

# 딥러닝 모델과 OpenCV를 활용한 한라봉 병징 탐지 및 발병 분석

김민지<sup>1</sup>, 박세훈<sup>2</sup>, 신의식<sup>3</sup>, 류병석<sup>4</sup>, 권용현<sup>5</sup>, 김영균<sup>6</sup>

<sup>1</sup>강원대학교 농업생명과학대학 식물자원응용과학전공

<sup>2</sup>강원대학교 IT대학 전기전자공학과

<sup>3</sup>강원대학교 IT대학 전자공학과

<sup>4</sup>연세대학교 공과대학 화공생명공학과

<sup>5</sup>한양대학교 공과대학 데이터사이언스전공

<sup>6</sup>융합소프트웨어랩

applecate44@gmail.com, sehunb592@gmail.com, sic0026@naver.com, bsryu@yonsei.ac.kr,  
mrkyh380@hanyang.ac.kr, ygkim-2004@hanmail.net

## Hallabong Symptom Detection and Outbreak Analysis Using Deep Learning Model and OpenCV

Minji Kim<sup>1</sup>, Sehun Park<sup>2</sup>, Euisik Shin<sup>3</sup>, Byeongseok Ryu<sup>4</sup>, Yonghyun Kwon<sup>5</sup>,  
YoungGyun Kim<sup>6</sup>

<sup>1</sup>Dept. of Applied Plant Sciences, Kangwon National University

<sup>2</sup>Dept. of Electrical & Electronics Engineering, Kangwon National University

<sup>3</sup>Dept. of Electronics Engineering, Kangwon National University

<sup>4</sup>Dept. of Chemical & Biomolecular Engineering, Yonsei University

<sup>5</sup>Dept. of Data Science, Hanyang University

<sup>6</sup>Convergence Software Lab

### 요약

기후 변화로 한라봉 재배 환경이 달라지면서 병해 발생 빈도와 심각성이 증가하고 있다. 그러나 기존 병해 판별 방식은 주관적 오류가 발생하기 쉽고, 시간이 많이 소요되어 효율적인 관리가 어렵다. 따라서, 보다 빠르고 정확한 병해 진단 자동화 시스템의 필요성이 커지고 있다. 본 연구에서는 딥러닝 모델과 OpenCV를 활용하여 한라봉 잎과 과실의 병징을 자동 감지하고, 확산 정도를 정량적으로 평가함으로써 농업 종사자의 신속한 대응을 지원하고 농가의 생산성과 상품 품질 향상에 기여하고자 한다.

### 1. 서론

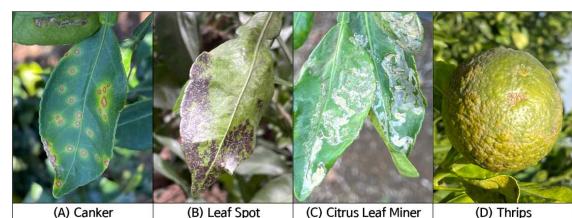
한라봉은 국내 과수 산업에서 중요한 경제적 가치를 가지며, 품질 유지를 위해 지속적인 관리가 필요하다 [1]. 그러나 기후 변화로 인해 재배지가 확대되면서 새로운 환경에서 병해충이 발생할 가능성이 높아지고 있으며, 이에 따라 신속하고 정확한 병징 판별의 중요성이 더욱 부각되고 있다[2].

한라봉 재배지에서는 주로 궤양병(Canker), 점무늬병(Leaf Spot), 굴굴나방(Citrus Leaf Miner), 총채벌레(Thrips) 등의 피해가 발생한다. 궤양병은 잎과 열매에 황색 반점이 생긴 후 코르크화되며, 강우 시 빠르게 전파된다(그림 1-A). 점무늬병은 갈색 반점이 확산되어 잎이 말라 죽고(그림 1-B), 굴굴나방은 잎을 깽도 형태로 파먹는다(그림 1-C). 총채벌레는 잎 세포를 파괴해 변색을 유발한다(그림 1-D)[3].

기존 육안 판별 방식은 숙련된 전문가가 필요하며, 주관적 오류로 일관성이 낮다[4]. 보완책으로써 실험실

분석이 활용되지만, 검사 비용과 시간이 많이 들며 대규모 농가는 실시간 대응이 어렵다. 이에 스마트팜 등 자동화 감지 시스템이 도입되며, 실제로 도입 농가는 미도입 농가보다 34~46% 높은 농업 소득 증가율을 보였다[5]. 특히, 데이터 효율성이 높은 딥러닝 모델을 활용하면 높은 정확도의 실시간 병징 판별이 가능해 실용성이 입증되고 있다[6][7].

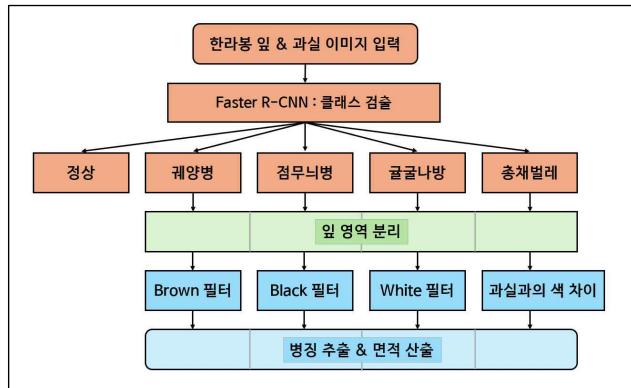
본 연구에서는 Faster R-CNN과 OpenCV를 활용하여 한라봉 잎과 과실의 색상 및 면적을 분석하고, 병징을 자동 감지함으로써 농가의 생산성과 상품 품질 관리 효율성 향상에 기여하고자 한다.



(그림 1) 병징별 시각적 특징

## 2. 한라봉 병징 탐지 분석 방법

본 연구에서는 딥러닝 기반의 한라봉 병징 탐지를 위해 Faster R-CNN을 적용하였으며, 모델 학습과 성능 평가를 위해 PyTorch 환경에서 수행하였다. Faster R-CNN은 객체 탐지(Object Detection)에서 높은 정확도를 제공하며, 작은 병징도 효과적으로 검출할 수 있는 강점이 있어 본 연구에 적합하다.



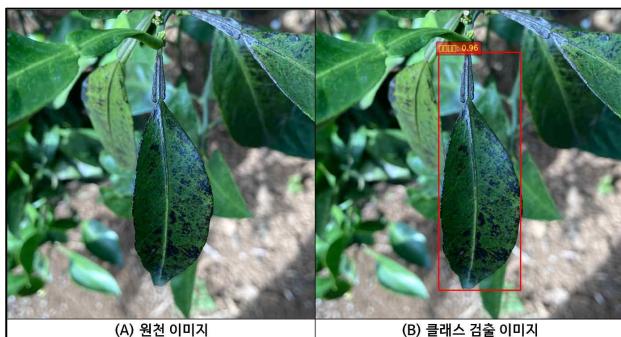
(그림 2) 시스템 흐름도

### 2.1. 데이터 수집

원천 데이터로는 한국지능정보사회진흥원(NIA) AI 허브의 ‘국내 재배 아열대/열대 병해충 데이터’를 활용하였다[8]. 한라봉 잎과 과실 이미지 총 4,320장을 훈련용 80%(3,456장), 검증용 10%(432장), 테스트용 10%(432장)로 분할하여 사용하였다. 또한, 각 이미지에는 수동으로 바운딩 박스를 라벨링하여 데이터셋을 구축하였다.

### 2.2. 딥러닝 기반 한라봉 병징 검출 모델

Faster R-CNN은 Region Proposal Network(RPN)를 활용하여 객체가 존재할 가능성이 높은 영역을 예측한 후, 원본 이미지(그림 3-A)에서 객체를 검출하고 바운딩 박스 회귀를 수행하는 딥러닝 모델이다(그림 3-B)[9]. 본 연구에서는 정상 잎, 정상 과실, 궤양병, 점무늬병, 굴굴나방, 총채벌레 등 총 6개 클래스를 검출했다.



(그림 3) Faster R-CNN 모델의 객체 검출

모델 학습에는 일반화 성능이 우수한 SGD(Stochastic Gradient Descent) 옵티마이저를 사용했고, 학습 안정성을 높이기 위해 학습률 감소 스케줄러를 적용하였다[10][11]. 또한, 과적합을 방지하고 다양한 병징 유형을 효과적으로 탐지하기 위해 데이터 균형을 고려하여 학습을 진행하였다.

### 2.3. 이미지 처리 기반 병징 부위 분석

객체 검출 후, OpenCV 기반 이미지 처리 기법을 활용하여 잎 및 과실의 병징 영역을 찾아 그 면적을 정량적으로 분석한다.

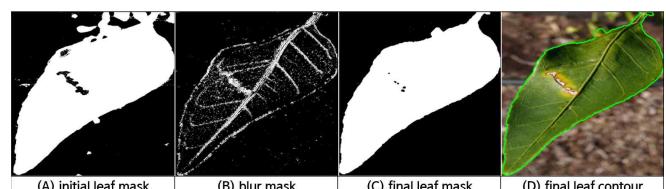
〈표 1〉 각 병징별 HSV 필터 값

		범위	
		min	max
Canker	색상		
	HSV	10°, 19.6%, 7.8%	60°, 100%, 100%
	HSV(OpenCV)	5, 50, 20	30, 255, 255
Leaf Spot	색상		
	HSV	160°, 0%, 0%	358°, 31.4%, 68.6%
	HSV(OpenCV)	80, 0, 0	179, 80, 175
	색상		
	HSV	0°, 0%, 0%	86°, 31.4%, 62.7%
Citrus Leaf Miner	HSV(OpenCV)	0, 0, 0	43, 80, 160
	색상		
	HSV	0°, 0%, 70.6%	360°, 31.4%, 100%
	HSV(OpenCV)	0, 0, 180	180, 80, 255

#### 2.3.1. 공통 처리 과정 및 궤양병(Canker)

입력 이미지를 HSV 색 공간으로 변환한 후, 최소 [20, 20, 20], 최대 [100, 255, 255] 범위로 필터링하여 녹색 계열을 기반으로 생성된 이진 마스크(HSV 마스크)를 활용해 잎을 추출하였다. HSV 색 공간은 색상과 밝기를 개별적으로 조절할 수 있어 특정 색상과 배경을 효과적으로 구분하는 데 적합하다.

그러나 일부 배경이 잎으로 오검출되는 문제를 보완하기 위해 Blur 기반 배경 억제 마스크를 적용하여 불필요한 배경을 제거하였다. 이후, HSV 마스크와 블러 마스크(그림 4-B)를 결합해 최종 마스크(그림 4-C)를 생성한 뒤, GrabCut 알고리즘을 적용한다. 이를 통해 배경을 제거하고, 최대 면적의 윤곽선만 유지하여 노이즈를 최소화하면서 잎 영역을 분리했다(그림 4-D). 마지막으로, 〈표 1〉의 Canker HSV 필터를 적용하여 병징 부위를 탐지한다.



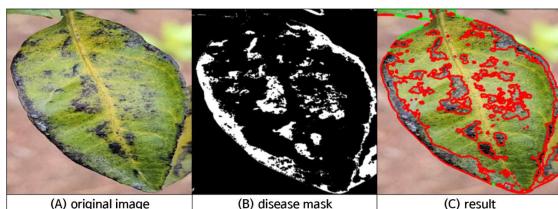
(그림 4) HSV 및 Blur 마스크

### 2.3.2. 점무늬병(Leaf Spot) & 굴굴나방(Citrus Leaf Miner)

점무늬병과 굴굴나방의 잎 영역 분리는 궤양병과 동일한 방식으로 수행된다. 그러나 병징 탐지 과정에서 점무늬병은 채도(S)와 명도(V)에 따라 검은색부터 회색까지 다양한 색으로 나타나므로, 단일 필터만으로는 일부 병징을 검출하기 어렵다. 이를 보완하기 위해 두 개의 필터를 적용하고〈표 1-Leaf Spot〉, 잎이 병징으로 오검출되는 문제를 방지하기 위해 녹색 계열(H 44-79)은 제외하였다. 〈표 1〉의 필터별 HSV(색상(Hue), 채도(Saturation), 명도(Value)) 범위는 병징별 샘플 이미지 20장을 분석하여 도출한 최소-최대 값을 기반으로 설정하였다.

또한, 병징 일부가 잎 윤곽선과 겹치는 경우(그림 5-A), 해당 부분이 잎 내부에 포함되도록 좌표를 보정하는 과정을 수행하였다(그림 5-B). 이 과정은 점무늬병과 굴굴나방에만 적용되었으며, 이는 두 병해가 넓게 분포하는 특성을 반영한 것이다.

병징이 탐지되면 윤곽선을 검출한 후(그림 5-C), 전체 잎 픽셀 수 대비 병징 면적 픽셀 수의 비율(%)을 계산한다.



(그림 5) 병징 분석 과정

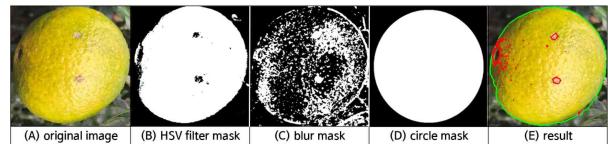
### 2.3.3. 총채벌레(Thrips)

검출된 객체 이미지를 HSV 색 공간으로 변환한 후, 원형 마스크를 생성하여 과실 영역을 탐지한다. 과실의 평균 H 값이 10-29이면 노란색(Yellow)으로 분류하고, 색상 필터 기반으로 차례로 HSV와 Blur, 원형 마스크의 비율을 8:1:1로 설정하여(그림 6-B, C, D) 과실 영역을 분리하였다(그림 6-E). H 값이 30-35이면 연두색(Yellowish Green), 36 이상이면 녹색(Green)으로 분류한다. 그러나 이 경우 배경 잎과 과실 색이 유사하여 명확한 구분이 어려울 수 있으므로, HSV 마스크의 비중을 줄이고 Blur 마스크의 비중을 높여 2:6:2의 비율로 설정하였다(그림 7-B, C, D).

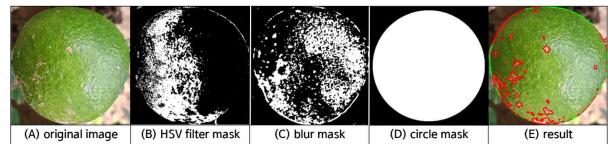
이후, 과실 내부 평균 H 값을 기준으로 색 차이를 계산한 뒤, 특정 임계값을 초과하는 영역을 병징 발생 가능성이 높은 영역으로 판단하고 필터링을 수행하였다. 총채벌레 피해 과실 테스트셋 20장을 대상으로 실험한 결과, 색 차이 값이 3 이상일 때 병징을 효과적으로 구별할 수 있음을 확인하였다.

분석 결과, 색 차이 값이 3 미만일 경우 병징이 아닌 부분까지 오탐지되는 경우가 많았으며, 반대로 값이

너무 크면 병징의 초기 변화를 감지하는 데 한계가 있었다. 이에 따라, 실험 데이터를 기반으로 색 차이 3 을 최적 임계값으로 설정하였다. 다만, 과실이 숙성되면서 표면 색이 녹색에서 노란색으로 점진적으로 변하는 과정에서 일부 노란색 영역이 병징으로 오탐지될 가능성이 있다. 이를 방지하기 위해 이미지 내 윤곽 감지에 활용되는 Sobel 필터를 적용하여 색상의 점진적 변화는 배제하고, 기울기 변화가 큰 부분만 병징으로 인식하였다.



(그림 6) 노란색 과실의 윤곽 처리 과정



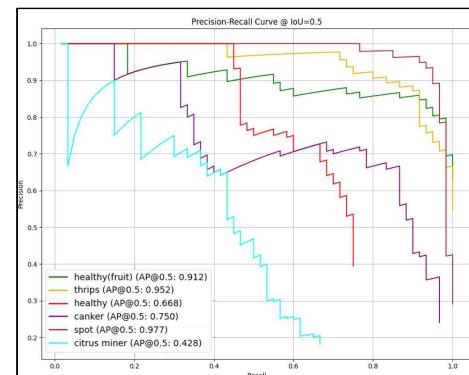
(그림 7) 연두색-녹색 과실의 윤곽 처리 과정

## 3. 연구 결과

### 3.1. 병징 검출 모델 성능 평가

mAP(mean Average Precision)는 객체 탐지 모델의 성능을 정량적으로 평가하는 지표로, Precision과 Recall의 관계를 반영하여 계산된다. 본 모델에서는 IoU=0.50 기준 각 클래스별 AP(Average Precision)을 구한 뒤, 이를 평균하여 전체 성능을 평가했다. 또한, Precision-Recall(PR) 곡선을 시각화하여 각 클래스의 성능 분포를 분석하였다(그림 8). IoU=0.50은 딥러닝 기반 객체 탐지 모델의 성능 평가에 널리 사용되는 학계 표준으로, 다양한 연구 간 결과의 비교 가능성을 높이는 데 유리하다[12].

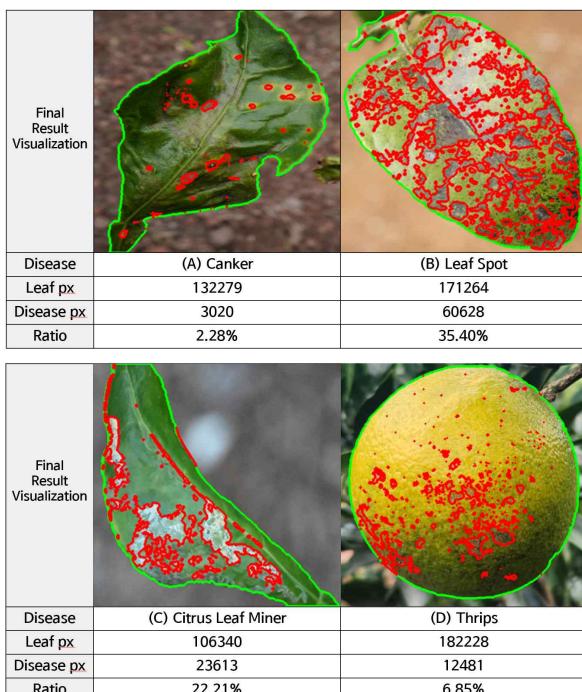
재학습된 Faster R-CNN 모델의 전체 mAP는 0.7812로 나타났다. 클래스별 mAP는 0.4278-0.9771 범위로 분포하며, 일부 병해에서는 낮은 성능을 보였지만, 대다수 병해에서 높은 정확도를 기록하였다.



(그림 8) Faster R-CNN 모델의 Precision-Recall Curve

### 3.2. 병징 부위 분석 결과

그림 9는 테스트셋에서 무작위로 선정한 각 병징별 이미지의 분석 결과를 시각적으로 나타낸 자료이다. 그림 9-A부터 D까지는 각각 궤양병, 점무늬병, 굴굴나방, 총채벌레 피해를 나타내며, 검출된 잎 영역은 녹색, 병징 영역은 붉은색 윤곽선으로 구분되었다. Faster R-CNN 모델을 활용하여 각 이미지 내 잎/과실 영역과 병징 영역의 픽셀 수를 직접 측정하고, 이를 바탕으로 병징 면적 비율(%)을 비교 분석하였다. 특히, 점무늬병과 굴굴나방 피해처럼 병징이 넓게 확산된 경우 높은 면적 비율이 나타났으며, 이는 계산 결과가 각 병해 유형의 특성을 명확하게 반영하고 있음을 시사한다. 또한, 그림 9의 시각적 결과는 산출된 픽셀 수의 신뢰성을 보완하는 근거로 활용될 수 있다.



(그림 9) 각 병징 분석 결과

### 4. 결론

본 연구에서는 Faster R-CNN과 OpenCV를 활용해 한라봉 잎과 과실의 병징을 자동 감지하고, 병징 면적을 정량적으로 분석하는 시스템을 구현하였다. 연구 결과, 모델의 전체 mAP는 0.7812로 나타났으며, 전반적으로 안정적인 병징 검출이 이루어졌다. 또한, OpenCV 기반 분석을 통해 검출된 픽셀 수를 바탕으로 병징 면적 비율을 정확하게 산출할 수 있음을 확인하였다. 이를 통해 본 시스템이 실시간 작물 관리에 효과적으로 활용될 수 있음을 검증하였다. 다만, 병징 초기 단계에서는 검출 성능이 다소 저하되는 경향을 보여 추가적인 데이터 확보와 세분화된 학습이 필요할

것으로 판단된다. 향후 연구에서는 다양한 작물에 적용할 수 있는 범용 모델을 개발하여, 병징 데이터셋을 확장하여 모델의 성능과 일반화를 더욱 향상시키는 데 중점을 둘 계획이다.

### 참고문헌

- [1] 김태련, 김화년, 김배성, “한·미 FTA가 한라봉 시장에 미치는 경제적 파급영향 분석”, Journal of the Korea Academia-Industrial cooperation Society, Vol. 21, No. 1, pp. 725–731, 2020.
- [2] 박혜은, 이종태, “기후변화에 따른 과수작물 재배지 변화 예측 연구: 한라봉을 중심으로”, 한국정보시스템학회, 2024, pp. 31-44.
- [3] 농촌진흥청, “작목별병해충”, 농사로 : 농촌진흥청 농업기술포털, Jan. 2025. [Online]. Available: <https://www.nongsaro.go.kr/portal/portalMain.ps?menuId=PS00001>
- [4] 김대용, 조병관, “Vis/NIR 분광 기법으로 정상 및 병징 씨감자의 판별에 관한 연구”, 한국농업기계학회, 2011, pp. 325.
- [5] 이지민, 김태곤, “농산물 재배 방식에 따른 사회, 경제, 환경 영향 비교 – 농산물 소득조사 자료와 스마트팜 실태조사 보고서를 기반으로”, 농촌계획, Vol. 29, No. 4, 2023, pp. 127–135.
- [6] 성선경, 최재완, “훈련자료 내 재배지역의 비율에 따른 딥러닝 모델의 성능 평가”, 대한원격탐사학회, 2022, pp. 1007–1014.
- [7] 김재현, 김대성, 이명훈, “딥러닝 기반 토마토 성숙도 판별 시스템”, 한국지식정보기술학회, Vol. 18, No. 5, 2023, pp. 1345–1353.
- [8] 한국지능정보사회진흥원(NIA), “국내 재배 아열대·열대 병해충 데이터”, AI Hub, Jan. 2025. [Online]. Available: <https://www.aihub.or.kr/>
- [9] Shaoqing Ren, Kaiming He, Girshick, Ross, Jian Sun, “Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks,” IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 39, No. 6, 2017, pp. 1137–1149.
- [10] Dai, Hulin; Peng, Xuan; Shi, Xuanhua; He, Ligang; Xiong, Qian; Jin, Hai, “Reveal training performance mystery between TensorFlow and PyTorch in the single GPU environment”, Science China. Information Sciences, Vol. 65, No. 1, 2022, pp. 112103.
- [11] 박성욱, 김도연, “가중치 초기화 및 매개변수 갱신 방법에 따른 컨벌루션 신경망의 성능 비교”, 멀티미디어학회, Vol. 21, No. 4, 2018, pp. 441–449.
- [12] Everingham, M., Van Gool, L., Williams, C. K., Winn, J., & Zisserman, A. “The pascal visual object classes (voc) challenge”, International journal of computer vision, 88, 2010, pp. 303–338.