

작물의 병충해 분류를 위한 이미지 활용 방법 연구

정성호* · 한정은* · 정성균* · 봉재환**

Study on Image Use for Plant Disease Classification

Seong-Ho Jeong* · Jeong-Eun Han* · Seong-Kyun Jeong* · Jae-Hwan Bong**

요약

서로 다른 특징을 가지는 이미지를 통합하여 작물의 병충해 분류를 위한 심층신경망을 훈련하는 것이 학습 결과에 어떤 영향을 미치는지 확인하고, 심층신경망의 학습 결과를 개선할 수 있는 이미지 통합방법에 대해 실험하였다. 실험을 위해 두 종류의 작물 이미지 공개 데이터가 사용되었다. 하나는 인도의 실제 농장 환경에서 촬영된 작물 이미지이고 다른 하나는 한국의 실험실 환경에서 촬영한 작물 이미지였다. 작물 잎 이미지는 정상인 경우와 4종류의 병충해를 포함하여 5개의 하위 범주로 구성되었다. 심층신경망은 전이학습을 통해 사전 훈련된 VGG16이 특징 추출부에 사용되었고 분류기에는 다층퍼셉트론 구조를 사용하였다. 두 공개 데이터는 세 가지 방법으로 통합되어 심층신경망의 지도학습에 사용되었다. 훈련된 심층신경망은 평가 데이터를 이용해 평가되었다. 실험 결과에 따르면 심층신경망을 실험실 환경에서 촬영한 작물 이미지로 학습한 이후에 실제 농장 환경에서 촬영한 작물 이미지로 재학습하는 경우에 가장 좋은 성능을 보였다. 서로 다른 배경의 두 공개데이터를 혼용하여 사용하면 심층신경망의 학습 결과가 좋지 않았다. 심층신경망의 학습 과정에서 여러 종류의 데이터를 사용하는 방법에 따라 심층신경망의 성능이 달라질 수 있음을 확인하였다.

ABSTRACT

It is worth verifying the effectiveness of data integration between data with different features. This study investigated whether the data integration affects the accuracy of deep neural network (DNN), and which integration method shows the best improvement. This study used two different public datasets. One public dataset was taken in an actual farm in India. And another was taken in a laboratory environment in Korea. Leaf images were selected from two different public datasets to have five classes which includes normal and four different types of plant diseases. DNN used pre-trained VGG16 as a feature extractor and multi-layer perceptron as a classifier. Data were integrated into three different ways to be used for the training process. DNN was trained in a supervised manner via the integrated data. The trained DNN was evaluated by using a test dataset taken in an actual farm. DNN shows the best accuracy for the test dataset when DNN was first trained by images taken in the laboratory environment and then trained by images taken in the actual farm. The results show that data integration between plant images taken in a different environment helps improve the performance of deep neural networks. And the results also confirmed that independent use of plant images taken in different environments during the training process is more effective in improving the performance of DNN.

키워드

Image-Based Classification, Plant Disease, Deep Neural Network, Transfer Learning
이미지 기반 분류, 작물 병충해, 심층 신경망, 전이 학습

* 상명대학교 휴먼지능로봇공학과(sbl0134@naver.com, jung_eun1004@naver.com, skjeong@smu.ac.kr) · Received : Jan. 19, 2022, Revised : Mar. 04, 2022, Accepted : Apr. 17, 2022
· Corresponding Author : Jae Hwan Bong

** 교신저자 : 상명대학교 휴먼지능로봇공학과

Dept. Human Intelligence Robot Engineering, Sangmyung University,
Email : drbong@smu.ac.kr

· 접수일 : 2022. 01. 19

· 수정완료일 : 2022. 03. 04

· 게재확정일 : 2022. 04. 17

1. 서론

기후 변화와 외래 병해충 유입 등의 이유로 돌발 병충해의 발생이 증가하고 있다. 이로 인한 농가의 피해가 증가하고 있으며 이러한 피해를 최소화하기 위해서는 짧은 주기의 반복적인 농작물 감시 및 조기 병충해 감지 활동이 이루어져야 한다. 상당수의 농가에서는 사람이 농작지를 돌아다니며 농작물을 감시하고 관찰자의 경험적 지식을 바탕으로 병충해 감지가 이루어지고 있다. 이러한 병충해 감지 방식은 농가의 제한적인 노동력으로 인해 짧은 주기의 농작물 감시가 어렵고 병충해 감지 성능이 관찰자의 능력에 의존적이라는 문제가 있다. 특히, 농작물의 재배 면적이 넓고 감시해야 할 농작물의 수가 많아질수록 이러한 문제는 부각된다.

심층인공신경망을 이용한 영상처리 기술은 지난 십수년간 비약적으로 발전해왔으며 얼굴 인식, 위변조 판별, 자율 주행 등의 다양한 영상 인식 분야에서 활용되고 있다[1-3]. 정밀 농업 분야에서는 심층인공신경망과 작물 이미지를 이용해 병충해 판별 및 탐지를 자동화하기 위한 연구가 다양하게 진행되고 있다.

단일 품종의 작물이나 다품종 작물에 대한 병충해 판별 및 탐지 연구가 심층인공신경망 기반으로 진행되고 있다. 심층인공신경망을 이용한 작물의 병충해 판별 및 탐지 연구들은 심층인공신경망의 훈련에 사용하는 작물 이미지의 종류를 기준으로 하여 촬영 배경을 정돈한 실험실 환경에서 다른 객체는 보이지 않게 작물만 보이도록 촬영한 이미지를 심층인공신경망의 훈련에 사용하는 연구[4-5], 실제 농장 환경 또는 이와 유사하게 마련한 배경에서 작물을 포함한 다양한 객체가 보이도록 촬영한 이미지를 심층인공신경망의 훈련에 사용하는 연구[6], 촬영한 이미지에서 관심 있는 작물의 영역만 잘라내어 심층인공신경망의 훈련에 사용하는 연구[7-8], 등으로 분류할 수 있다.

작물의 병충해 판별 및 탐지를 위해 훈련된 심층인공신경망은 실제 농장 환경에서 적용 및 사용되므로 심층인공신경망이 어떠한 종류의 이미지로 훈련이 되었던 성능 평가 단계에서는 실제 농장 환경에서 획득한 이미지에 대한 정확도 평가가 중요하다. 실제 농장 환경에서 획득한 이미지는 실험실 환경에서 획득한 이미지에 비해 배경이 복잡하고 데이터의 수가 제한

적이기 때문에 심층인공신경망을 훈련시키는 데 어려움이 있다. 실험실 환경에서 획득한 이미지로 심층인공신경망을 훈련하는 경우에는 실제 농장 환경에서 획득한 이미지에 대한 정확도 성능이 감소하는 경향이 있다[7].

본 연구에서는 서로 다른 공공데이터로부터 추출한 실제 농장 환경에서의 병충해 이미지와 실험실 환경에서의 병충해 이미지를 병합하여 심층인공신경망의 훈련에 사용할 경우 훈련된 심층인공신경망이 실제 농장 환경에서의 병충해 이미지에 대한 판별 정확도가 향상되는지 확인하고자 한다.

II. 데이터 구성

2.1 작물 이미지 데이터

실제 농장 환경에서의 병충해 이미지와 실험실 환경에서의 병충해 이미지를 서로 다른 공공 데이터에서 추출하였다. 실험실 환경에서의 병충해 이미지는 한국지능정보사회진흥원에서 운영하는 AI Open Innovation Hub(: AI Hub)에서 2018년도에 구축한 농업 지식 베이스 데이터로부터 추출하였다. 농업 지식 베이스 데이터에는 건강한 작물의 잎 이미지와 병충해가 있는 작물의 잎 이미지를 합쳐 총 40,704개의 이미지가 작물 품종 및 병충해의 종류에 따라 28개의 하위 범주로 분류되어 있다. 전체 이미지 데이터에는 농장 환경과 실험실 환경에서의 이미지 데이터가 혼재하며, 전체 이미지 데이터 중 실험실 환경에서의 이미지 데이터만 추출하여 연구에 사용하였다.

실제 농장 환경에서의 병충해 이미지는 공공 데이터인 PlantDoc Dataset(: PDD)에서 추출하였다[8]. PDD는 농업 지식 베이스 데이터와 달리 실제 농장에서 촬영한 작물 이미지만으로 구성되어 있다. PDD는 건강한 작물의 잎 이미지와 병충해가 있는 작물의 잎 이미지를 합쳐 총 2,569개의 이미지가 작물 품종 및 병충해의 종류에 따라 30개의 하위 범주로 분류되어 있다.

두 공공 데이터, 농업 지식 베이스 데이터와 PDD,의 하위 범주가 완전히 일치하지 않기 때문에 두 공공 데이터에서 겹치는 하위 범주만 선정하여 연구에 사용하였다. 선정된 하위 범주는 총 5가지로 청벌레

(Blue Bug), 잎곰팡이병(Leaf Mold), 흰가루병(Leaf Powdery Mildew), 점박이병(Leaf Spot), 정상(Normal)이었다.




그림 1. 심층신경망의 학습과 평가에 사용된 두 공공데이터: (a)PlantDoc data, (b)AI Open Innovation Hub data

Fig. 1 Two public data used to train and evaluate deep neural network: (a)PlantDoc data, (b)AI Open Innovation Hub data

2.2 훈련 및 평가 데이터 쌍

<그림 1>에서 확인할 수 있듯이 실험실 환경에서의 병충해 이미지는 흰색 배경을 바탕으로 병충해가 발생한 잎이나 정상 잎 이미지가 한 장씩 촬영되어 있다. 이와 달리 실제 농장 환경에서의 병충해 이미지에는 병충해가 발생한 잎 이외에도 정상 잎이나 다른 작물의 잎이 배경에 포함되어 있다. 다수의 잎이 배경에 포함되는 것을 최소화하기 위해서 실제 농장 환경에서의 병충해 이미지에 대해 목표 병충해가 발생한 잎 주변만 사각형으로 잘라내는 작업을 추가로 수행하였다.

서로 다른 공공데이터에서 추가한 실제 농장 환경에서의 병충해 이미지와 실험실 환경에서의 병충해 이미지가 병합되어 심층인공망의 훈련에 사용되면 훈련 결과에 어떤 영향을 미치는 지 확인하기 위해서 각 하위 범주의 병충해에 포함되는 실제 농장 환경에서의 병충해 이미지 개수와 실험실 환경 병충해에서의 이미지 개수를 통제 변인으로써 일치시켰다. <표 1>에서 볼 수 있듯이 각 하위 범주인 청벌레, 잎곰팡이병, 흰가루병, 점박이병, 그리고 정상 범주에는 실제 농장 환경과 실험실 환경에서 촬영한 병충해 이미지

가 동일한 개수만큼 포함되었다. 데이터 쌍은 심층인공신경망의 입력으로 사용할 이미지 데이터에 심층인공신경망의 목표 값으로 사용할 라벨을 짝지어 구성하였다. 훈련 데이터 쌍(Training dataset)은 3,344 쌍으로 구성하였고 검증 데이터 쌍(Validation dataset)은 834 쌍으로 구성하였다. 평가 데이터 쌍(Test dataset)은 실제 농장 환경에서 촬영한 이미지 데이터만 포함하여 50 쌍으로 구성하였다. 훈련 데이터 쌍, 검증 데이터 쌍, 그리고 평가 데이터 쌍은 전체 데이터 쌍에 대해 각각 79.1%, 19.7%, 1.2%의 비율로 서로 겹치는 데이터 없이 모두 다른 데이터를 사용하여 구성하였다.

표 1. 훈련, 검증, 평가 데이터의 수

Table 1. Number of image data for train, validation, and test dataset

		Train	Validation	Test
Blue bug	AS	155	39	10
	LS	155	39	-
Leaf mold	AS	434	108	10
	LS	434	108	-
Leaf powdery mildew	AS	215	54	10
	LS	215	54	-
Leaf spot	AS	434	108	10
	LS	434	108	-
Normal	AS	434	108	10
	LS	434	108	-
* AS: Image data taken at Agricultural Site				
* LS: Image data taken at Laboratory Setup				

III. 전이학습

전이학습은 해결하고자 하는 문제와 비슷한 종류의 데이터로 사전에 학습되어 있는 심층인공신경망의 구조와 가중치(weights)를 사용하여 해결하고자 하는 문제의 데이터로 심층인공신경망을 재훈련하는 방법이다. 전이학습을 이용하면 심층인공신경망의 학습 속도를 빠르게 할 뿐만 아니라, 학습에 사용할 수 있는 데이터의 양이 제한적인 경우에도 좋은 성능의 심층인공신경망을 구성할 수 있다.

3.1 전이학습에 사용된 심층인공신경망 구조

작물의 잎 이미지를 입력으로 하는 병충해 판별기를 개발하기 위해 이미지 인식에서 좋은 성능을 보였던 VGG16[9] 구조를 전이학습에 이용하였다. 전이학습에 사용된 VGG16의 구조는 <그림 2>에 나타내었다. <그림 2>의 심층신경망 구조에서 파란색 상자는 사전 훈련된 VGG16의 구조와 가중치를 모두 가져온 부분이며, 오렌지색 상자는 구조만 가져온 부분이다. 초록색 상자는 훈련될 가중치가 없는 부분이며, 빨간색 상자는 사전 훈련된 VGG16과 구조와 가중치가 모두 다르게 생성한 부분이다.

<그림 2>의 심층신경망 구조는 역할에 따라 크게 두 부분으로 나뉘어 특징 추출부(Feature Extractor)와 분류부(Classifier)를 이용해 입력 이미지를 처리한다. 입력층에 입력된 2차원 이미지 데이터는 Convolutional Neural Network(CNN)[10] 구조를 이용하는 특징 추출부를 지나면서 특징이 추출된다. 특징 추출부의 출력은 Fully Connected(FC) 층을 이용해 추출한 특징을 해석하는 분류부에서 분류된다.

VGG16의 특징 추출부에서는 2개 또는 3개의 Convolutional Layer(Conv)와 하나의 Pooling 층이 순서대로 쌓여서 하나의 VGG 모듈을 이루며 이러한 VGG 모듈이 총 5개 연속해서 나타난다. 입력층에 가까운 VGG 모듈일 수록 이미지에 포함된 기본적인 도형에 대한 특징을 추출하고 VGG 모듈이 쌓일수록 기본 도형이 모여 훈련 이미지 데이터에 적합하고 더 복잡한 특징을 추출하게 된다.

VGG16은 ImageNet 데이터를 이용해 사전에 가중치가 훈련되어 있다. 작물의 잎 데이터와 ImageNet 데이터는 2차원 이미지로 형태가 같지만, 이미지의 종류는 다르기 때문에 추출해야 하는 이미지의 특징이 다르다. 작물 잎 데이터의 수가 충분하다면 VGG16의 구조만 사용하고 가중치는 임의의 값으로 초기화하여 작물 잎 데이터를 이용한 훈련을 진행하겠지만 VGG16 구조에서 훈련이 필요한 가중치를 모두 훈련하기에는 작물 잎 데이터의 수가 부족하다. 이러한 문제를 해결하기 위해 ImageNet 데이터와 작물의 잎 데이터에서 도형과 같은 기본적인 특징은 공통적으로 추출된다는 가정을 하고 VGG16의 특징 추출부 중에서 첫 번째부터 네 번째 VGG 모듈까지는 ImageNet 데이터로 사전 학습된 가중치를 사용하였고 다섯 번

째 VGG 모듈의 가중치는 임의의 값으로 초기화하여 작물의 잎 데이터를 통해 훈련되도록 하였다.

ImageNet의 하위 범주는 총 1000개로 구성되어 있기 때문에 ImageNet으로 사전 학습된 VGG16의 분류부는 특징 추출부의 결과를 1000개의 하위 범주로 분류하는 데 적합한 구조와 가중치로 구성되어 있다. 연구에서 사용하는 작물의 잎 데이터는 하위 범주가 5개인 데이터로 사전 학습된 VGG16의 분류부와는 구조와 가중치가 맞지 않다. 사전 학습된 VGG16의 분류부는 구조와 가중치 모두 참고하지 않았고, 분류부의 구조를 작물의 잎 데이터에 맞게 여러 개의 FC 층을 이용해 구성하고 가중치는 임의의 값으로 초기화하여 훈련하였다. 새롭게 구성한 분류부는 <그림 2>의 빨간색 상자로 표시하였듯이 VGG16의 특징 추출부 뒤에 이어서 오도록 배치하였다.




그림 2. 전이학습에 사용된 VGG16의 구조
Fig. 2 Structure of VGG16 applied to transfer learning

3.2 하이퍼파라미터 탐색 및 선정 방법

심층인공신경망의 가중치와 하이퍼파라미터(Hyperparameters)는 학습된 심층인공신경망의 성능을 결정하는 중요한 요소들이다. 가중치는 학습 과정에서 데이터 쌓에 최적화되며 갱신되지만 하이퍼파라미터는 학습 과정에서 갱신되지 않으며 학습 시작 이전에 최적의 조합을 선정해야 한다. <그림 2>의 분류부를 구성하기 위해 FC 층을 쌓아 Multi-Layer Perceptron(: MLP) 구조를 만들면서 필요한 하이퍼파라미터를 선정하였고, 학습 과정에 필요한 하이퍼파라미터도 선정하였다. 하이퍼파라미터의 선정 과정에서 고려했던 하이퍼파라미터의 범위는 <표 2>에 나열하였다.

분류부에 쌓는 FC 층의 수는 1개에서 4개까지 1개 간격으로 고려하였다. 각 FC 층에서는 뉴런의 수, 활성화 함수, 그리고 Dropout 비율에 대한 하이퍼파라미터를 탐색하여 선정하였다. 뉴런의 수는 2의 거듭제곱 형태로, 지수를 5에서 9까지 1씩 증가시키며 탐색

하였다. 활성화 함수는 Hyperbolic Tangent(: HTanh)와 Rectified Linear Unit(: ReLu) 중에서 선택하였다. 과적합(Overfitting)을 일정 부분 막아주는 정규화(Regularization) 방법 중 하나로써 Dropout 비율을 각 FC 층에 추가하였다. Dropout 비율은 0.1에서 0.5까지 0.05씩 증가하는 실수 범위에서 탐색하였다.

심층신경망의 훈련 과정에서는 학습율, 학습율의 감소율, 그리고 Optimizer에 대한 하이퍼파라미터를 탐색하여 선정하였다. 전이학습의 훈련 과정은 두 단계로 이루어진다. 첫 번째 단계에서는 <그림 2>와 같이 특징 추출부의 대다수 가중치는 사전 학습된 VGG16의 가중치로 고정하여 훈련 과정에서 갱신되지 않도록 하고, 다섯 번째 VGG 모듈과 분류부의 가중치만 임의의 값으로 초기화하여 훈련 과정에서 갱신한다. 첫 번째 단계의 학습이 종료되고 두 번째 단계의 학습에서는 심층신경망의 모든 가중치가 첫 번째 단계의 훈련으로 획득한 가중치를 초기값으로 설정하여 훈련 과정에서 갱신된다.

표 2. 전이학습을 위해 탐색된 하이퍼파라미터의 범위
Table 2. Explored range of hyperparameters for transfer learning

Hyperparameters		Explored Range
Classifier (MLP structure)	Number of FC layers	Integer in range of [1, 4]
	Number of neurons	Integer in range of [5, 9]
	Activation function	Choose between Tanh and ReLu
	Dropout rate	Real number in range of [0.1, 0.5] with interval of 0.05
Training process	Learning rate	Integer in range of [2, 5]
	Learning rate decay	Integer in range of [2, 5]
	Optimizer	Choose among SGD, Adam, and RMSprop

첫 번째 훈련 단계를 위한 학습율과 학습율의 감소율은 0.1의 거듭제곱 형태로, 지수를 2에서 5까지 1씩 증가시키며 탐색하였다. 두 번째 훈련 단계를 위한 학습율은 첫 번째 훈련 단계에서 사용했던 학습율에 비례하여 사용하였고, 학습율의 감소율은 사용하지 않았다.

3.3 하이퍼파라미터 선정 결과

분류부에는 두 개의 FC 층을 쌓았다. 각 FC 층의 뉴런 수는 256개와 128개로 선정하였다. 모든 FC 층에서 활성화 함수는 ReLu, Dropout 비율은 0.25로 선정하였다. 분류부 뒤에 오는 출력층의 하이퍼파라미터는 탐색을 통해 결정한 것이 아니라 작물의 잎 데이터 분류에 필요한 하이퍼파라미터로 선정하였다. 출력층의 뉴런 수는 작물 잎 데이터의 하위 범주 수와 같은 5개로 하였고 활성화 함수는 분류에 적합한 Softmax를 사용하였다.

두 단계의 전이학습 훈련 과정 중, 첫 번째 단계의 훈련 과정에서 학습율은 $(0.1)^4$ 을 사용하였고 학습율의 감소율은 $(0.1)^2$ 으로 선정되어 20 epochs 마다 학습율이 감소하였다. Optimizer는 RMSprop이 선정되었다. 두 번째 단계의 훈련 과정에서 학습율은 첫 번째 훈련 단계의 학습율에 0.1을 곱하여 $(0.1)^5$ 으로 사용하였고 학습율의 감소율은 사용하지 않았다. Optimizer는 첫 번째 훈련 단계와 동일하게 RMSprop을 사용하였다. 전체 훈련 과정에서 손실 함수(Loss Function)은 다중 분류에 적합한 Categorical Cross-Entropy를 사용하였다.

IV. 성능 평가 방법 및 결과

4.1 성능 평가 방법

두 단계의 전이학습 훈련 과정에서 <표 3>과 같이 각 훈련 과정에 사용하는 데이터 쌍의 종류를 세 방법으로 바꿔가며 동일한 구조의 심층신경망에 대해 데이터 쌍의 종류를 다르게 하여 훈련시키면 평가 데이터 쌍에 대한 심층신경망의 정확도가 어떻게 변화하는지 확인하였다.

첫 번째 방법은 전이학습의 첫 번째 훈련 과정에서 실제 농장 환경에서 촬영한 병충해 이미지 데이터 쌍

을 사용하고 전이학습의 두 번째 훈련 과정에서 실험실 환경에서 촬영한 병충해 이미지 데이터 쌍을 사용하는 방법으로 훈련 과정에서 사용하는 데이터 쌍의 종류를 결정하였다.

표 3. 전이학습에 사용된 데이터의 종류

Table 3. Types of datasets used for transfer learning

	1st Training for Transfer Learning	2nd Training for Transfer Learning
Dataset type 1	AS	LS
Dataset type 2	LS	AS
Dataset type 3	Both AS and LS	Both AS and LS
* AS: Image data taken at Agricultural Site		
* LS: Image data taken at Laboratory Setup		

두 번째 방법은 전이학습의 첫 번째 훈련 과정에서 실험실 환경에서 촬영한 병충해 이미지 데이터 쌍을 사용하고 전이학습의 두 번째 훈련 과정에서 실제 농장 환경에서 촬영한 병충해 이미지 데이터 쌍을 사용하는 방법으로 훈련 과정에서 사용하는 데이터 쌍의 종류를 결정하였다.

마지막으로 세 번째 방법으로는 전이학습의 첫 번째 훈련 과정과 두 번째 훈련 과정 모두에서 실제 농장 환경에서 촬영한 병충해 이미지 데이터 쌍과 실험실 환경에서 촬영한 병충해 이미지 데이터 쌍이 혼재되어 병합되어 있는 데이터 쌍을 사용하였다. 각 훈련 과정에 사용된 데이터 쌍의 수는 세 번째 방법에서 가장 많았다.

세 가지 방법으로 훈련된 심층신경망은 실제 농장 환경에서 촬영한 이미지 데이터로만 구성된 평가 데이터 쌍을 이용해 분류 정확도를 계산하고 성능을 평가하였다.

4.2 성능 평가 결과

<표 3>에 나열한 데이터 쌍을 이용하여 전이학습의 두 단계의 훈련 과정을 거치면서 평가 데이터 쌍에 대한 정확도를 계산하고 <표 4>에 나열하였다.

<표 3>의 Dataset type 1의 방법을 통해 전이학습의 두 단계 훈련 과정을 거치면 두 번째 훈련 단계에 비해 첫 번째 훈련 단계에서 더 높은 정확도를 보였

다. 실제 농장 환경에서 촬영한 이미지 데이터를 사용해 전이학습의 첫 번째 훈련 단계를 수행한 심층신경망은 평가 데이터 쌍의 분류에서 58.0%의 정확도를 나타냈다. 하지만 실험실 환경에서 촬영한 이미지 데이터를 사용해 두 번째 훈련 단계를 마친 심층신경망은 평가 데이터 쌍의 분류에서 46.0%의 정확도를 보이며, 오히려 정확도가 떨어지는 결과를 보였다.

<표 3>의 Dataset type 2의 방법을 통해 전이학습의 두 단계 훈련 과정을 거치면 첫 번째 훈련 단계에 비해 두 번째 훈련 단계에서 더 높은 정확도를 보였다. 실험실 환경에서 촬영한 이미지 데이터를 사용해 전이학습의 첫 번째 훈련 단계를 수행한 심층신경망은 평가 데이터 쌍의 분류에서 40.0%의 낮은 정확도를 나타냈다. 실제 농장 환경에서 촬영한 이미지 데이터를 사용해 두 번째 훈련 단계를 마치면 심층신경망은 평가 데이터 쌍의 분류에서 66.0%의 정확도를 보이며 정확도가 크게 향상되었다.

<표 3>의 Dataset type 3의 방법을 통해 전이학습의 두 단계 훈련 과정을 거치는 경우, 두 훈련 단계에서 모두 같은 데이터 쌍을 사용하기 때문에 두 번째 훈련 단계가 끝난 심층신경망에 대해 평가 데이터 쌍의 분류 정확도를 계산하였다. 두 번째 훈련 단계를 마치고 심층신경망은 평가 데이터 쌍의 분류에서 52.0%의 정확도를 보였다.

표 4. 농장 환경에서 촬영된 평가 데이터에 대한 훈련된 심층신경망의 정확도

Table 4. Accuracy of trained DNN for the test dataset taken at agricultural site

	DNN after 1st Training	DNN after 2nd Training
Dataset type 1	58.0 %	46.0 %
Dataset type 2	40.0 %	66.0 %
Dataset type 3	-	52.0 %

4.3 성능 평가 결과에 대한 고찰

실제 농장 환경에서 촬영한 이미지와 실험실 환경에서 촬영한 이미지 데이터의 조합으로 동일한 전이학습 모델에 대한 훈련을 진행했을 때, 각 훈련 단계에 사용하는 데이터의 종류에 따라 훈련된 심층신경망의 평가 데이터 쌍의 분류에 대한 정확도가 달라짐을 확인하였다.

<표 3>의 Dataset type 1과 Dataset type 3을 이용한 <표 4>의 결과를 비교해 보면, 실제 농장 환경에서 촬영한 이미지와 실험실 환경에서 촬영한 이미지 데이터를 섞어서 심층신경망의 훈련에 사용하는 방법은 학습된 심층신경망의 정확도 측면에서 가장 나쁜 결과를 보였다. 데이터를 섞어서 사용하기 보다는 데이터의 양이 적어지더라도 실제 농장 환경에서 촬영한 이미지만 사용해 심층신경망을 훈련하는 방법이 학습된 심층신경망의 정확도 측면에서 더 좋은 결과를 보였다.

<표 3>의 Dataset type 2를 이용한 <표 4>의 결과를 통해 동일한 양의 실제 농장 환경에서 촬영한 이미지와 실험실 환경에서 촬영한 이미지 데이터에 대해 전이학습의 첫 번째 단계에서 실험실 환경에서 촬영한 이미지를 사용하고 전이학습의 두 번째 단계에서 실제 농장 환경에서 촬영한 이미지를 사용하는 것이 학습된 심층신경망의 정확도 측면에서 가장 좋은 결과를 보였다.

V. 결론

ImageNet 데이터로 사전에 학습된 VGG16을 서로 다른 공공데이터에서 추출한 실제 농장 환경에서의 작물 잎 이미지와 실험실 환경에서의 작물 잎 이미지 데이터를 이용해 전이학습 하고, 전이학습의 결과를 실제 농장 환경에서 촬영한 작물 잎 이미지로 구성된 평가 데이터 쌍에 대한 정확도 측면에서 향상시킬 수 있는 방법에 대해 연구를 수행하였다. 데이터 구성에 따른 정확도 향상 정도를 확인하기 위해 전이학습에 사용되는 심층신경망의 구조와 실제 농장 환경에서 촬영한 이미지와 실험실 환경에서 촬영한 이미지 개수 등 다른 조건들은 모두 일치시켜 실험을 진행하였다.

VGG16의 특징 추출부에서 대부분의 가중치는 사전 학습된 가중치를 사용하고 특징 추출부의 일부 가중치와 분류기의 가중치만 임의의 값으로 초기화하여 훈련 과정에서 갱신하는 전이 학습의 첫 번째 단계와 전체 심층신경망의 가중치를 낮은 학습율을 사용해 갱신하는 전이 학습의 두 번째 단계에 각각 다른 데이터 쌍을 사용하면서 훈련을 마친 심층신경망의 평가 데이터 쌍에 대한 정확도를 계산하고 평가하였다.

본 연구를 통해 데이터 쌍의 활용 방법에 따라 같

은 구조의 심층신경망, 같은 훈련 방법, 같은 수의 데이터를 사용해도 심층신경망의 훈련 결과가 달라질 수 있다는 것을 확인하였다. 전이 학습의 첫 번째 단계에 실험실 환경에서 촬영한 이미지를 사용하고, 전이 학습의 두 번째 단계에서 실제 농장 환경에서 촬영한 이미지를 사용하는 순서의 '데이터 활용 방법이 훈련을 마친 심층신경망의 평가 데이터 쌍에 대한 정확도 측면에서 가장 좋은 결과를 보였다. 전이 학습의 첫 번째 단계와 두 번째 단계 모두에서 실제 농장 환경에서 촬영한 이미지와 실험실 환경에서 촬영한 이미지를 섞어서 사용하는 데이터 활용 방법이 가장 나쁜 결과를 보였다. 오히려 데이터의 수가 적더라도 실제 농장 환경에서 촬영한 이미지만 이용해 전이 학습의 첫 번째 단계만 수행하는 데이터 활용 방법이 실제 농장 환경에서 촬영한 이미지와 실험실 환경에서 촬영한 이미지를 섞어서 사용하는 방법에 비해 더 나은 결과를 보였다.

본 연구에서 다루지 못한 심층신경망의 훈련에 사용되는 데이터의 수, 데이터 전처리 방법, 객체 검출을 통한 관심 영역(Region of Interest) 설정 등이 심층신경망의 훈련 결과에 어떤 영향을 미치고, 최적의 방법이 무엇인지 확인하기 위한 추가 연구가 필요하다.

감사의 글

본 연구는 2021학년도 상명대학교 교내연구비를 지원받아 수행하였음

References

- [1] S. Salimov and J. Yoo, "A Design of Small Scale Deep CNN Model for Facial Expression Recognition using the Low Resolution Image Datasets," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 16, no. 1, 2021, pp. 75-80.
- [2] S. Bak, N. Kim, M. Jeong, D. Hwang, U. Enkhjargal, B. Kim, M. Park, H. Yoon, and W. Seo, "Study on Detection Technique for Coastal Debris by using Unmanned Aerial Vehicle Remote Sensing and Object Detection Algorithm based on Deep Learning," *J. of the Korea Institute of Electronic Communication*

Sciences, vol. 15, no. 6, 2020, pp. 1209-1216.

[3] S. Bak, M. Jeong, D. Hwang, U. Enkhjargal, N. Kim, and H. Yoon., "Study on Cochlodinium polykrikoides Red tide Prediction using Deep Neural Network under Imbalanced Data," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 14, no. 6, 2019, pp. 1161-1170.

[4] S. Kim and J. Ahn, "Tomato Crop Diseases Classification Models Using Deep CNN-based Architectures," *J. of the Korea Academia-Industrial cooperation Society*, vol. 22, no. 5, 2021, pp. 7-14.

[5] K. Aravind, P. Raja, and R. Aniirudh, "Tomato crop disease classification using pre-trained deep learning algorithm," *Procedia Computer Science*, vol. 133, no. 1, 2018, pp. 1040-1047.

[6] H. Ham and H. Cho, "A Development of Rose Leaf Disease Classification System using Convolutional Neural Network," *The transactions of The Korean Institute of Electrical Engineers*, vol. 69, no. 7, 2020, pp. 1040-1045.

[7] M. Kim and C. Choi, "Superpixel-based Apple Leaf Disease Classification using Convolutional Neural Network," *J. of Broadcast Engineering*, vol. 25, no. 2, 2020, pp. 208-217.

[8] S. Davinder, J. Naman, J. Pranjali, K. Pratik, K. Sudhakar, and B. Nipun, "PlantDoc: A Dataset for Visual Plant Disease Detection," *Proceedings of the 7th Association for Computing Machinery India Special Interest Group On Knowledge Discovery and Data Mining Conference on Data Sciences and 25th Conference on Management of Data*, Hyderabad, India, 2020, pp. 249-253.

[9] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," *International Conference on Learning Representations*, San Diego, CA, USA, 2015.

[10] A. Krizhevsky, I. Sutskever, and G. Hinton, "Imagenet classification with deep convolutional neural networks," *Advances in neural information processing systems*, vol. 25, 2012, pp. 1097-1105.

저자 소개



정성호(Seong-Ho Jeong)

2017년 ~ 현재 상명대학교 휴먼
지능봇공학과 재학

※ 관심분야 : 컴퓨터 공학, 임베디드 시스템, 인공지능 딥러닝



한정은(Jeong-Eun Han)

2019년 ~ 현재 상명대학교 휴먼
지능봇공학과 재학

※ 관심분야 : 인공지능 데이터 처리



정성균(Seong-Kyun Jeong)

2003년 서울대학교 기계항공공학
부졸업(공학사)

2005년 서울대학교 기계항공공학
부졸업(공학석사)

2020년 한국과학기술원 항공우주
공학과 졸업(공학박사)

2005년 3월 ~ 2016년 2월 한국전자통신연구원 선
임연구원

2016년 4월 ~ 2020년 8월 과학기술정보통신부 사
무관

2020년 9월 ~ 현재 상명대학교 부교수

※ 관심분야 : 위성항법, 비행동역학, 제어

봉재환(Jae-Hwan Bong)



2012년 고려대학교 기계공학과
졸업(공학사)

2014년 고려대학교 대학원 기계
공학과 졸업(공학석사)

2020년 고려대학교 대학원 기계
공학과 졸업(공학박사)

2020년 3월 ~ 2020년 8월 RA, MMMI, University
of Southern Denmark

2020년 9월 ~ 현재 상명대학교 조교수

※ 관심분야 : Robotics, Human-Robot Interface,
Data-Driven Control, Machine Learning