

# LeafNet: 합성곱 신경망을 이용한 식물체 분할<sup>+</sup>

## (LeafNet: Plants Segmentation using CNN)

조 정 원<sup>1)</sup>, 이 민 혜<sup>2)</sup>, 이 흥 로<sup>3)</sup>, 정 용 석<sup>4)</sup>, 백 정 호<sup>5)</sup>, 김 경 환<sup>6)</sup>, 이 창 우<sup>7)\*</sup>

(Jeong Won Jo, Min Hye Lee, Hong Ro Lee, Yong Suk Chung, Jeong Ho Baek, Kyung Hwan Kim, and Chang Woo Lee)

**요 약** 식물 표현체(plant phenomics) 연구는 우수한 형질의 식물 품종과 유전적 특성을 선별하기 위해 여러 식물체의 형태적 특징을 관측하고, 획득한 영상 빅데이터를 분석하는 기술이다. 기존의 방법은 검출 대상에 따라 직접 색상 임계값을 변경해야 하기 때문에 빅데이터를 다루는 정밀검정시스템에 적용하기 어렵다. 본 논문에서는 정밀검정시스템을 위한 식물체와 배경의 자동 분할이 가능한 합성곱 신경망(Convolution neural network: CNN) 구조를 제안한다. LeafNet은 9개의 컨벌루션 계층과 식물의 유무를 판단하기 위한 시그모이드(Sigmoid) 활성화 함수로 구성된다. LeafNet을 이용한 학습 결과, 식물 모종 영상에 대하여 정밀도 98.0%, 재현율 90.3%의 결과가 도출되어 정밀검정시스템의 적용 가능성을 확인하였다.

**핵심주제어:** 딥 러닝, 분할, 식물 표현체, 피노믹스 시스템, 합성곱 신경망

**Abstract** Plant phenomics is a technique for observing and analyzing morphological features in order to select plant varieties of excellent traits. The conventional methods is difficult to apply to the phenomics system. because the color threshold value must be manually changed according to the detection target. In this paper, we propose the convolution neural network (CNN) structure that can automatically segment plants from the background for the phenomics system. The LeafNet consists of nine convolution layers and a sigmoid activation function for determining the presence of plants. As a result of the learning using the LeafNet, we obtained a precision of 98.0% and a recall rate of 90.3% for the plant seedlings images. This confirms the applicability of the phenomics system.

**Key Words:** Deep learning, Segmentation, Plant phenomics, Phenomics system, CNN

\* Corresponding Author: leecw@kunsan.ac.kr

+ 이 논문은 농촌진흥청 차세대 바이오그린21사업(PJ01451202)의 지원에 의해 이루어진 것임

Manuscript received July 23, 2019 / revised August 07, 2019 / accepted August 12, 2019

1) 군산대학교 컴퓨터정보통신공학부, 제1저자  
2) 군산대학교 컴퓨터정보통신공학부, 제2저자  
3) 군산대학교 컴퓨터정보통신공학부, 제3저자  
4) 제주대학교 식물자원환경전공, 제4저자  
5) 농촌진흥청 국립농업과학원, 제5저자  
6) 농촌진흥청 국립농업과학원, 제6저자  
7) 군산대학교 컴퓨터정보통신공학부, 교신저자

## 1. 서 론

식물 표현체(Plant phenomics) 연구는 식물의 형태적 특징을 영상 빅데이터를 통해 수치화, 객관화하여 분석하는 기술이다[1]. 식물의 형태학적 특징은 발아, 생육, 병해충에 대한 저항성, 영양학적 가치 증대, 대량생산 등 품질과 밀접한 관계가 있으며, 이러한 식물 표현체 연구를 통해 우수한 형질의 품종과 작물의 유전적 특성을 선별할 수 있다

[2]. 데이터베이스에 저장된 식물의 이미지 정보를 재배환경, 생육시기별 크기, 생체량, 수량 등 농업 형질에 따라 분류하고 유전체, 표현체 정보를 포괄적으로 비교 분석하면 육종 기간 단축, 우수한 품종 및 유전자 확보 등 시간 및 비용이 감소되며 효율적인 작업이 가능하다[3].

표현체 연구에 사용되는 식물의 종류는 다양하고 수가 많기 때문에 이를 파악하고 관리할 정밀검정시스템이 필요하다. 대다수의 식물 분류 과정과 데이터 입력은 수작업으로 이루어지기 때문에 품종에 대한 정보가 많을수록 관리가 복잡하고 실수가 발생할 수 있다. 따라서 다품종 식물체의 색상, 형태, 크기 등의 특징 정보를 추출하고 분류할 수 있는 자동화 시스템의 필요성이 높아지고 있다.

기존에 사용되고 있는 정밀검정시스템은 여러 가지 센서를 온실에 설치하여 식물의 표현형을 측정하는 방법과 식물의 색소체 특성을 기반으로 잎 면적이나 손상부위를 측정하는 방법이 있다[3]. 센서를 이용한 측정 방법은 온실에 RGB 및 RFID, 3D, 적외선 센서 등을 설치하여 얻은 엽록소 형광, 초분광영상에서 식물의 표현형을 측정한다. 이러한 방법은 사이즈가 큰 식물이나 다수 샘플의 표현형 측정에는 용이하나 시설 내 재배 환경을 균일하게 맞춰야 하며 센서 시스템의 고장이나 오작동이 발생하면 고가의 수리비용이 발생하는 단점이 있다. 색소체 특성에 관한 연구는 촬영한 영상으로부터 색상 정보를 추출하여 식물을 식별하는 방법이다. 이 방법은 일반적으로 영상처리에 사용되는 적색, 녹색, 청색 3원색의 색상영역(RGB color)을 기반으로 대상을 검출한다[4]. 복잡한 센서 시스템의 설치 없이 카메라로 촬영한 영상에서 식물의 표현형을 측정하므로 비용이 저렴한 장점이 있다. 그러나 원하는 색상 영역 임계값을 사용자가 수동으로 설정하여 분류해야 하며, 화소의 밝기에 민감하게 반응하므로 단순한 배경, 동일선상의 위치, 동일한 광량에서 촬영된 영상이 요구된다.

이와 같은 검출 방법의 가장 큰 문제점은 각 식물체나 육종 환경에 따라 사용자가 직접 측정에 필요한 설정들을 변경해야 하는 것이다. 빅데이터를 다루는 자동화 시스템에서 사용자의 개입은 객

체 검출 단계에서 최대한 제외되어야 한다. 최근에는 검출 정확도와 편의성을 높이기 위해 합성곱 신경망(CNN)[5]과 같이 딥러닝을 이용한 객체 검출 기법이 발달되면서 영상 내 특징영역을 자동으로 분할하는 방법이 연구되고 있다. 따라서, 본 논문에서는 식물체와 배경의 자동 분할을 위한 합성곱 신경망 구조인 LeafNet을 제안한다. 2장에서는 사전연구에 대해 기술하고, 3장에서 제안된 방법의 구조와 식물체 분할을 위한 LeafNet에 관하여 논한다. 4장에서는 실험결과 및 고찰에 관하여 기술하며, 마지막으로 5장에서 결론 및 향후과제에 관하여 논한다.

## 2. 관련 연구

식물 영상은 영상을 획득한 빛의 파장대에 따라 시각영상, 엽록소 형광영상, 근적외선 영상, 분광 영상 등으로 구분하여 사용한다. 시각영상은 사람의 눈으로 볼 수 있는 가시광선 영역대의 영상을 일컫는다. 시각영상은 대부분의 영상 처리에서 사용되고 있으며 RGB 색 공간을 나타낸다. RGB를 이용한 영상처리는 그림자, 광잡음 등에 의해 각 색상 값이 크게 달라질 수 있어 색상을 기반으로 검출하는 영상처리에 단일 방법으로 쓰이기 어렵다. 이로 인해 색상, 명도, 채도로 구성된 HSV나 특정 컬러를 기준으로 하는 YCbCr, Lab 등 다양한 색상공간을 목적에 맞게 변환하여 사용한다[6-7].

본 논문에서 검출하고자 하는 식물의 잎과 줄기는 400nm에서 700nm의 가시광선 파장 범위에 속한다. 특히, 식물의 잎은 Fig. 1에 나타낸




Fig. 1 UV-Visible Spectroscopy

바와 같이 550nm와 700nm의 파장 영역의 색을 가장 높게 함유하고 있다. 파장 영역대에 따른 색 분포는 400nm~500nm는 청색, 550nm는 녹색과 황색, 700nm는 적색을 나타낸다[8].

합성곱 신경망은 영상을 입력으로 받아 영상의 특성을 추출하여 구분하는 방법이다. 입력 영상의 특성을 추출하는 부분으로 컨벌루션(Convolution) 계층과 풀링(Pooling) 계층이 있으며, 특징 맵(Feature map)을 구분하는 과정에 완전 연결(Fully-connected) 신경망 계층이 있다. 컨벌루션 계층은 여러 개의 필터를 적용하고 활성화 함수를 통해 입력 영상의 특성을 추출하여 특징 맵을 얻는 역할을 한다. 컨벌루션 계층에서 추출된 특징 맵은 완전 연결 신경망 계층과 분류기를 거쳐 객체를 검출하게 된다[9]. 국내에서는 이러한 신경망 모델을 이용하여 농경지 영상에서 잡초를 검출[10]하거나 식용버섯과 독버섯을 분류하는 연구[11]가 수행된 사례가 있다.

### 3. 제안 방법

#### 3.1 전처리 과정

합성곱 신경망을 학습하기 위해서는 전처리 과정을 거친 식물 영상 데이터셋이 필요하다. 식물의 잎과 줄기는 2절에서 확인한 바와 같이 녹색과 황색 범위의 색상으로 이루어져 있다. 본 논문에서는 웹사이트[12]에서 무작위로 크롤링한 500×500 크기의 식물 영상 300장과 표현체 연구를 위해 촬영한 4,384×6,576 크기의 식물 모종 영상 300장을 데이터셋으로 사용한다. 선별된 영상들은 라벨링 과정을 거친 후, 224×224 크기로 축소시키고 360장은 훈련 데이터셋, 40




Fig. 2 Examples of Plants Images

장은 검증 데이터셋, 200장은 실험 데이터셋으로 사용한다. 배경이나 광원이 다르게 주어지는 환경에서의 검출 가능성도 확인하기 위해 데이터셋은 Fig. 2와 같이 다양한 배경을 내포한 식물 영상으로 구성된다.

#### 3.2 라벨링

전처리된 영상은 GitHub에서 제공하는 오픈 소스 라벨링 프로그램 PixelAnnotation Tool[13]을 사용하여 라벨링 과정을 거친다. 해당 프로그램은 색상 영역을 기반으로 원하는 객체를 라벨링 할 수 있다. 본 논문에서는 녹색과 황색영역을 기반으로 전처리된 영상에서의 라벨링을 진행한다. 영상의 해상도가 낮거나 화질이 좋지 않은 경우 수정 기능을 이용하여 선택 영역의 크기 범위를 조절할 수 있다. Fig. 3과 같이 라벨링 된 영역은 이진화 되어 PNG 이미지 포맷 형태로 저장된다.

#### 3.3 전경 물체 분할 신경망(LeafNet) 구현

LeafNet은 224 ×224 크기의 전처리된 식물 영상을 입력으로 사용하고 식물의 특징을 추출하기 위한 9개의 컨벌루션 층과 식물의 유무를 판단하기 위한 시그모이드 활성화 함수로 이루어져 있다. LeafNet에 입력된 영상은 2개의 1×1 크기의 32, 64개의 필터를 가지는 컨벌루션 계층을 거친다. 필터의 개수가 128개가 되는 시점부터 필터를 Fig. 4의 LeafNet-1과 같이 9×9, 7×7, 5×5, 3×3 크기로 감소시키고 영상의 화소 상에서 식물과 배경간의 관계성을 찾는 과정을 거친다.




Fig. 3 Labeling using PixelAnnotation Tool

색상을 기반으로 하는 이진분할은 주변 광원, 잎이나 줄기 색상의 변화에 민감하나 신경망을 통해 특징을 학습하여 검출하게 되면 이러한 단점을 보완할 수 있다. 각 계층에서 얻어지는 특징 맵은 LeakyReLU를 이용하여 정규화하고, 이전 계층의 출력을 축소하는 풀링 계층과 완전 연결 신경망 계층을 제거하여 영상의 손실을 줄여 식물 분할에 최적화된 형태로 설계한다. 컨벌루션 계층의 마지막 단에서 현재 화소에 대한 식물 유무를 판단할 목적으로 시그모이드 함수를 활성화 함수로 사용한다.

각 계층의 필터 크기와 식물체 검출에 대한 관계성을 확인하기 위해 LeafNet 구조에서 필터를 감소형(LeafNet-1), 증가형(LeafNet-2), 고정형(LeafNet-3) 세 가지 형태로 설계하고 Fig. 4에 각각 나타내었다.

#### 4. 성능 평가

##### 4.1 실험 환경

웹 크롤링 영상과 식물 모종 영상 360장이 라벨링 되어있는 훈련 데이터셋과 각 20장씩 총 40장으로 이루어진 검증 데이터셋을 사용하여 학습 가중치 모델을 얻는다. 학습 반복횟수(Epoch)는 30, 반복된 학습에 대한 가중치 업데이트 횟수(Steps per epoch)는 100으로 설정하고 학습을 진행한다. 학습 환경은 I7 8700k, 48GB RAM, RTX 2080ti 11GB 사양의 데스크톱에서 실험을 진행하였으며 총 학습 시간은 0.5시간 소요되었다.

LeafNet의 성능을 검증하기 위한 비교군으로 실험 데이터셋을 이용하여 라벨링 과정에서 생성된 이진영상, 색상 임계값 이진영상, LeafNet을 통해 검출한 이진영상을 각각 비교하여 식물과 배경의 자동 분할 가능성을 확인하였다.

##### 4.2 색상영역 기반 이진 분할

기존의 이진 분할 방법의 성능을 확인하기 위해 영상처리 오픈소스 라이브러리인 OpenCV

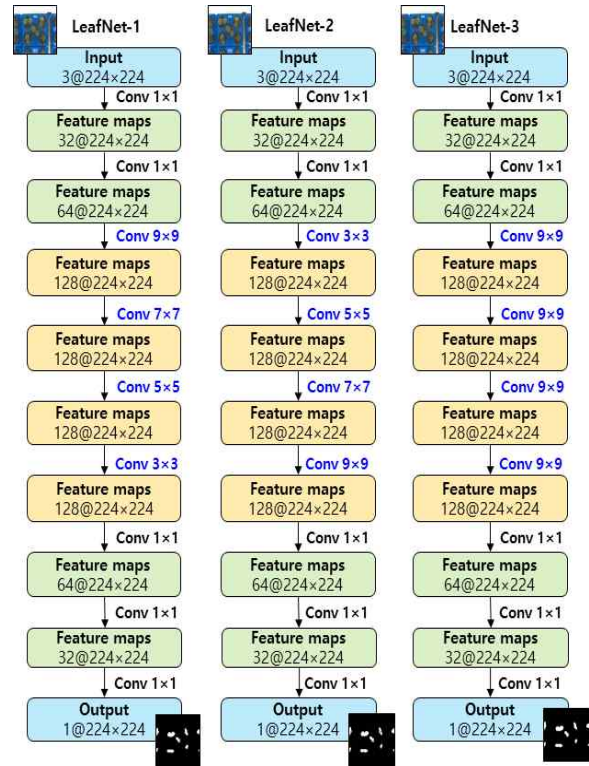


Fig. 4 Structure of LeafNet Models

[14]와 Python 3을 이용하여 색상범위의 분포를 휴리스틱(Heuristic) 기법으로 검출하고 RGB, HSV, YCbCr 영역에서 식물영역과 배경을 분할하였다. 선별한 데이터셋의 식물 영상은 녹색범위에 색상이 분포되어있기 때문에 해당범위에 맞춰서 Table 1과 같이 각 임계치를 설정하고 검출할 필요가 있다. 화소의 밝기에 민감한 RGB와 밝기 값의 영향을 감소시킬 수 있는 HSV, YCbCr 색 공간 범위에서의 식물 검출 결과를 Fig. 5에 비교하여 나타냈다.

Fig. 5(a)는 훈련 데이터셋에서 임의로 선별한 원본영상이며 Fig. 5(b)~(d)은 RGB, HSV, YCbCr 각각의 색 공간으로부터 얻어진 결과영

Table 1 Color Range of Plants in Color Space

Color space	Range
RGB	R(46~109), G(85~185), B(36~90)
HSV	H(36~70), S(0~255), V(0~255)
YCbCr	Y(0~255), Cb(90~120), Cr(110~125)

상이다. 색상 임계값을 이용하여 식물을 검출하는 경우, 빛이나 음영이 드리우는 일 부분은 잘 검출되지 않은 것을 확인 할 수 있다. 화소의 밝기 값의 영향을 크게 받는 Fig. 5(b) RGB 영상에서의 식물 검출율이 가장 낮게 나타났으며, Fig. 5(c) HSV 영상은 흙과 모종포트 지지대와 같은 범위 내의 유사색이 검출되었다. Fig. 5(d) YCbCr 영상에서의 검출이 식물을 가장 잘 검출하였으나 여전히 잎 안쪽의 그림자와 모종포트의 유사색상이 부분적으로 검출되는 것을 확인할 수 있었다.




Fig. 5 Plants Binarization Results using Threshold Values

### 4.3 정확도 비교 및 실험 결과

본 절에 사용되는 실험 데이터셋은 훈련 데이터셋과 검증 데이터셋을 구성하고 남은 200장의 식물영상으로 구성된다. LeafNet의 성능을 검증하기 위해 500×500 크기의 웹 크롤링 된 식물 영상 100장과 4,384×6,576 크기의 식물 모종 영상 100장으로 실험 데이터셋을 형성하였다.

LeafNet의 설계에 있어서, 다양한 필터 크기가 식물의 특징 검출에 어떠한 영향을 주는지 비교하기 위해 필터 크기를 변경한 LeafNet 모델에 대한 실험을 함께 진행하였다. 제안된 LeafNet 모델의 성능을 검증하기 위해 기존 이진분할 방법에서 가장 검출율이 높은 YCbCr을

이용한 결과영상과 비교하였다.

제안된 LeafNet은 컨벌루션 계층에서 필터 크기를 점진적으로 감소시키는 LeafNet-1, 점진적으로 증가시키는 LeafNet-2, 9×9 크기의 고정필터를 이용하는 LeafNet-3 세 가지 모델을 제시한다. LeafNet 모델을 통해 검출된 결과영상을 라벨링 과정에서 얻어진 이진영상의 화소 수와 비교하고 이에 따른 정밀도(Precision)와 재현율(Recall)을 식 (1)과 식 (2)를 통하여 도출하였다 [15].

$$Precision = \frac{TP}{TP + FP} \quad (1)$$

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

웹 데이터셋에 대한 정밀도와 재현율에 대한 결과를 Table 2에 나타내었다. 증가형 필터를 사용하는 LeafNet-2 모델이 정밀도 98.5%, 재현율 93.0%로 실험군 중에서 가장 높은 결과를 얻었으며, 색상 임계값을 이용한 YCbCr 결과영상보다 재현율이 2배 이상 높은 값을 보였다.

Table 2 Precision and Recall Rates on Web Images

Method	Precision(%)	Recall (%)
threshold(YCbCr)	86.6	44.9
LeafNet-1	91.3	96.5
LeafNet-2	94.1	93.0
LeafNet-3	87.7	96.1

Table 2의 시각적인 이해를 돕기 위해 라벨링 이진영상과 색상 임계값 이진영상, LeafNet 모델의 비교 결과를 Fig. 6에 도시하였다. YCbCr 색상 임계값 결과 영상은 식물의 에지 부분에 분포가 밀집되어있어 밝기나 그림자로 인해 색이 균일하지 않은 영역은 식물 영역으로 검출하지 못하는 결과를 보였다. 증가필터를 사용하는 LeafNet-2 모델이 라벨링 이진영상과 가장 유사한 형태를 보였으며 영상의 세밀한 영역을 가장 많이 유지하는 것으로 확인되었다. 감소 필터를 사용하는 LeafNet-1 모델은 LeafNet-2 모델에 비해 세밀한 영역의 검출율이 낮게 나타났

다. 9×9 고정 필터를 사용하는 LeafNet-3 모델은 동일한 필터를 이용하여 특징 맵을 추출하기 때문에 세밀한 잎이나 줄기 영역을 검출하지 못하는 것으로 확인되었다.

식물 모종 데이터셋에 대한 비교 결과를 Table 3에 나타내었다. Table 2와 마찬가지로 증가 필터를 사용하는 LeafNet-2 모델이 정밀도 98.0%, 재현율 90.3%로 실험군 중에서 가장 우수한 결과를 보였다. 9×9 고정 필터를 사용하는 LeafNet-3 모델은 정밀도 96.1%, 재현율 88.5%로 제안된 LeafNet 모델 중에서 가장 낮은 결과를 보였다. Table 2의 결과와 비교하여 Table 3의 결과는 색상 임계값 이진영상의 정밀도가 LeafNet 모델보다 높게 도출되었다. 이는 식(1)과 같이 검출한 이진 결과의 대부분이 식물영역 내부에 위치하기 때문에 정밀도가 높게 나타난다. 그러나 재현율은 식(2)와 같이 이진 결과가 영상 전체영역에서 비교되기 때문에 임계값 이진 결과는 전체적으로 LeafNet 모델보다 검출 성능이 낮은 것을 확인할 수 있다. 또한, 웹 데이터셋은 대부분 영상의 전체 화소에서 하나의 식물이 차지하는 비중이 높아 재현율이 높았으나, 식물 모종 데이터셋은 전체 화소에 여러 개의 식물이 겹쳐 나타나는 형태도 고려되어야하므로 재현율이 보다 낮게 나온 것으로 예측된다.

Table 3의 시각적인 이해를 돕기 위해 라벨링 이진영상과 색상 임계값 이진영상, LeafNet 모델의 비교 결과를 Fig. 7에 도시하였다.

YCbCr 색상 임계값 이진영상은 웹 데이터셋 결과와 같이 그림자로 인해 색이 균일하지 않은 영역은 검출이 누락되는 결과를 보였다. 식물 모종 검출 실험에서 증가 필터를 사용하는 LeafNet-2 모델이 잎의 형태를 라벨링 이진영상과 유사하게 검출하는 것을 확인할 수 있었으며 LeafNet-3 모델은 겹쳐있는 잎이나 식물의 특징을 모두 손실시켜 정확도가 떨어지는 특징을 보여 웹 데이터셋과 비슷한 결과를 보였다.

### 5. 결론

본 논문에서는 식물 표현체 연구를 위한 정밀검정시스템에 적용을 목적으로 제공되는 영상에서 식물과 배경의 자동 분할이 가능한 LeafNet을 제




Fig. 6 Plant Extraction Results on Web Images

Table 3 Precision and Recall Rates on Plant Seedlings Images

Method	Precision(%)	Recall (%)
threshold(YCbCr)	98.6	80.6
LeafNet-1	95.6	91.5
LeafNet-2	98.0	90.3
LeafNet-3	96.1	88.5




Fig. 7 Experimental Results of Proposed Method

안하였다. 정밀검정시스템은 식물체의 검출율을 높이기 위해 배경이 단순하며 규격화된 영상을 사용한다. 이러한 영상은 식물영역과 배경영역을 나누는 이진 분할을 이용하여 식물체 영역을 검출할 수 있다. 단순한 배경에서의 이진 분할을 위해 풀링 계층을 사용하지 않고 입력단과 출력단 사이에 1×1 컨벌루션 계층을 추가하여 식물체의 특징정보를 유지하는 형태로 LeafNet을 설계하였다. LeafNet의 신뢰성 검증을 위해 라벨링 과정에서 얻어진 이진영상과 색상 임계값 결과영상, 설계한 신경망의 결과영상을 비교하였다. 설계한 신경망은 필터 크기에 따른 특징 추출 관계성을 확인하기 위해 필터의 감소, 증가, 고정 세 가지 모델을 설

계하여 그 결과를 비교하였다.

실험 결과, 증가 필터를 사용한 신경망이 웹 데이터셋에서 정밀도 98.5%, 재현율 93.0%, 식물 모종 데이터셋에서 정밀도 98.0%, 재현율 90.3%을 보임으로써 기존의 색상 임계값을 이용하는 측정방법보다 성능이 높은 것으로 확인되었다. 또한, 사용자가 직접 색상영역을 변경할 필요 없이 딥러닝을 이용하여 식물과 배경의 자동 분할 가능성을 확인하였다. 필터 크기를 점진적으로 변형한 모델은 고정 필터를 사용하는 모델보다 잎의 모서리부분, 잎과 잎의 사이 등 세밀한 영역을 검출해야할 때, 보다 유용한 것으로 확인되었다. 그러나, 정밀검정시스템은 검출율을 높이기 위해 단순한 배경과 규격화된 환경에서의 영상을 중심으로 하고 있기 때문에 추후 연구에서는 본 연구를 토대로 복잡한 배경이나 유사한 특징으로 인해 검출율이 낮은 영상에서도 식물체의 검출 성능을 높일 수 있도록 하고자 한다. 본 논문에서 제안하는 LeafNet은 식물의 정밀검정시스템에서 검출하고자 하는 식물체에 대해 사용자의 직접적인 변경 없이 자동 검출이 가능하였다. 따라서, 제안된 방법이 빅데이터를 처리해야하는 검정시스템에 적용하며 보다 정확하고 빠른 결과를 도출할 것으로 기대된다.

## References

- [1] Lee, Y. H., "Establishment of National Automatic Testing System for Massive Plant Phenotype," Business Report of National Institute of Agricultural Science, Oct. 2014.
- [2] Lee, S. W., "Current Status on the Development of GM Plants Based on the Published Articles and Patents in Korea," Journal of Plant Biotechnology, Vol. 37, No. 4, pp. 394-399, 2010.
- [3] Kim, H. S., "Open S/W Development for Plant Expression Data and Its Application Plan," Proceedings on Joint Symposium on the Revitalization of Genome Breeding for Crops, Korea National Institute of Agricultural Science, June, 2019.
- [4] Choi, Y. H., Bu, K. D. and Koo, B. H., "Classification System of Fruits by Color Image Processing," Journal of the Korea Industrial Information Systems Research, Vol. 5, No. 3, pp. 65-70, 2000.
- [5] Krizhevsky, A., Sutskever, I. and Hinton, G., "ImageNet Classification with Deep Convolutional Neural Networks," Communications of the ACM. Vol. 60, No. 6, pp. 84 - 90, 2012.
- [6] Noh, T. K. and Kim, D. S., "Weed Research using Plant Image Science," Weed and Turfgrass Science, pp. 285-296, 2018.
- [7] Kim, J. H., Kim, S. K. and Shin, B. J., "Object Image Classification Using Hierarchical Neural Network," Journal of the Korea Industrial Information Systems Research, Vol. 11, No. 1, pp. 77-85, 2006.
- [8] Park, J. Y., "Relationship Between Leaf Pigment and Inhabitation Environment in Korean Native Plants," Master Thesis, Graduate School of Changwon National University, Changwon, Korea, 2011.
- [9] Lee, J. H., Kim, B. M. and Shin, Y. S., "Effects of Preprocessing and Feature Extraction on CNN-based Fire Detection Performance," Journal of the Korea Industrial Information Systems Research, Vol. 23 No. 4, pp. 41-53, 2018.
- [10] Kim, S. J., Lee, J. S. and Kim, H. S., "Deep Learning-based Automatic Weed Detection on Onion Field," Smart Media Journal, Vol. 7, No. 3, pp. 16-21, 2018.
- [11] Kang, E. C., Han, Y. T. and Oh, I. S., "Mushroom Image Recognition using Convolutional Neural Network and Transfer Learning," KIISE Transactions on Computing Practices, Vol. 24, No. 1, pp.

53-57, 2018.

- [12] Search Results for “Flowerpot” on Google. [https://www.google.com/search?q=Flowerpot&hl=ko&source=lnms&tbm=isch&sa=X&ved=0ahUKEwiw4\\_Pf\\_fzjAhXtw4sBHZKfC3cQ\\_AUIESgB&biw=1351&bih=744](https://www.google.com/search?q=Flowerpot&hl=ko&source=lnms&tbm=isch&sa=X&ved=0ahUKEwiw4_Pf_fzjAhXtw4sBHZKfC3cQ_AUIESgB&biw=1351&bih=744) (Accessed on May 10th, 2019)
- [13] Amaury Bréhéret. “PixelAnnotationTool,” <https://github.com/abreheret/PixelAnnotationTool> (Accessed on March 15th, 2019)
- [14] OpenCV, <https://opencv.org/> (Accessed on March 15th, 2019)
- [15] Olson, D. L. and Dursun, D., “Advanced Data Mining Techniques,” Springer, Berlin, Heidelberg, 2008.



**조 정 원** (Jeong Won Jo)

- 준회원
- 군산대학교 컴퓨터정보통신공학부 학부생
- 관심분야 : 머신러닝, 컴퓨터 비전



**이 민 혜** (Min Hye Lee)

- 정회원
- 군산대학교 컴퓨터정보공학과 공학사
- 원광대학교 전자공학과 공학석사
- 원광대학교 전자공학과 공학박사
- 군산대학교 컴퓨터정보통신공학부 박사 후 연구원
- 관심분야 : 영상처리, 머신러닝, 의공학



**이 홍 료** (Hong Ro Lee)

- 정회원
- 전북대학교 전기공학과 공학사
- 전북대학교 전기공학과 공학석사
- 전북대학교 전자공학과 공학박사
- 군산대학교 공과대학 컴퓨터 정보통신공학부 정교수
- 관심분야 : 객체지향시스템, GIS, 스마트시티, IoT



**정 용 석** (Yong Suk Chung)

- 정회원
- 고려대학교 원예과학학과 농학학사
- 위스콘신주립대학교 식물육종식물유전 농학석사
- 위스콘신주립대학교 식물육종식물유전 농학박사
- 제주대학교 식물자원환경전공 전임교수
- 관심분야 : 식물육종, 피노믹스



**백 정 호** (Jeong Ho Baek)

- 정회원
- 군산대학교 컴퓨터정보공학과 공학사
- 군산대학교 컴퓨터정보공학과 공학석사
- 군산대학교 컴퓨터정보공학과 공학박사
- 농촌진흥청 국립농업과학원 농업연구사
- 관심분야 : 표현체, 유전자기능, 빅데이터



**김 경 환** (Kyung Hwan Kim)

- 정회원
- 경북대학교 미생물학과 이학사
- 경북대학교 미생물학과 이학석사
- 경북대학교 미생물학과 이학박사
- 농촌진흥청 국립농업과학원 농업연구관
- 관심분야 : 표현체, 유전자기능, 지방산생합성



**이 창 우** (Chang Woo Lee)

- 정회원
- 경일대학교 컴퓨터공학과 공학사
- 경북대학교 컴퓨터공학과 공학석사
- 경북대학교 컴퓨터공학과 공학박사
- 군산대학교 공과대학 컴퓨터 정보통신공학부 정교수
- 관심분야 : 컴퓨터비전, 머신러닝, 패턴인식