base + Leaf Crop	97.59%	98.60%
YOLOv8 R1 + Leaf Crop	97.12%	97.78%
YOLOv8 R2 + Leaf Crop	97.94%	98.88%
YOLOv8 R3 + Leaf Crop	97.94%	98.92%
YOLOv8 R4 + Leaf Crop	97.38%	98.45%
YOLOv8 R5 + Leaf Crop	97.08%	98.67%
YOLOv8 R6 + Leaf Crop	86.02%	98.08%

<표 8> 잎 추출 이미지에 대한 클래스별 모델 테스트 정확도

병해	Base	Base +Leaf Crop	YOLOv8 R1 +Leaf Crop	YOLOv8 R2 +Leaf Crop	YOLOv8 R3 +Leaf Crop
정상	97.11%	99.80%	99.55%	99.76%	99.76%
흰가루병	95.58%	97.01%	96.19%	97.35%	97.76%
잿빛곰팡이병	84.63%	98.25%	95.63%	99.04%	98.69%
황화잎말이 바이러스병	98.54%	99.27%	100.00%	99.27%	99.27%
잎곰팡이병	95.41%	99.08%	99.08%	97.25%	99.08%
잎마름역병	29.03%	87.10%	96.77%	100.00%	93.55%

귀적 학습 방식의 횟수가 증가함에 따라 이미지 삭제 기준의 미세 조정이 필요함을 시사한다.

<표 8>에서는 잎 추출 이미지에 대한 클래스별 성능 분석을 한 결과를 볼 수 있다. 원본 이미지를 학습한 ‘Base’ 설정이 잿빛 곰팡이병과 잎마름역병에 대해 상대적으로 크게 낮은 성능을 보였고, 다른 클래스 또한 다른 방법과 비교했을 때 낮은 성능을 보였다. 이는 잎 추출 이미지로 학습하여 잎 추출 이미지에 대해 예측을 했을 때 성능이 더 좋음을 보여준다. 전반적으로 재귀적 학습 방법론을 적용했을 때 상대적으로 클래스가 적은 병해에서 성능이 향상되었다. 이는 특정 병해의 탐지에 재귀적 학습 방법론이 특히 효과적임을 시사한다.

V. 결론

이 연구는 토마토 잎 병해의 분류를 위한 새로운 접근법을 제안하였다. YOLOv8을 기반으로 한 재귀적 학습 방식과 EfficientNet-B0의 결합은, 특히 ‘YOLOv8 R3 + Leaf Crop’ 설정에서 높은 정확도를 달성하며 그 가능성을 입증하였다. 이 방법론은 클래스 불균형 문제에서 부족한 데이터를 효과적으로 확보하여 제한된 라벨 데이터로도 성능 개선이 가능함을 보여준다. 또

한, 원본 이미지에서 잎 추출 처리를 통해 관련 없는 배경 정보를 최소화함으로써 더 정확한 예측을 도모하였다.

이 연구의 한계점으로는 데이터셋 구축 시 이미지 삭제 처리 과정이 개선될 필요가 있다. 현재는 Base 데이터셋의 클래스별 최소 바운딩 박스 크기 기준으로 이미지를 삭제했지만, 보다 세밀한 이미지 처리를 통해 데이터의 질을 더욱 향상시킬 필요가 있다. 재귀적 학습 방식을 거친 이미지를 개별적으로 검수하여 분류한다면 더욱 정밀한 데이터셋 구축이 가능할 것으로 보인다.

실제 농업 현장에서의 응용 가능성에 대해서는 이 연구의 방법론이 실시간 모니터링을 위한 IoT 기기와의 통합 등 현장 적용 측면에서 확장될 수 있는 잠재력을 가지고 있다. 특히, 재귀적 학습 방식과 효율적인 병해 분류 모델은 시간적, 경제적 비용을 절감하고, 정확도를 높여 지속 가능한 농업을 위한 기술로써 큰 기여를 할 수 있을 것이다.

향후 연구 방향으로는 본 연구의 방법론을 다른 작물 부위나 다양한 작물 종에 적용하여 그 범용성과 효과를 검증하는 것이다. 이를 통해 본 연구의 방법론이 다양한 농업적 문제 상황에 유용하게 적용될 수 있음을 확인할 필요가 있다.

결론적으로, 본 연구는 농업 분야에서 딥러닝 기술의 효과적인 적용 가능성을 보여주고, 농업 분야뿐만 아니라 다른 영역에서의 응용 가능성을 열어 줄 것으로 기대된다.

참 고 문 헌

- [1] G. Idoje, T. Dagiuklas, and M. Iqbal, "Survey for smart farming technologies: Challenges and issues," *Computers & Electrical Engineering*, 2021.
- [2] Y. Guo et al., "Plant Disease Identification Based on Deep Learning Algorithm in Smart Farming," *Discrete Dynamics in Nature and Society*, 2020.
- [3] David. P. Hughes and M. Salathe, "An open access repository of images on plant health to enable the development of mobile disease diagnostics," *arXiv*, 2015.
- [4] 한국정보화진흥원, "지능정보산업 인프라 조성사업 연차보고서," <https://scienceon.kisti.re.kr/srch/selectPORSrchReport.do?cn=TRKO201800039420&dbt=TRKO#>, 2017.
- [5] 한국지능정보사회진흥원, "농업 지식베이스," AI Hub, <https://www.aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=data&dataSetSn=150>, 2019.
- [6] 채종욱, 신영학, "딥러닝 기반 토마토 잎 병충해 분류 및 시각화를 위한 연구," *한국지능시스템학회 논문지*, 32(2), pp.145-150, 2022.
- [7] 나명환, 조완현, 김상균, "딥러닝 알고리즘을 이용한 토마토에서 발생하는 여러가지 병해충의 탐지와 식별에 대한 웹응용 플랫폼의 구축," *품질경영학회지*, 48(4), pp.581-596, 2020.
- [8] 함현식, 김동현, 채정우, 이신애, 김윤지, 조현욱, 조현중, "딥러닝 기반 토마토 병충해 분류 시스템 연구," *전기학회논문지*, 69(2), pp.349-355, 2020.
- [9] 한국지능정보사회진흥원, "노지 작물 질병 진단 이미지," AI Hub, <https://www.aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=data&dataSetSn=147.5>, 2021.
- [10] 한국지능정보사회진흥원, "시설 작물 질병 진단 이미지," AI Hub, <https://www.aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=data&dataSetSn=153>, 2021.
- [11] 한국지능정보사회진흥원, "식물 병 유발 통합

- 데이터,” AI Hub, <https://www.aihub.or.kr/ai-hubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=data&dataSetSn=525>, 2022.
- [12] R. King, “Visualization of YOLOv8 Architecture,” [Online]. Available: <https://github.com/ultralytics/ultralytics/issues/189>. [Accessed: May. 08, 2024].
- [13] I. Ahmed and P. K. Yadav, “A systematic analysis of machine learning and deep learning based approaches for identifying and diagnosing plant diseases,” *Sustainable Operations and Computers*, vol. 4, pp.96-104, 2023.
- [14] H. Ulutaş and V. Aslantas, “Design of Efficient Methods for the Detection of Tomato Leaf Disease Utilizing Proposed Ensemble CNN Model,” *Electronics*, vol. 12, no. 4, pp.827, 2023.
- [15] Y. He, G. Zhang, and Q. Gao, “A novel ensemble learning method for crop leaf disease recognition,” *Frontiers in Plant Science*, vol. 14, 2023.
- [16] J. H. Lim and O. Attallah, “Tomato Leaf Disease Classification via Compact Convolutional Neural Networks with Transfer Learning and Feature Selection,” *Horticulturae*, vol. 9, no. 2, pp.149, 2023.
- [17] S. Ahmed, M. B. Hasan, T. Ahmed, M. R. K. Sony, and M. H. Kabir, “Less is More: Lighter and Faster Deep Neural Architecture for Tomato Leaf Disease Classification,” *IEEE Access*, vol. 10, pp.68868-68884, 2022.
- [18] N. Ullah et al., “An effective approach for plant leaf diseases classification based on a novel DeepPlantNet deep learning model,” *Frontiers in Plant Science*, vol. 14, 2023.
- [19] A. Gangwar, G. Rani, V. P. S. Dhaka, and Sonam, “Detecting Tomato Crop Diseases with AI: Leaf Segmentation and Analysis,” 7th International Conference on Trends in Electronics and Informatics, pp.902-907, 2023.
- [20] A. Abbas, S. Jain, M. Gour, and S. Vankudothu, “Tomato plant disease detection using transfer learning with C-GAN synthetic images,” *Computers and Electronics in Agriculture*, vol. 187, 2021.
- [21] Ultralytics, “YOLOv8 documentation,” [Online]. Available: <https://docs.ultralytics.com/>. [Accessed: Mar. 14, 2024].
- [22] M. Tan and Q. v. Le, “EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks,” *International Conference on Machine Learning*, 2019.
- [23] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. C. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp.4510-4520, 2018.
- [24] T. Y. Lin, P. Goyal, R. Girshick, K. He, and P. Dollar, “Focal Loss for Dense Object Detection,” *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 42, no. 2, pp.318-327, 2020.

저자 소개



이 준 혁(Junhyuk Lee)

· 2023년 2월 : 가천대학교 응용통계학과 (경영학사) / 컴퓨터공학과 복수전공 (공학사)

· 2023년 3월~현재 : 가천대학교 응용통계학과 (석사과정)

<관심분야> 빅데이터 분석, 머신러닝, 컴퓨터 비전



김 남 형(Namhyoung Kim)

· 2008년 2월 : 포항공과대학교 산업경영공학과 (공학사)

· 2013년 2월 : 포항공과대학교 산업경영공학과 (공학박사)

· 2014년 3월~현재 : 가천대학교 응용통계학과 교수

<관심분야> 빅데이터 분석, 데이터 마이닝, 머신러닝