

VGG16을 활용한 미학습 농작물의 효율적인 질병 진단 모델

정석봉 · 윤협상[†]

An Efficient Disease Inspection Model for Untrained Crops Using VGG16

Seok Bong Jeong · Hyoup-Sang Yoon[†]

ABSTRACT

Early detection and classification of crop diseases play significant role to help farmers to reduce disease spread and to increase agricultural productivity. Recently, many researchers have used deep learning techniques like convolutional neural network (CNN) classifier for crop disease inspection with dataset of crop leaf images (e.g., PlantVillage dataset). These researches present over 90% of classification accuracy for crop diseases, but they have ability to detect only the pre-trained diseases. This paper proposes an efficient disease inspection CNN model for new crops not used in the pre-trained model. First, we present a benchmark crop disease classifier (CDC) for the crops in PlantVillage dataset using VGG16. Then we build a modified crop disease classifier (mCDC) to inspect diseases for untrained crops. The performance evaluation results show that the proposed model outperforms the benchmark classifier.

Key words : crop disease, convolutional neural network (CNN), VGG16

요약

농작물 질병에 대한 조기 진단은 질병의 확산을 억제하고 농업 생산성을 증대하는 데에 있어 중요한 역할을 하고 있다. 최근 합성곱신경망(convolutional neural network, CNN)과 같은 딥러닝 기법을 활용하여 농작물 잎사귀 이미지 데이터셋을 분석하여 농작물 질병을 진단하는 다수의 연구가 진행되었다. 이와 같은 연구를 통해 농작물 질병을 90% 이상의 정확도로 분류할 수 있지만, 사전 학습된 농작물 질병 외에는 진단할 수 없다는 한계를 갖는다. 본 연구에서는 미학습 농작물에 대해 효율적으로 질병 여부를 진단하는 모델을 제안한다. 이를 위해, 먼저 VGG16을 활용한 농작물 질병 분류기(CDC)를 구축하고 PlantVillage 데이터셋을 통해 학습하였다. 이어 미학습 농작물의 질병 진단이 가능하도록 수정된 질병 분류기(mCDC)의 구축방안을 제안하였다. 실험을 통해 본 연구에서 제안한 수정된 질병 분류기(mCDC)가 미학습 농작물의 질병 진단에 대해 기존 질병 분류기(CDC)보다 높은 성능을 보임을 확인하였다.

주요어 : 농작물 질병, 합성곱신경망, VGG16

1. 서론

농작물 상태를 감시하고 증상을 탐지하여 심각한 병충해를 예방하기 위한 농작물 질병 탐지는 병충해 확산을 막고 생산성을 높여 농가의 수익을 보호하는 중요한 역

할을 하고 있다(Khamparia 등, 2020). 농작물 질병 탐지에는 크게 1) 육안/현미경 검사, 2) 머신러닝, 3) 합성곱네트워크(convolutional neural network, CNN) 기반 딥러닝 기술을 활용하고 있다.

육안 검사 또는 현미경을 사용하는 방법은 과도한 비용과 시간이 소요되고 오류 발생 가능성이 높다는 한계로 인해 최근에는 이미지 기반 자동화 탐지 기술이 개발되고 있다(Sladojevic 등, 2016). 이러한 탐지 기술은 농작물 잎사귀 이미지에 SVM(support vector machine) 분류기, K-평균 군집분석 등 머신러닝이나 CNN 기반 딥러

Received: 3 August 2020, **Revised:** 15 September 2020,
Accepted: 16 September 2020

[†] **Corresponding Author:** Hyoup-Sang Yoon

E-mail: hsyoon@cu.ac.kr

Dept. of Software Convergence, Daegu Catholic University, Kyeongsbuk-do, Korea

닝 기술을 적용하여 조기에 정확한 질병 진단을 가능하게 하는 방향으로 발전하고 있다(Khamparia 등, 2020; Saleem 등, 2019; Rangarajan 등, 2018; Huang 등, 2018).

딥러닝 기술은 인공지능경망에서 발전된 분야이며 은닉층이 여러 개 적층되어 심층신경망이라고 불린다. 딥러닝 기술 중에서 이미지 처리 분야에 널리 사용되는 CNN은 손글씨 이미지 분류에 적용된 LeNET 구조(LeCun 등, 1998)로부터 점차 발전하여 2012년에 이르러 AlexNet (Krizhevsky 등, 2012)이 ILSVRC(ImageNet Large Scale Visual Recognition Challenge)에서 우승하면서 그 가치가 입증되었다. 이후 CNN은 이미지 분류 분야에 특화되어 ResNet(He 등, 2016)과 VGG 16(Simonyan and Zisserman, 2015) 등으로 발전하고 있으며 농작물 질병 분류 분야에도 활발히 적용되고 있다(Picon 등, 2018; Ferentinos, 2018).

농작물 분류에 CNN을 활용한 기존 연구는 일반적인 이미지 분류를 위해 학습된 CNN 구조를 확장하여 질병을 담고 있는 농작물 잎사귀 이미지를 학습하고, 농작물 질병 분류모델을 생성하여 정확도를 계산하거나 기존의 CNN 구조 중에서 가장 우수한 성능을 나타내는 것이 무엇인지 비교하는 방식으로 진행되고 있다.

Picon 등(2018)은 ResNet 구조를 이용하여 모바일 단말기로 촬영된 농작물의 질병 분류에 CNN을 적용하였고, Ferentinos(2018)는 58종의 농작물 질병을 담고 있는 데이터세트에 대하여 VGG 구조가 99.53%의 정확도로 가장 우수하다는 결과를 제시하고 있다.

기존 연구에서는 학습 데이터에 포함된 농작물의 특정 질병에 대한 분류에 CNN이 우수한 성능을 나타냄을 확인할 수 있지만, 학습 데이터에 포함되지 않은 신규 농작물의 질병 진단이나 기존 농작물의 신규 질병에 활용하기에는 적합하지 않다는 문제를 갖고 있다.

본 연구에서는 신규 농작물 및 신규 질병을 진단하는 분류기를 생성하기 위해 새로운 학습 데이터를 수집하지 않고 VGG16 CNN 구조를 활용하고자 한다. 이후 내용은 다음과 같다. 2장에서는 본 연구의 연구 방법 및 데이터세트에 대해 소개한다. 3장에서는 기존 농작물 질병 분류기 구축 방법과 그 성능을 살펴보고, 4장에서는 본 연구에서 제안하는 신규 농작물 질병 분류기의 구축과 성능에 대해 다룬다. 결론과 추후 연구는 5장에서 제시하고자 한다.

2. 연구 방법 및 데이터세트

2.1 연구 방법

본 연구는 크게 두 부분으로 구성된다. 첫 번째는 농작물 질병의 진단에 있어 사전 학습된 질병 분류기(crop disease classifier, CDC)가 미학습 신규 농작물의 질병 여부 진단에 어느 정도 성능을 보이는지 확인하는 것이다. 이어서 신규 농작물에 대한 분류 성능을 높이기 위해 수정된 CDC(modified CDC, mCDC)를 구축하는 방안을 제안하고 그 성능을 확인한다.

그동안 수많은 이미지 분류에서 CNN이 보여 준 뛰어난 성능으로 말미암아 CDC가 기존의 학습된 농작물의 질병은 잘 예측할 것으로 예상할 수 있다. 그러나 농작물의 경우 그 종류가 2,500여 종에 이르며 질병의 종류도 농작물별로 매우 다양하다. 더불어 기존에 발견하지 못했던 신규 질병이 발생하는 등 CDC가 모든 농작물 및 질병 데이터를 진단하는 것은 현실적으로 불가능하다고 할 수 있다.

한편, 학습에 포함된 분류 대상(class) 외에는 정확도가 높지 않은 딥러닝의 한계로, CDC가 미학습 신규 농작물에 대한 질병 여부의 진단은 그 성능을 기대하기 어렵다. 따라서 본 연구에서는 CDC가 미학습 농작물의 질병 여부 진단에서 보이는 성능을 평가하고 이 성능을 개선하는 방안을 제시하고자 한다.

2.2 데이터세트

본 연구에서는 공개적으로 이용 가능하며, 농작물 관련 연구에서도 널리 활용되고 있는 PlantVillage(<https://plantvillage.psu.edu>)의 농작물 잎사귀 이미지를 활용한다. 실질적인 데이터의 수집은 Kaggle을 통하여 이루어졌다(<https://www.kaggle.com>).

Kaggle에서 제공하는 PlantVillage 데이터세트는 데이터 증식(data augmentation)을 사용한 총 17,572개의 농작물 잎사귀 이미지로 구성되어 있으며, 총 14종의 농작물에 대해 38개의 질병 classes로 분류되어 있다(Table 1 참조). 데이터세트는 각 농작물에 대해 정상 이미지와 각 질병 종류별 이미지로 구성되어 있다. 예를 들어, 1번 농작물 사과(Apple)의 경우 정상(healthy class) 이미지와 3종의 질병(disease classes)에 대한 이미지들로 구성되어 있다. 참고로 농작물별 이미지의 수는 차이가 있으며, 각 class에 포함된 이미지의 수도 차이가 있다. 전체 데이터를 분할하여 학습 및 검증 데이터는 8:2의 비율로 구성하였다.

Table 1. The number of classes for each crop

No.	Crops	healthy class	disease classes	total
1	Apple	1	3	4
2	Blueberry	1	0	1
3	Cherry	1	1	2
4	Corn	1	3	4
5	Grape	1	3	4
6	Orange	0	1	1
7	Peach	1	1	2
8	Pepper	1	1	2
9	Potato	1	2	3
10	Raspberry	1	0	1
11	Soybean	1	0	1
12	Squash	0	1	1
13	Strawberry	1	1	2
14	Tomato	1	9	10
total		12	26	38

3. 학습된 분류기 및 성능 평가

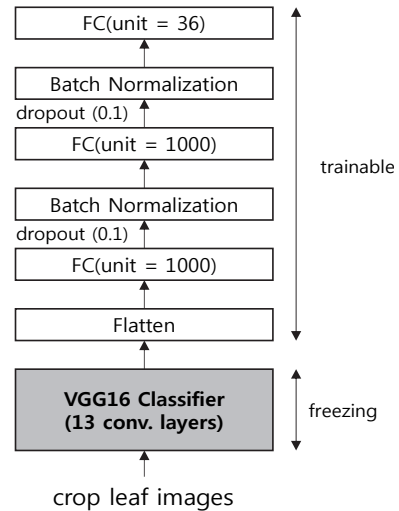
3.1 학습된 분류기(CDC) 구축

CDC가 미학습 신규 농작물의 질병 여부 진단에 어느 정도의 성능을 보이는지 확인하기 위하여 먼저 학습 및 검증 데이터 세트를 활용해 CDC를 구축하였다.

CDC를 신규로 구축하는 것은 많은 학습 데이터 및 컴퓨팅 자원이 요구되기 때문에 본 연구에서는 사전 학습된 분류기(pretrained classifier)인 VGG16(Simonyan and Zisserman, 2015)을 활용하였다. VGG16은 ImageNet 데이터세트에서 학습된 분류기로 13개의 convolutional (conv.) layer로 이루어진 구조를 갖는다. 이 모델은 2014년 ILSVRC-2014 대회에서 준우승(top-5)을 차지한 모델로써, 쉬운 구조와 좋은 성능 때문에 객체 인식 연구에 폭넓게 활용되고 있다(Chollet, 2017).

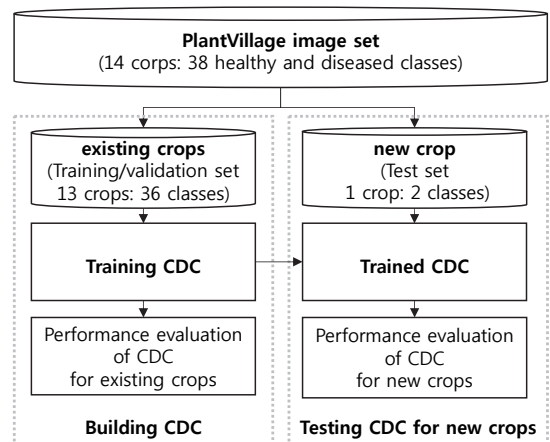
한편, VGG16은 1,400만개의 레이블된 이미지와 1,000개의 classes로 이루어진 ImageNet 데이터세트에서 동작하기 때문에 이를 그대로 농작물의 질병 분류에 적용할 수는 없다. 따라서 본 연구에서는 VGG16을 이용한 CDC를 Fig. 1과 같이 구축하였다.

본 연구에서 구축한 CDC는 기존의 VGG16 분류기에 3개의 완전연결(fully connected, FC) layer를 추가한 것으로, 각 FC layer 사이에 과적합(overfitting)을 막기 위한 dropout(rate = 0.1)과 batch normalization을 추가하였다.

**Fig. 1.** Architecture of CDC

또한, 기 학습된 VGG16 분류기가 CDC 학습 과정 중 추가 학습되는 것을 막기 위해 13개 conv. layers 사이의 가중치가 업데이트 되는 것을 동결(freezing)하였다. 이를 통해 VGG16 분류기가 ImageNet을 통해 사전에 학습한 표현들이 CDC 학습 과정 중 수정되어 훼손되는 것을 막을 수 있다(Chollet, 2017).

CDC 구축 및 성능 평가를 위한 전체 과정은 Fig. 2에 도식화 되어 있다. 먼저 구축된 CDC를 학습시키기 위하여 전체 이미지를 기존 농작물(existing crops: 13종/36 classes)과 신규 농작물(new crops: 1종/2classes)로 분할하고, 이 중 기존 농작물을 학습과 검증세트(training/validation set)로 분할하여 CDC 학습(training CDC) 및 성능 평가에 사용하였다.

**Fig. 2.** Performance evaluation of CDC

이어서 신규 농작물에 대한 CDC의 질병 여부 진단 수준을 확인하기 위하여, 신규 농작물을 테스트세트로 활용하여 앞서 학습된 CDC를 통해 그 성능을 측정하였다.

3.2 학습된 분류기(CDC)의 성능 평가

CDC의 성능 평가는 기존 농작물에 대한 질병분류(36 classes)와 신규 농작물에 대한 질병 여부 진단(2 classes: healthy or disease)으로 이루어진다.

본 연구에서는 4종의 신규 농작물 별로 시나리오를 구성하여 CDC의 성능을 평가하였다. 시나리오별 신규 농작물의 종류와 각 농작물의 class별 이미지의 갯수는 Table 2와 같다. 테스트세트의 class 불균형에 의한 정확도의 착시현상을 방지하기 위하여, class별로 데이터의 개수가 비슷한 작물을 선정하여 신규작물로 선정하였다.

Table 2. New crop for each scenario

scenario	new crop	# of healthy images	# of diseases images
1	strawberry	2280	2218
2	pepper	2485	2391
3	cherry	2282	2104
4	peach	2160	2297

본 연구에서는 CDC 구축을 위해, 시나리오별 총 25 epochs의 학습 기간 동안 학습 세트를 통해 CDC를 학습하였고, 검증 세트를 통해 CDC의 정확도를 측정하였다. 실험 환경은 Intel i7-7700 2.80GHz CPU, 16GB RAM, GeForce GTX 1060 GPU로 구성하였다.

Fig. 3은 학습 기간 동안 CDC의 분류 정확도를 보여주고 있다. 지면상의 제약으로 인해 Fig. 3에서는 시나리오 3에 대한 결과만을 보여주고 있으나, 모든 시나리오에 대해 학습 정확도는 약 10 epochs 이후부터 안정적인 모습을 보여주었다. 또한 검증 세트에 대한 정확도 역시 10 epochs 이후부터 큰 변화가 없어 과적합은 발생하지 않은 것으로 보인다.

시나리오별 CDC의 성능을 분류 정확도(accuracy)로 살펴보면 Table 3과 같다. 신규 농작물의 정확도는 테스트세트에 포함된 질병 여부(healthy 또는 disease)와 예측된 질병 여부를 비교하여 그 결과가 일치하는 비율로 계산되었다.

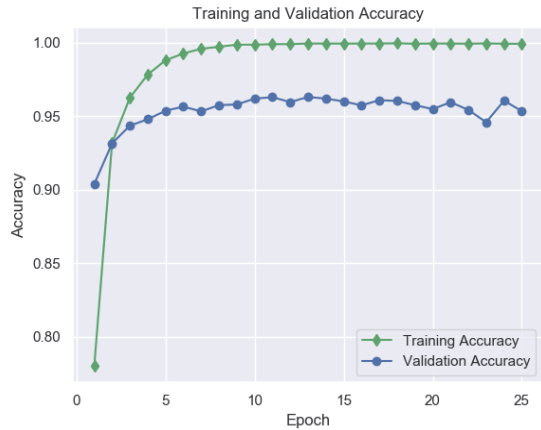


Fig. 3. Accuracy of CDC for scenario 3

Table 3. Accuracy of CDC

scenario	existing crops		new crop
	training	validation	test
1	0.99959	0.96343	0.49777
2	0.99965	0.96484	0.49568
3	0.99959	0.96306	0.50712
4	0.99971	0.96363	0.52275
average	0.99964	0.96374	0.50583

Table 3에 표기된 기존 농작물에 대한 CDC 정확도는 시나리오별로 25 epochs의 학습 기간 동안 가장 높은 정확도를 표현하고 있다. Table 2에서 보듯이 기존 농작물에 대한 CDC의 질병 분류 결과는 시나리오 별로 약간의 차이는 있지만 검증세트에서 평균 96.374%의 높은 정확도를 보이고 있다.

한편 Table 2의 신규 농작물에 대한 CDC의 정확도는 25 epochs의 학습 기간 중 가장 높은 검증 정확도를 보이는 CDC 가중치를 이용해 테스트세트에 대해 측정할 값이다.

Table 2에서 보듯이 신규 농작물에 대한 CDC의 성능은 예상대로 매우 저조함을 알 수 있다. 신규 농작물에 대한 질병 진단은 이진분류(healthy and disease) 문제이므로 평균 50.583%의 분류 결과는 전혀 학습되지 않은, 즉 무작위 분류 결과와 동일한 수준이라고 할 수 있다.

결론적으로 본 실험의 결과, 기존 농작물로 학습된 CDC가 미학습 신규 농작물의 질병 여부를 분류하는 것은 거의 불가능하다는 것을 알 수 있다.

4. 수정된 분류기

4.1 수정된 분류기(mCDC) 구축

본 연구에서는 미학습 신규 농작물에 대한 분류 정확도를 높이기 위하여 학습된 CDC를 활용한 mCDC구축 방법을 제안한다. 먼저 mCDC의 구조는 Fig. 4와 같다.

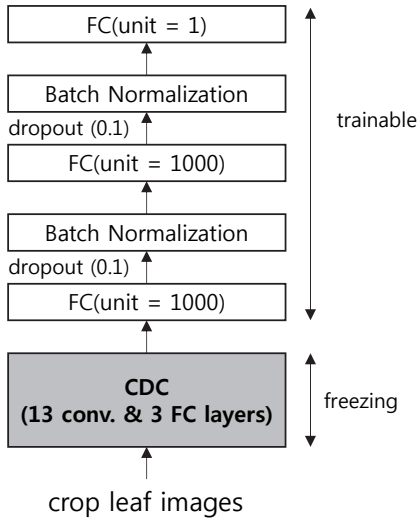


Fig. 4. Architecture of mCDC

mCDC는 기존의 학습된 CDC의 결과를 이용한다. 주어진 농작물 이미지에 대한 CDC의 결과는 36개 classes에 대한 softmax 값으로, 이 이미지가 각 질병 class에 속할 확률 값으로 이해할 수 있다.

이 결과를 입력으로 받아 질병 여부를 진단하는 이전 분류기를 추가하는 것으로 mCDC는 구성된다. 본 연구에서는 CDC 구축과 유사하게 3개의 FC layers와 dropout 및 batch normalization을 추가하여 mCDC를 구축하였다.

한편, CNN을 활용한 이미지 분류문제에서 사전 학습된 분류기를 재사용할 경우, 기존 분류기의 conv. layers는 동결하고(혹은 미세 조정을 위하여 상위 일부 conv. layers는 동결 제외) FC layers만 재학습하는 것이 일반적이다. 그러나 본 연구에서는 13개의 conv. layers와 3개의 FC layers를 갖는 CDC 전체를 동결하고 추가적인 이전 분류기만 재학습시킴으로써 학습에 걸리는 총 시간을 최소화하고자 한다. 이렇게 함으로써 사전 학습된 CDC의 변경 없이 최소한의 노력만으로 mCDC를 구축할 수 있으며 제안된 기법의 현실 적용 가능성을 높일 수 있다.

mCDC의 구축 및 성능 평가를 위한 전체 과정은 CDC의 그것과 유사하며 Fig 5.에 도식화 되어 있다. Table 2와 같이 총 4종의 농작물(strawberry, pepper, cherry, peach)을 각각 신규 농작물로 간주하고 성능 분석을 수행하였다.

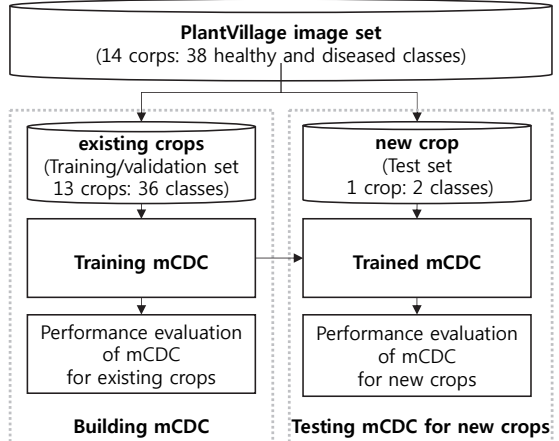


Fig. 5. Performance evaluation of mCDC

4.2 수정된 분류기(mCDC)의 성능평가

mCDC의 성능평가는 기존 농작물에 대한 질병 여부 및 신규 농작물에 대한 질병 여부 진단(2 classes: healthy or diseases)으로 이루어진다.

Fig. 6은 학습 기간 동안 mCDC의 분류 정확도를 보여주고 있다.



Fig. 6. Accuracy of mCDC for scenario 3

mCDC는 epoch 당 평균 학습 시간은 CDC와 동일한 실험환경에서도 4.06초로 매우 빠른 학습 수행이 가능하

다. 또한 기존의 CDC를 수정 없이 사용하기 때문에 학습 및 검증세트에 대한 분류 정확도도 Fig. 6에서 보듯이 학습 초기부터 높은 성능을 보이고 있음을 알 수 있다.

CDC의 성능평가에서 사용한 동일한 시나리오를 대상으로 측정된 mCDC의 분류 정확도는 Table 4에 나타나 있다.

Table 4. Accuracy of mCDC

scenario	existing crops		new crop
	training	validation	test
1	1.00000	0.99123	0.83549
2	0.99998	0.99297	0.75288
3	1.00000	0.99279	0.82858
4	1.00000	0.99327	0.68107
average	1.00000	0.99257	0.77451

Table 4에서 보듯이 기존 농작물에 대한 질병 여부 진단의 정확도는 CDC 보다 mCDC가 더 높게 나타나고 있다. 이는 CDC가 36개 classes의 다중분류 문제이고, mCDC는 이진분류 문제이기 때문으로 보인다.

한편, Fig. 7에서 보듯이 분석한 4개의 신규 농작물 모두에서 mCDC가 CDC에 비해 우수한 성능을 보이고 있다. 평균적으로 신규 농작물에 대한 CDC와 mCDC의 분류 정확도는 각각 50.583%, 77.451%로, mCDC가 CDC에 비해 26.868%p 향상되었다. 이는 기존 분류기를 이용한 수정된 분류기가 신규 농작물의 질병 여부 진단에 높은 성능 개선을 이루었음을 의미한다고 하겠다.

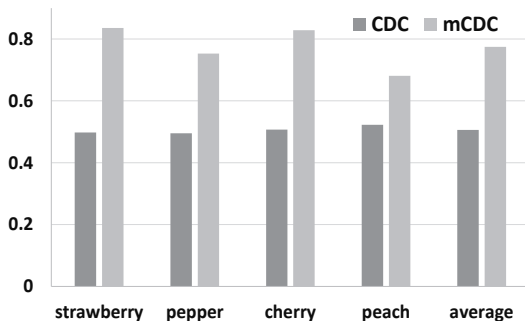


Fig. 7. Accuracy comparison between CDC and mCDC

5. 결론

본 연구는 대다수의 이미지 분류 연구와는 달리 기존

분류기의 확장성에 대한 주제를 다루고 있다. 농작물의 질병 분류와 같이 기존 분류기가 모든 농작물과 질병을 학습하기 어려운 상황에서 신규 농작물의 질병 여부를 더 효과적으로 진단하는 방법은 농업 생산성을 높이는 데 중요한 역할을 할 수 있다.

본 연구에서는 학습된 질병 분류기가 미학습 신규 농작물의 질병 여부를 진단하는 데 어느 정도 성능을 보이는지 확인하고, 이를 개선하기 위한 방법을 제안하였다.

또한, 실험을 통해 기존의 학습된 질병 분류기는 신규 농작물의 질병 여부를 진단하는데 저조한 성능을 보임을 확인하였고, 제안된 방법이 그 한계를 극복할 수 있음을 보였다. 본 연구에서 제안한 수정된 질병분류기는 학습하지 않은 다양한 신규 농작물의 질병 여부 진단에서 일정 수준 이상의 분류 성능을 보여주었다.

본 연구의 결과는 스마트팜의 필요 기술 중 하나인 농작물의 성장과정 모니터링 부분에 폭넓게 사용될 수 있을 것으로 예상된다. 기존의 학습된 환경을 넘어선 범용적인 질병 분류기는 다양한 농작물 재배를 위한 스마트팜 구축에 필수적인 기술이 될 것이다.

한편, 본 연구에서 CDC 및 mCDC 구축을 위해 사용한 VGG16 분류기는 농작물 질병 분류를 대상으로 학습한 분류기가 아니기 때문에, 농작물을 대상으로 학습한 CDC의 성능은 본 실험 결과와 다를 수 있다.

제안된 mCDC의 신규 농작물에 대한 질병 진단 정확도는 평균 77% 정도에 달하고 있어, 향후 추가 연구를 통해 성능 향상을 기대할 수 있다.

References

- Chollet, F., *Deep Learning with Python*, Manning Publications, Inc. USA, 2017.
- Ferentinos, K.P., "Deep Learning Models for Plant Disease Detection and Diagnosis", *Comput. Electron. Agric.* Vol. 145, pp. 311-318, 2018.
- He, K., Zhang, X., Ren, S., and Sun, J., "Residual Learning for Image Recognition", *Proc. of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 770-778, 2016.
- Huang, T., Yang, R., Huang, W., Huang, Y., and Qiao, X., "Detecting Sugarcane Borer Diseases Using Support Vector Machine". *Inf. Process. Agric.* Vol. 5, No. 1, pp. 74-82, 2018.
- Khamparial, A., Sainil, G., Gupta, D., Khanna, A.,

- Tiwari, S., and Albuquerque, V. H. C., "Seasonal Crops Disease Prediction and Classification Using Deep Convolutional Encoder Network", *Circuits, Systems, and Signal Processing*, Vol. 39, pp. 818-836, 2020.
6. Krizhevsky, A., Sutskever, I., and Hinton, G.E., "Imagenet Classification with Deep Convolutional Neural Networks", *Proc. of the Advances in Neural Information Processing Systems*, pp. 1097-1105, 2012.
 7. LeCun, Y., Bottou, L., Bengio, Y., and Hader, P., "Gradient-based Learning Applied to Document Recognition", *Proc. IEEE*, Vol. 86, pp. 2278-2324, 1998.
 8. Picon, A., Alvarez-Gila, A., Seitz, M., Ortiz-Barredo, A., Echazarra, J., and Johannes, A., "Deep Convolutional Neural Networks for Mobile Capture Device-based Crop Disease Classification in the Wild". *Comput. Electron. Agric.* Vol. 138, pp. 200-209, 2018.
 9. Saleem, M. H., Potgieter, J., and Arif, K. M., "Plant Disease Detection and Classification by Deep Learning, *Plants*", Vol. 8, pp. 468-490, 2019.
 10. Simonyan, K. and Zisserman, A., "Very Deep Convolutional Networks for Large-scale Image Recognition", *Proc. ICLR*, 2015.
 11. Sladojevic, S., Arsenovic, M., Anderla, A., Culibrk, D., and Stefanovic, D., "Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification", *Computational Intelligence and Neuroscience*, Vol. 2016, Article ID 3289801.



정 석 봉 (ORCID : <https://orcid.org/0000-0002-6209-1935> / sbjung@kiu.kr)

1999 한국과학기술원(KAIST) 산업경영학과 학사
 2001 한국과학기술원(KAIST) 산업공학과 석사
 2005 한국과학기술원(KAIST) 산업공학과 박사
 2011~ 현재 경일대학교 철도학부 부교수

관심분야 : 이미지 인식, 스마트팜, 사회네트워크분석



윤 협 상 (ORCID : <https://orcid.org/0000-0003-3306-7327> / hsyoon@cu.ac.kr)

1997 한국과학기술원(KAIST) 산업공학과 학사
 2000 한국과학기술원(KAIST) 산업공학과 석사
 2007 한국과학기술원(KAIST) 산업공학과 박사
 2010~ 현재 대구가톨릭대학교 소프트웨어융합학과 부교수

관심분야 : 이미지 인식, 실험계획법, 하이퍼파라미터 최적화, 스마트팜