

# 병해충 분류를 위한 DANet-CAM

웬트리찬 흥<sup>1</sup>, 김영언<sup>1</sup>, 이효종<sup>2\*</sup>

<sup>1</sup> 전북대학교 에너지-AI 융학공학과

<sup>2</sup> 전북대학교 컴퓨터공학과

Ntchung3397@jbnu.ac.kr, thdcnr@naver.com, hlee@jbnu.ac.kr

\*Corresponding author

## DANet-CAM for Pest & Disease Classification

Nguyen Tri Chan Hung<sup>1</sup>, Young Un Kim<sup>1</sup>, Hyo Jong Lee<sup>2</sup>

<sup>1</sup>Graduate School of Integrated Energy-AI, Jeonbuk National University, Jeonju, Korea,

<sup>2</sup>Dept. of Computer Science and Engineering, Jeonbuk National University

### Abstract

작물을 경작 해충과 질병은 오랫동안 주요 관심사였다. 농업에서 병해충을 탐지하기 위해 전통적인 방법을 사용하는 것은 더 이상 높은 효율성을 제공하지 않는다. 오늘날 과학과 인공 지능의 폭발적인 발달로 인해 농업분야의 연구원들은 병해충을 탐지하기 위해 딥 러닝을 적용하고 있다. 최근에 다양한 분야의 문제들을 해결하기 위해 수많은 모델들이 발표되었지만, 많은 병해충 진단 딥러닝을 사용한 방법들은 하드웨어 리소스를 낭비하고 실제 농장에서 사용하기 어렵다. 따라서 본 논문에서는 작물의 병해충을 분류하기 위해 Select Kernel Attention(SK Attention)을 Channel Attention Module 로 변경하여 Decoupling-and-Attention network (DANet)을 하드웨어 리소스 사용을 최소화한다.

고 DANet-CAM 을 사전 처리하여 더 가볍고 빠른 최소한의 하드웨어 리소스를 사용하는 방법을 제시한다.

### 1. 서론

다양한 질병과 해충이 작물에 위협을 초래한다. 다양한 종류의 해충 및 질병의 대규모 발생으로 인해 농부들은 상당한 재정적 손실을 입을 수 있다. 해충에 의한 작물의 작은 손상이나, 과일이나 작물에 박테리아와 같은 세균성 질병으로 약간의 손상조차도 농업 생산물의 시장 가치를 극적으로 낮출 수 있다. 작물 생산의 품질을 개선하는 것은 재배 작물의 해충 및 질병 관리에 달려 있다. 과거에는 질병과 해충의 발생을 수동으로 관찰하고 찾아냈다. 농부들은 분류 연구를 위해 전문가에게 보내기 전에 해충과 질병의 샘플을 수집해야 했다. 이 방법은 엄청나게 비효율적이다. 게다가 이 방법 많은 노력과 시간을 필요로 한다. 그렇기 때문에, 많은 연구자들이 해충과 질병을 식별하기 위해 머신 러닝과 딥 러닝을 적용하기 시작했다. Domingues et al.에 따르면, Random Forest 와 다양한 유형의 SVM 기반 분류 및 회귀 알고리즘이 농업 컨텍스트에 적용된다.[3] Türkoğlu et al.은 8 가지 다른 유형의 해충 및 질병 탐지를 위한 심층 특징 추출 및 전이 학습의 성능을 비교했다. 그들의 주장에 의하면, Resnet101 모델이 99.53%로 최고 성능에 도달했다.[4] 이미지 데이터셋은 많았지만 이미지 배경이 단순했고 좋은 점수를 얻기 위한 모델도 매우 무거운 단점이 존재한다. 우리는 이러한 문제점을 해결하기 위하여 해충과 질병을 분류하기 위해 데이터 증강을 사용하

### 2. 데이터셋

우리가 연구에 사용한 병해충 질병 데이터셋은 다양한 작물을 포함한다. 이 크롤링 데이터 세트에는 9 가지 다른 식물 종이 있으며, 각 종에는 고유한 해충, 질병 및 건강한 식물 종류가 있다. 아래의 테이블 1 을 참고하면 총 117 개 병해충이 있다.

plant	# healthy cls	# pest cls	# disease cls	num classes
감귤	2	11	6	19
감자	2	4	4	10
딸기	2	6	6	14
복숭아	2	6	6	14
사과	2	4	4	10
옥수수	2	5	5	12
토마토	2	3	9	14
포도	2	6	6	14
호박	2	4	4	10
합계				117

Table 1. Pest and diseases dataset

데이터를 더 다양하고 균형 있게 만드는 것은 딥 러닝 모델을 적용하는 다음 단계가 될 것이다. 원본 사진에서 더 많은 사진을 만들기 위해 우리는 일종의 보강을 적용했다.




Figure 1. Citrus plant with Augmentation

3. DANet-CAM

이 작업에서는 해충 및 질병 식물을 분류하는 데 사용된 모델 아키텍처를 소개한다. 이 모델에는 두 가지 주요 부분이 있다. 전체 구조는 여전히 DANet 네트워크로 유지하면서 모델을 배경 정보보다 객체 세부 사항에 더 초점을 맞추는 데 사용하는 채널 주의 모듈이다. [5]

A) Channel Attention Module

각각의 DANet 그룹에서 이전 컨볼루션의 모든 커널 레이어를 병합하여 기능 맵이 생성된다. 그런 다음 최대 풀링 및 평균 풀링 작업을 모두 사용하여 처음에 기능 맵의 공간 데이터를 결합한다. 공유 네트워크는 두 설명자를 모두 수신하고 채널 어텐션 맵을 생성한다. 공유 네트워크는 하나의 은닉층과 완전히 연결된 두 개의 계층으로 구성된다. 공유 네트워크가 각 디스크립터에 적용된 후 최종 피쳐 맵을 반환하기 위해 sigmoid를 거치기 전에 요소별을 사용하여 출력 피쳐를 병합한다.




Figure 2. Channel Attention Module

B) DANet-CAM

Decoupling-and-Attention network[5]는 식물의 해충과 질병을 예측하기 위해 Shuli Xing 이 만든 독창적모듈이다. 모델의 아키텍처는 SK Attention [1] 모듈을 사용하여 기능 맵에서 세부 정보를 학습하기 위해 각 커널 그룹의 필터 커널에 중점을 둔다. 그러나 이 접근 방식은 많은 유형의 질병이나 해충이 유사한 특징을 갖는 경우 위양성을 쉽게 유발할 수 있다. 이 아이디어에 의해 SK Attention 모듈을 Channel Attention [2] 모듈로 교체하여 새로운 아키텍처를 제안했다. 채널 Attention 모듈은 모든 커널의 정보를 합한 다음 그 하나를 기반으로 글로벌 기능 맵 기반을 만든다.

새로운 입력 기능 맵에서 모델은 출력 기능을 반환하기 전에 주의 채널을 통해 공간 정보를 학습한다. 이 접근 방식은 또한 이전 방법보다 매개변수 수를

줄일 수 있습니다. 최종 출력 기능을 제공하기 전에 각 커널에서 정보를 계산하려고 시도하지 않기 때문이다.

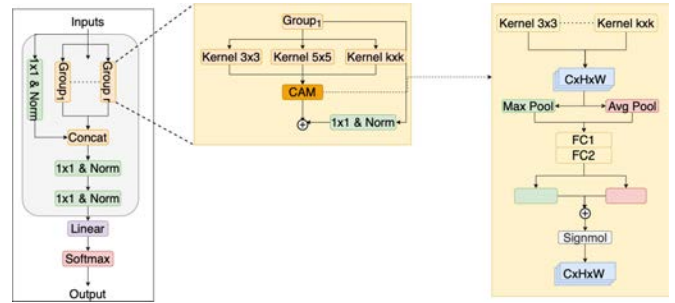


Figure 3. DANet-CAM Architecture

그림 3 에서 우리는 각 그룹 정보가 세부 기능을 반환하기 위해 CAM 모듈을 거치기 전에 많은 커널 계층을 포함하고 아키텍처의 다른 부분이 원래의 것과 동일하게 유지되는 것을 쉽게 볼 수 있다.

4. 결론

본 연구에서는 컴퓨터자원을 최소화하기 위하여 DANet 에서 SK attention 모듈을 Channel attention 모듈로 변경하는 것을 제안하였다. 변경 네트워크는 동일한 유사도로 병해충을 검출하면서 컴퓨터 자원의 사용은 감소하는 것을 보여주었다.

사사

본 성과물은 중소벤처기업부에서 지원하는 2022년도 지역중소기업 공동수요기술개발사업 (No. 3035805)의 연구수행으로 인한 결과물임을 밝힙니다.

참고문헌

[1] Li X, Wang W, Hu X, Yang J. Selective kernel networks. In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition p. 510-519, 2019.

[2] Lee H, Park J, Hwang JY. Channel attention module with multiscale grid average pooling for breast cancer segmentation in an ultrasound image. IEEE transactions on ultrasonics, ferroelectrics, and frequency control. 10;67(7), p. 1344-53, 2020.

[3] Domingues T, Brandão T, Ferreira JC. Machine Learning for Detection and Prediction of Crop Diseases and Pests: A Comprehensive Survey. Agriculture. 12(9) p. 1350, 2022.

[4] Türkoğlu M, Hanbay D. Plant disease and pest detection using deep learning-based features. Turkish Journal of Electrical Engineering and Computer Sciences. 27(3) p. 1636-51, 2019.

[5] Xing S, Lee HJ. Crop pests and diseases recognition using DANet with TLDP. Computers and Electronics in Agriculture. 1;199, p.107144, 2022.