

농작물 병해충 진단을 위한 인공지능 앱, Dr. Vegetable

김수환*, 정대기*, 이승준^o, 정성엽*, 양동제*, 정근영*, 황석형(교신저자)*, 황세웅*

*선문대학교 AI소프트웨어학과,

^o선문대학교 AI소프트웨어학과

e-mail: {kimsoohwan*, eor16598*, mamum5^o, jsysu2846*, rmsdud3271*, ydj9805*, sewoong*}@sunmoon.ac.kr
shwang@sunmoon.ac.kr(교신저자)*

Dr. Vegetable: an AI-based Mobile Application for Diagnosis of Plant Diseases and Insect Pests

SooHwan Kim*, DaeKy Jeong*, SeungJun Lee^o, SungYeob Jung*,

DongJae Yang*, Geunyeong Jeong*, Suk-Hyung Hwang(Corresponding Author)*, Sewoong Hwang*

*Department of Artificial Intelligence and Software Technology, Sun Moon University,

^oDepartment of Artificial Intelligence and Software Technology, Sun Moon University

● 요약 ●

본 연구는 시설작물의 병충해 진단을 위해 딥러닝 모델을 응용한 인공지능 서비스 앱, Dr. Vegetable을 제안하고자 한다. 농업 현장에서 숙련된 농부는 한눈에 농작물의 병충해를 판단할 수 있지만 미숙련된 농부는 병충해 피해를 발견하더라도 그 종류와 해결 방법을 찾아내기가 매우 어렵다. 또한 아무리 숙련된 농부라고 할지라도 육안검사만으로 병충해를 조기에 발견하는 것은 쉽지 않다. 한편 시설작물의 경우 병충해에 의한 연쇄피해가 발생할 우려가 있으므로 병충해의 조기 발견 및 방제가 매우 중요하다. 즉, 농부의 경험에 따른 농작물 병해충 진단은 정확성을 장담할 수 없으며 비용과 시간적인 측면에서 위험성이 높다고 할 수 있다. 본 논문에서는 YOLOv5를 활용하여 상추, 고추, 토마토 등 농작물의 병충해를 진단하는 인공지능 서비스를 제안한다. 특히 한국지능정보사회진흥원이 운영하고 있는 AI 통합 플랫폼인 AI 허브에서 제공하는 노지 작물 질병 및 해충 진단 이미지를 사용하여 딥러닝 모델을 학습하였다. 본 연구를 통해 개발된 모바일 어플리케이션을 이용하여 실제 시설농장에서 병충해 진단 서비스를 적용한 결과 약 86%의 정확도, F1 Score 0.84, 그리고 0.98의 mAP 값을 얻을 수 있었다. 본 연구에서 개발한 병충해 진단 딥러닝 모델을 다양한 조건에서 강인하게 동작하도록 개선한다면 농업 현장에서 널리 활용될 수 있을 것으로 기대한다.

키워드: 농작물 병충해(plant diseases and insect pests), 딥러닝 인공지능 모델(deep learning)

I. Introduction

최근 부족한 농촌의 인력을 대체하고 농업 생산성을 향상시키기 위하여 스마트 팜과 농업용 로봇 등 농업 분야에 인공지능을 활용하고자 하는 다양한 시도가 전 세계적으로 이루어지고 있다. 특히 대한민국은 고령화 사회를 넘어 초고령화 사회로 진입하면서 지난 10년간 농가 수와 농업 인구수가 지속적으로 하락하고 있기 때문에 빅데이터와 인공지능을 응용한 스마트농업에 대한 사회적 수요가 매우 높다.

특히 대한민국 농가의 주요형태인 시설재배지에서는 병충해에 의한 연쇄피해가 발생할 수 있기 때문에 농업생산성을 향상시키기 위해서는 농작물의 병해충을 조기에 진단하고 방제하는 것이 매우 중요하다.

한편 숙련된 농부라고 할지라도 육안검사만으로 초기 병충해를 진단하기는 매우 어렵기 때문에 본 논문에서는 YOLOv5 딥러닝 기반 인공지능 모델[1]을 활용하여 병충해 진단 서비스 Dr. Vegetable을 제안하고자 한다. 본 논문에서는 한국지능정보사회진흥원이 운영하고 있는 AI 통합 플랫폼인 AI 허브[2]에서 대한민국 노지에 특화된 농작물 질병 및 해충 진단 이미지를 활용하여 딥러닝 모델을 학습하여 병충해 인식 정확도를 높였다.

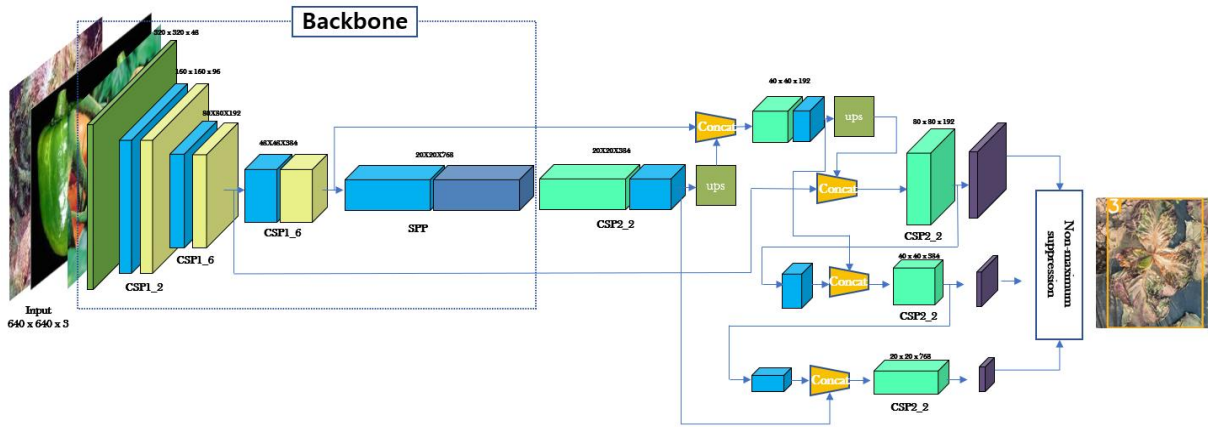


Fig. 1. YOLOv5 딥러닝 네트워크 모델 [1]

II. Preliminaries

1. Related works

1-1. Fast R-CNN

물체인식(object detection)에서 탁월한 성능을 발휘하는 R-CNN 모델[3]의 한계점을 개선한 모델로서 합성곱 신경망(Convolutional Neural Networks)의 특징 추출 및 분류, 바운딩 박스(bounding box) 회귀를 모두 하나의 모델에서 학습시키는 모델이다. Fast R-CNN 모델[4]의 핵심은 관심영역 추출(RoI pooling)로서 관심영역(Region of Interest)에 해당하는 부분만 최대값 추출(max-pooling)하여 특징맵(feature map)으로부터 고정된 길이의 저차원 벡터를 생성하는 것이다. 즉, 관심영역 추출 레이어(RoI pooling layer)를 사용하여 기존의 R-CNN과 SPPNet[5]에 비해 빠른 연산 속도와 정확도를 나타낸다. 하지만 영역 제안(region proposal) 연산이 느리다는 단점이 있다.

1-2. CSPNet

CSPNet 모델[6]은 합성곱 신경망(CNN)의 학습 능력을 향상시킬 수 있는 백본(backbone)으로서 DenseNet 모델[7]의 특징맵을 두 단계로 나누고, 두 단계를 결합(cross-stage hierarchy)하여 정확도를 유지 시키면서 추론을 위한 연산량을 줄여 네트워크 모델을 경량화하는 알고리즘이다.

1-3. YOLOv5

YOLO(You Only Look Once) 모델[8]은 실시간으로 물체인식을 수행하기 위해 만들어진 Darknet 프레임워크[9] 기반의 딥러닝 모델이다. 특히 한번에(one stage detection) 물체인식 예측(proposal)과 분류(classification)를 동시에 수행하는 것이 특징이다. YOLOv5 모델 [1]은 파이토치(PyTorch)로 개발되었으며 백본(backbone)은 이미지에서 특징맵(feature map)을 추출하는 부분으로 CSPnet 모델을 사용하기 때문에 실시간으로 동작하면서도 높은 성능과 낮은 용량의 장점을 가진다.

III. Methodology

1. 데이터 세트

모델 학습에 사용된 데이터 세트는 AI 허브를 통해 획득하였으며 시설재배지에서 재배하는 농작물들의 질병 환부와 정상 농작물이 포함된 데이터 세트이다. 특히 해당 작물의 병충해는 중증도를 정상, 초기, 중기, 말기의 4단계로 구성되어 있다. 모델 학습에 사용된 이미지는 4,032x3,024 크기의 3채널 컬러이미지로 총 120,000장의 이미지가 사용되었으며 그 중에서 정상 7,000장, 각 질병의 중증도 7,000장이 사용되었다.

2. 전처리

본 연구에서 인식하고자 하는 농작물의 병충해 종류는 총 다섯 가지(상추 2개, 토마토 2개, 고추 1개)이며 이를 중증도 별로 나누기 위해 정상을 포함하여 4개의 클래스(class)로 정의, 총 18개의 클래스로 분류하였다.

한편, 학습데이터를 구축하는 중에 본 연구에서 탐지하고자 하는 질병의 병환부가 아닌 이미지가 존재함을 확인하여서 본 연구의 취지에 맞게 질병의 중증도를 파악하는 모델을 학습시키기 위해 이를 아웃라이어(outlier)로 정의하여 정제하였다.

또한, 학습데이터의 각 클래스별 데이터 분포의 편차를 맞추기 위해 데이터 증강(회전, 색변경, 블러링 처리)을 통해 각 클래스별 분포를 맞추었다.

3. 모델 선택

물체인식을 위한 딥러닝 모델은 현재까지 가장 인식 속도가 빠르면서 정확도가 높다고 알려진 YOLO v5를 선택하였다. 특히 YOLO의 경우 이미지에서 물체 추론(inference)과 물체 영역 찾기(localization)가 한 번에 이루어지기 때문에 실시간으로 동작할 수 있는 YOLO 모델을 선정하였다.

YOLOv5는 그림 1과 같이 영상에서 특징점(feature)을 추출하는 백본(backbone), 추출된 특징을 융합하여 성능을 높이는 목부분(neck), 특징점을 바운딩 박스(bounding box)로 변환하는 머리부분

(head)과 같이 3부분으로 나누어져 있다. 백본과 헤드는 포커스 (focus) 모듈, 합성곱(conv) 모듈, C3 모듈, SPPF 모듈 등으로 이루어져 있다.

4. 모델 학습

각 이포크(epoch)마다 성능을 기록하고 비교 후 모델의 성능 향상을 위하여 하이퍼 파라미터 튜닝(hyper parameter tuning)을 진행하였다. 특히 컴퓨터 파워의 한계가 있었기 때문에 입력 영상의 크기를 640x640으로 줄여서 학습을 진행하였다.



Fig. 3. 농작물 병충해 인식 결과

IV. Evaluation

모델의 성능 평가에는 테스트 이미지 총 5,000장이 사용되었다. 정확도, F1 Score, mAP를 통해 모델의 성능을 평가하였다. Table 1은 성능 평가 결과를 나타낸 것이다. 성능 평가 결과 정확도 86.00%, F1 Score 0.84%, mAP 0.98의 성능을 보였다.

Table 1. 모델 성능 평가 결과

성능 지표	결과값
정확도	86.0%
F1 Score	0.84
mAP	0.98

그림 2는 학습된 인공지능 모델을 통해 상추, 토마토, 고추 등 농작물의 병충해를 중증도 4단계로 인식하고 있는 결과를 보여주고 있다. 실제 병해충에 걸린 농작물을 구하기가 힘들어서 이미지로 대체하여 진단하였다.

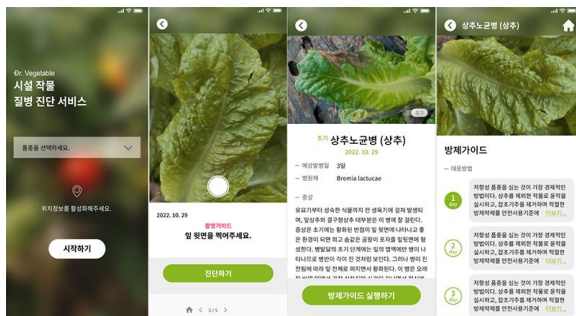


Fig. 2. 모바일 어플리케이션 Dr. Vegetable 실행 화면

그림 3은 스마트폰 카메라를 통해 시설작물을 촬영하고 촬영된 사진 또는 동영상을 통해 농작물의 병충해를 인식하고 방제 방법을 안내하는 모바일 어플리케이션 Dr. Vegetable의 실행 화면을 보여주고 있다. 모바일 어플리케이션의 형태로 개발되어 농부가 언제 어디서든 간편하게 농작물의 병충해를 초기에 진단할 수 있도록 설계되었다.

V. Conclusion

본 논문은 딥러닝 기반의 인공지능 모델을 통해 상추, 토마토, 고추 등 농작물의 병충해를 인식하는 모바일 어플리케이션 서비스 Dr. Vegetable을 제안하였다. 특히 한국지능정보사회진흥원이 운영하는 AI 허브를 통해 대한민국 노지 농작물의 병충해 데이터를 통해 인공지능 모델을 학습하였으며 모바일 어플리케이션의 형태로 개발하여 농부가 언제 어디서든 간편하게 농작물의 병충해를 진단하여 초기에 병충해를 방제하여 생산성을 높일 수 있도록 설계되었다. 실험 결과 86%의 정확도, 0.84 F1 Score, 그리고 0.98의 mAP를 얻을 수 있었다. 다양한 조도에서도 강인하게 동작할 수 있도록 모델을 개선한다면 실제 농가에서 널리 활용될 수 있을 것으로 기대한다.

REFERENCES

- [1] Glenn Jocher, YOLOv5, <https://github.com/ultralytics/yolov5>
- [2] NIA, AI Hub, <https://aihub.or.kr/>
- [3] Ross Girshick, Jeff Donahue, Trevor Darrell, and Jitendra Malik. "Rich Feature Hierarchies for Accurate Object Detection and Semantic Segmentation." In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 580-587. 2014.
- [4] Ross Girshick, "Fast R-CNN." In Proceedings of the IEEE International Conference on Computer Vision, pp. 1440-1448. 2015.
- [5] Kaiming He, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. "Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition." IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 37, no. 9, pp. 1904-1916, 2015.
- [6] Chien-Yao Wang, Hong-Yuan Mark Liao, Yueh-Hua Wu, Ping-Yang Chen, Jun-Wei Hsieh, and I-Hau Yeh.

- "CSPNet: A New Backbone that can Enhance Learning Capability of CNN." In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops, pp. 390-391. 2020.
- [7] Gao Huang, Zhuang Liu, Laurens Van Der Maaten, and Kilian Q. Weinberger. "Densely Connected Convolutional Networks." In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 4700-4708. 2017.
- [8] Joseph Redmon, Santosh Divvala, Ross Girshick, and Ali Farhadi. "You Only Look Once: Unified, Real-time Object Detection." In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 779-788. 2016.
- [9] Joseph Redmon, "Darknet: Open Source Neural Networks in C," <http://pjreddie.com/darknet/>