

일반논문 (Reguler Paper)

방송공학회논문지 제27권 제6호, 2022년 11월 (JBE Vol.27, No.6, November 2022)

<https://doi.org/10.5909/JBE.2022.27.6.923>

ISSN 2287-9137 (Online) ISSN 1226-7953 (Print)

피노믹스 시스템을 위한 식물 잎의 질병 검출 및 분류

박관익^{a)}, 심규동^{a)}, 견민수^{a)}, 이상화^{b)*}, 백정현^{c)}, 박종일^{a)}

Detection and Classification of Leaf Diseases for Phenomics System

Gwan Ik Park^{a)}, Kyu Dong Sim^{a)}, Min Su Kyeon^{a)}, Sang Hwa Lee^{b)*}, Jeong Hyun Baek^{c)},
and Jong-Il Park^{a)}

요약

본 논문에서는 스마트팜 시스템에서 재배 중인 식물 잎의 질병을 검출하고, 질병 유형을 분류하는 방법을 제안한다. 영상으로부터 식물 잎의 컬러 정보와 질병 유형의 형태 정보를 다층 퍼셉트론(MLP) 모델을 이용하여 학습한다. 1단계에서는 입력된 영상의 컬러 분포를 분석하여 질병 존재 여부를 판단한다. 1단계의 질병 존재 가능성이 높은 영상에 대하여 2단계에서는 Mean shift clustering을 이용하여 작은 영역으로 분할하고, 각 분할된 영역 단위로 컬러 정보를 추출하여 제안한 Color Network에 의하여 질병 여부를 판별한다. 컬러 분할된 영역이 Color Network에 의하여 질병으로 판별되면, 3단계에서는 그 영역의 형태 정보를 추출하여 제안한 Shape Network를 이용하여 질병의 유형을 분류한다. 사과나무 잎과 서양 양상추(Iceberg)에서 발생하는 두 가지 대분류 유형의 질병에 대하여, 제안한 기법은 작은 영역 단위로는 92.3%의 잎 질병 검출률을 보였으며, 보통 2개 이상의 질병 영역이 존재하는 한 장의 영상 단위로는 99.3% 이상의 검출률을 보였다. 본 논문에서 제안한 방법은 스마트팜 환경에서 잎 식물의 질병 여부를 조기에 발견할 수 있으며, 대상 식물에 따른 추가 학습 없이 다양한 식물과 질병 유형으로 확대 적용이 가능하다.

Abstract

This paper deals with detection and classification of leaf diseases for phenomics systems. As the smart farm systems of plants are increased, It is important to determine quickly the abnormal growth of plants without supervisors. This paper considers the color distribution and shape information of leaf diseases, and designs two deep leaning networks in training the leaf diseases. In the first step, color distribution of input image is analyzed for possible diseases. In the second step, the image is first partitioned into small segments using mean shift clustering, and the color information of each segment is inspected by the proposed Color Network. When a segment is determined as disease, the shape parameters of the segment are extracted and inspected by proposed Shape Network to classify the leaf disease types in the third step. According to the experiments with two types of diseases (frog-eye/rust and tipburn) for apple leaves and iceberg, the leaf diseases are detected with 92.3% recall for a segment and with 99.3% recall for an input image where there are usually more than two disease segments. The proposed method is useful for detecting leaf diseases quickly in the smart farm environment, and is extendible to various types of new plants and leaf diseases without additional learning.

Keyword : Phenomics system, Leaf disease, Deep learning network, Mean shift color clustering, Shape parameters

Copyright © 2022 Korean Institute of Broadcast and Media Engineers. All rights reserved.

"This is an Open-Access article distributed under the terms of the Creative Commons BY-NC-ND (<http://creativecommons.org/licenses/by-nc-nd/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited and not altered."

1. 서론

전 세계적으로 인구가 기하급수적으로 증가하면서 식량 양식 기술과 시스템에 관한 관심도 커지고 있다. 증가하는 인구에 맞춰 대량으로 농작물을 생산하는 과정에서 각종 농작물에서 발생하는 질병은 생산량과 품질에 악영향을 준다. 이러한 상황에서 사물 인터넷, 인공지능, 빅데이터 기술의 발전으로 기존의 농산업을 정보통신기술(ICT)을 융합해 농작물의 생육 상태를 모니터링하고 질병을 예방할 수 있는 스마트팜 피노믹스 기술이 주목받고 있다^[1]. 하지만 이런 스마트팜 환경에서도 질병이 생길 수 있으므로, 우수한 상품성과 일관된 품질을 갖추기 위해 식물에 발생한 질병을 초기에 검출하고 치료하는 것이 중요하다. 사람이 직접 실시간 영상을 감시하여 질병의 발생 유무와 질병의 정도를 검출하는 것에는 큰 비용이 들며, 대규모 스마트팜일 경우에는 식물의 질병을 전문가가 육안으로 일일이 검출하는 것도 쉽지 않다. 따라서 스마트팜 피노믹스 시스템에서 식물의 질병을 자동으로 검출하는 컴퓨터 비전 기술과 그 장치 환경을 설치하는 것이 필수적인 상황이다.

식물 질병 검출 과정은 크게 이미지 전처리, 영역 분할, 특징 추출, 분류로 구분할 수 있다. 이미지 전처리 단계에서는 RGB 이미지를 색 공간으로 변환한 후 가우시안 필터(Gaussian filter), 미디언 필터(Median filter), 바이레터럴 필터(Bilateral filter)와 같은 다양한 필터를 사용하여 노이즈를 제거한다. 그다음 영역 분할 단계에서는 K-평균 군집화(K-means clustering), �츠 알고리즘(Otsu thresholding) 방법을 사용하여 식물 영역과 질병 영역을 분할하고, 이후 특징 추출 단계에서는 SIFT, LBP, HOG 방법을 사용해 질

병의 특징을 추출한다. 마지막으로 분류 단계에서는 KNN, SVM, ANN, Random forest와 같은 머신러닝 기반의 분류기를 통해 식물 질병을 분류한다^[2].

최근에는 식물 잎에 나타나는 질병을 검출하고 예측하는 합성곱 신경망(CNN) 기법의 방법론이 주목받고 있다^[3]. 이미지 분류 분야에서는 GoogleNet, VGGNet, ResNet, DenseNet 등과 같이 사전에 훈련된 네트워크 모델을 많이 사용하고, 객체 검출 분야에서는 YOLO, RCNN 등의 모델을 사용하여 식물의 질병을 검출하고 있다. 딥러닝 기법은 자동으로 이미지에서 특징을 추출하기 때문에 기존 방법에 비해 수작업이 적다는 장점이 있다. 하지만, 좋은 모델 성능을 위해서 많은 데이터를 수집하고 직접 분류해야 하는 번거로움과 모델을 적절하게 학습시키는데 평균적으로 많은 시간이 소요된다는 단점이 있다. 또한 모델의 계층 수, 학습 유형과 같은 다양한 학습 기법과 RAM, GPU와 같은 하드웨어에 따라 학습 결과가 달라질 수 있다.

본 논문에서는 식물 잎 영상을 Mean shift clustering을 통해 같은 색상을 지닌 영역을 하나의 영역으로 분할하고, 분할된 영역 단위로 색상 정보와 형태 정보를 추출하여 최종적으로 식물 잎 질병 검출 및 분류 모델을 구현한다. 기존 방법들과 달리 제안하는 방법은 복잡한 딥러닝 모델을 사용하지 않고, 간단한 다층 퍼셉트론 모델을 통해 합성곱 신경망 기법의 모델만큼 높은 정확도로 질병을 검출하고 분류한다. 또한 식물 질병이 발생한 작은 영역(Segment)을 기반으로 모델을 학습했기 때문에, 크기가 작은 질병에도 효과적으로 적용할 수 있음을 보여준다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 제안하는 식물 잎 질병 검출 및 분류 모델에 대하여 자세하게 설명하고, 3장에서는 실험 데이터셋 설명 및 학습 과정과 실험 결과를 제시한다. 끝으로 4장에서는 본 논문에 대한 결론으로 마무리한다.

II. 식물 잎 질병 검출 및 분류 모델

스마트팜 피노믹스 시스템에서 데이터를 수집하고 분석할 때, 고성능의 하드웨어와 많은 연산량이 필요하여, 모든 재배 베드를 곧바로 딥러닝 모델의 데이터셋으로 활용하기

a) 한양대학교 컴퓨터소프트웨어학과(Hanyang University, Department of Computer Science)

b) 서울대학교 뉴미디어통신공동연구소(Seoul National University, Inst. of New Media & Communications)

c) (주)케이엠씨로보틱스(KMCROBOTICS INC)

‡ Corresponding Author: 이상화(Sang Hwa Lee)
E-mail: lsh529@snu.ac.kr
Tel: +82-10-6238-9198
ORCID: <https://orcid.org/0000-0003-0228-0459>

※이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 정보통신기획지원의 ICT R&D 지원을 받아 수행된 연구임 (No.2021-0-00917, 식물 성장 영상 정보를 이용한 식물공장 피노믹스 시스템 개발)

· Manuscript September 23, 2022; Revised November 4, 2022; Accepted November 4, 2022.

는 쉽지 않다. 효율적인 피노믹스 시스템을 위하여 본 논문에서 제안하는 식물 잎 질병 검출 및 분류 모델은 크게 3단계의 과정으로 구성된다. 그림 1은 제안하는 기법의 전반적인 파이프라인을 보여준다.

1단계에서는 먼저 컬러 분포의 변화를 분석하는 질병 예측 알고리즘을 통해 식물 잎에서 질병이 검출되기 시작하는 재배 베드를 찾는다. 질병이 발생한 것으로 예측되는 식물 영상에 대해서, 2단계에서는 컬러 분할된 영역 단위로 *Color Network*를 통해 질병의 컬러 분포를 학습하여 식물 잎 영역의 질병 유무를 정밀하게 판별하고 검출한다. 3단계에서는 질병으로 판별된 영역에 대해서 그 영역의 형태 정보를 분석하는 *Shape Network*를 통해 식물 잎의 질병 유형을 분류한다.

1. 식물 잎 질병 예측 알고리즘

첫 번째 단계에서는 컬러 히스토그램 분포를 이용하여 식물에 잎 질병이 발생하였는지를 예측하는 알고리즘을 수

행한다.

우선 컬러 히스토그램 분석을 수행하기 전에 영상의 밝기 및 컬러 분포를 최대한 규격화하는 전처리 과정을 수행한다. 스마트팜 시스템에서 식물이 성장하면서 높이가 점차 변하기 때문에, 획득한 식물 잎 영상들은 각기 다른 밝기 값을 가지게 된다. 식물 잎은 빛을 직광으로 받게 될 시 화이트 밸런스의 변화가 발생하기 때문에 컬러 분포의 변화가 커져서 정확하게 질병 여부를 판별하기가 어렵다. 일정한 영상 조건에서 식물의 잎 질병을 정확하게 검출하는 것이 목표이므로, RGB 임계 값 처리를 통해 정반사된 영역이 제외된 식물 영역만을 획득하고, 사전에 충분히 촬영한 식물 영상의 RGB 평균값으로 현재 식물 영상의 밝기와 컬러를 보정하는 작업을 진행한다. 그림 2는 영상의 밝기와 컬러를 보정한 결과를 보여준다.

이제 컬러 분포와 밝기가 비교적 규격화된 보정 영상에 대하여 컬러 히스토그램을 구하고 정상인 잎의 컬러 히스토그램의 통계적 특성과 비교한다. 대부분 식물의 잎은 초록색 계열이지만, 식물 잎에서 발생한 질병은 이와는 다른




그림 1. 식물 잎 질병 검출 및 분류 모델 파이프라인
Fig. 1. Proposed pipeline of leaf disease detection and classification



그림 2. 식물 잎 영상의 밝기 보정 결과
Fig. 2. Results of brightness correction for leaf images

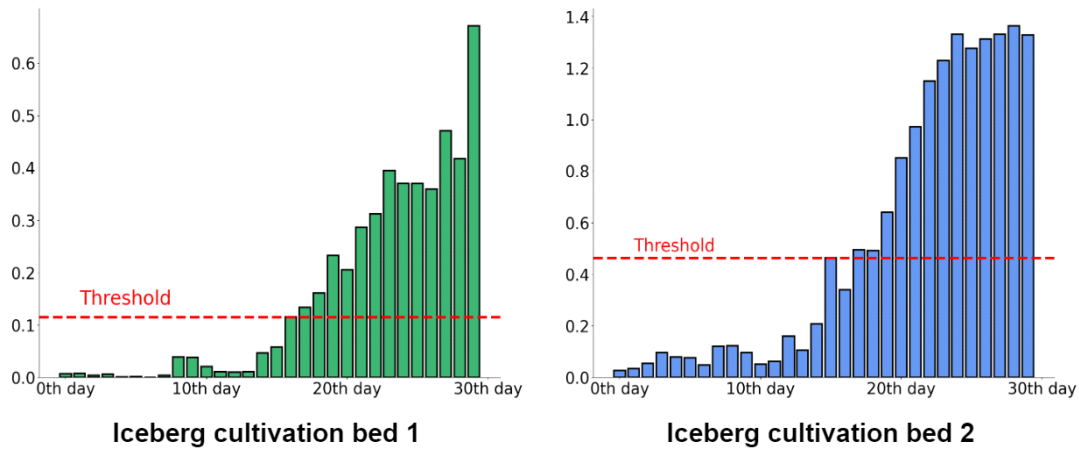


그림 3. 2개의 재배 베드에서 측정된 아이스버그의 색상 성분(H)의 히스토그램 분포
 Fig. 3. Histogram distributions of hue (H) for 2 Iceberg beds

다양한 색상을 띤다. 이러한 색상 특성을 고려하여 영상을 HSV 색 공간으로 변환한 후, 질병 영역에 해당하는 색상 값과 채도 값의 범위를 정하여 기준치를 넘는 히스토그램 분포를 갖는 영상을 판별한다.

본 논문에서 식물 잎의 질병 정도는 식물의 영역과 앞서 생성된 질병 컬러 화소의 검출 비율로 정의한다. 우선, 사전 분석을 통하여 특정한 색상 성분에 대하여 질병 발병 기준선(Threshold)을 설정하고, 이를 초과한 히스토그램을 보이면서 질병 정도가 이전 날짜보다 일정 수준(2배) 이상으로 급증하는 처음 날짜의 비율을 기준점으로 설정하고, 해당 기준점을 이틀 이상 연속으로 넘길 때 해당 식물의 잎 질병 정도가 심하다고 판별한다. 보통 잎에 확실하게 질병이 발생하면, 급격하게 질병이 확산하는 현상을 고려하여 이러한 기준을 제안한다. 그림 3은 스마트팜 시스템의 각기 다른 두 베드에서 재배한 아이스버그에서 추출한 컬러 분포를 나타낸 그래프로서, 질병이 급속하게 확산하는 현상을 잘 보여준다.

2. Color Network를 이용한 식물 잎 질병 판별

두 번째 단계에서는 앞선 단계에서 질병이 있을 것으로 예측된 영상들을 Color Network를 통해 동일한 컬러 영역 단위로 질병 유무를 판별한다. 그림 4는 컬러 영역 단위로 잎의 질병을 판별하는 과정을 보여준다. 컬러 정보 생성을 위해 먼저 입력 영상에 Mean shift clustering 작업을 수행하여 과 영역 분할된(Over-segmentation) 영상을 생성한 후, 각 영역의 대표 색상에 대하여 색상, 채도, 명도 값을 하나의 입력 벡터로 하여 다층 퍼셉트론 구조인 Color Network에서 질병 여부에 대한 학습 및 판별을 수행한다^[4]. 2단계에서는 영상 전체가 아닌 동일한 컬러를 갖는 작은 영역 단위로 질병 여부를 판별함으로써, 영상에서 잎의 질병을 검출할 뿐만 아니라, 질병 영역을 세밀하게 분할하는 기능을 동시에 수행하게 된다.

그림 5는 본 논문에서 학습한 데이터셋에서 영역별로 HSV 정보를 추출하여 건강한 식물 잎 클래스와 질병이 검




그림 4. 컬러 분할과 Color Network를 이용한 식물 질병 영역 검출
 Fig. 4. Detecting disease segments using color segmentation and Color Network

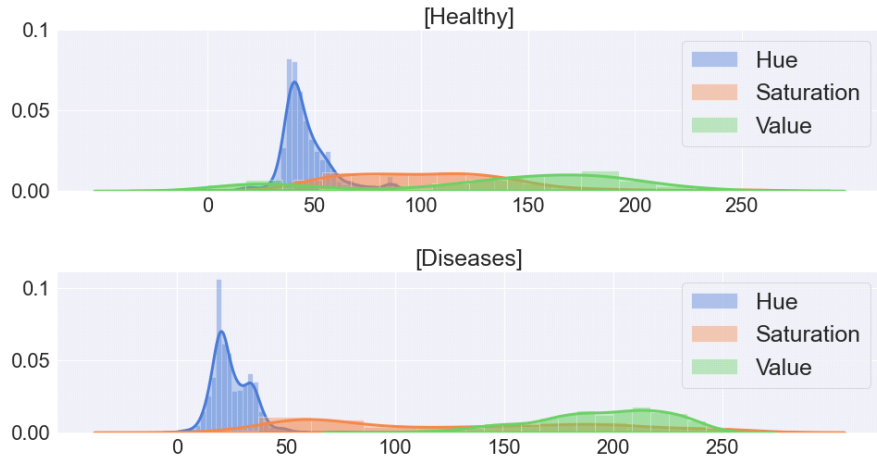


그림 5. 정상/질병 영역의 HSV 분포
 Fig. 5. HSV distribution of plant leaves for healthy and disease segments

출된 식물 잎 클래스의 HSV 분포를 보여준다. 그림 5에서 보는 바와 같이 정상 잎의 컬러 분포와 질병 잎의 컬러 분포가 매우 겹치는 것을 볼 수 있다. 이 경우, 임계 값 처리 (Thresholding)와 같은 규칙 기반 분류 기법을 적용하면 분류의 정확도가 크게 낮아지며, 의사 결정 트리(Decision tree)를 설계하는 과정에서도 어려움이 있다. 이러한 이유로, 본 논문에서는 그림 4의 과정에서 소개한 것과 같이, 3개의 컬러 정보인 색상, 채도, 명도 값을 하나의 입력 벡터로 하여 학습한 *Color Network* 모델을 사용했다.

3. Shape Network를 이용한 식물 잎 질병 분류

마지막 단계에서는 앞선 *Color Network*를 통해 질병으로 판별된 영역을 대상으로 질병의 유형을 분류한다. 그림 6은 식물 잎 질병 분류 모델의 처리 과정으로서, 입력 영상의 형태 정보를 활용하는 것을 볼 수 있다. 본 논문에서는

*Shape Network*를 통해 해당 식물 잎 질병이 사과나무에서 주로 발생하는 잎 질병인 Frogeye 또는 Rust 유형과 아이스 버그와 같은 잎채소 식물에서 주로 발생하는 잎 질병인 Tipburn 유형으로 크게 나누어 학습을 진행하였다. 일반적으로 잎의 질병 유형의 형태적인 분류는 재배 식물에 따라 크게 다르지 않으며 대상 식물에 따라 질병의 명칭이 달라지기 때문에, 이와 같은 2가지 형태를 기준으로 대분류하더라도 재배하는 식물에 따라 질병을 확인하는 데 어려움은 없다.

*Color Network*를 통하여 검출된 질병 영역에 대하여 바운딩 박스(Bounding box)를 설정하고, 해당 잎 질병 개체의 형태 정보를 추출하여 입력 데이터셋으로 사용한다. 형태 정보는 총 3가지의 파라미터로 구성되는데, 질병 영역 단위로 전체 사각 영역 대비 질병으로 표기되는 화소의 밀도, 질병 영역의 장 단축 비율, 질병 영역의 (x, y) 좌표 간의 상관계수가 이에 해당한다^[5]. 밀도는 검출된 질병의 각 바




그림 6. 식물 잎 질병 분류 모델 파이프라인
 Fig. 6. Plant leaf diseases classification model pipeline

운딩 박스 안에서 존재하는 질병 영역을 다시 4 등분하여 각각 d1, d2, d3, d4로 정의하여 세분화한다. 원형에 가까울수록 4개의 밀도 값이 균등한 밀도 분포를 가지게 되는데, 그림 7에서 보는 바와 같이 Frogeye와 Rust가 Tipburn보다 고른 분포를 갖는다는 것을 확인할 수 있다. 장 단축 비율은 질병 영역의 단축을 장축으로 나눈 값으로 정의하며, 그림 8을 통해 Tipburn 보다 Frogeye와 Rust가 원형에 가까우므로 주로 1에 가까운 분포를 나타내는 것을 볼 수 있다. (x, y) 좌표의 상관계수는 검출된 질병 영역 좌표의 상관성을 정의하며, 본 논문에서는 상관계수의 절댓값을 사용한다. 수식 (1)은 평균과 표준편차를 사용하여 구한 (x, y) 좌표

간의 상관계수를 나타낸다. 그림 9에서 보는 바와 같이 Frogeye와 Rust가 Tipburn 보다 원형에 가까우므로 상관계수가 0에 가까운 분포를 나타내며, 상대적으로 더 길쭉한 Tipburn이 1에 가까운 분포를 나타내는 것을 볼 수 있다. 이러한 형태적인 특징을 3가지 종류, 총 6개의 파라미터로 추출하여 벡터 데이터로 Shape Network에 입력을 넣고 학습 및 판별을 수행한다. 그림 10은 생성된 질병 영역 이진 마스크와 해당 바운딩 박스를 추출하는 형태 정보를 보여 준다.

$$|\rho_{xy}| = \left| \frac{E[X \cdot Y] - (E[X] \cdot E[Y])}{\sigma_x \cdot \sigma_y} \right| \quad (1)$$

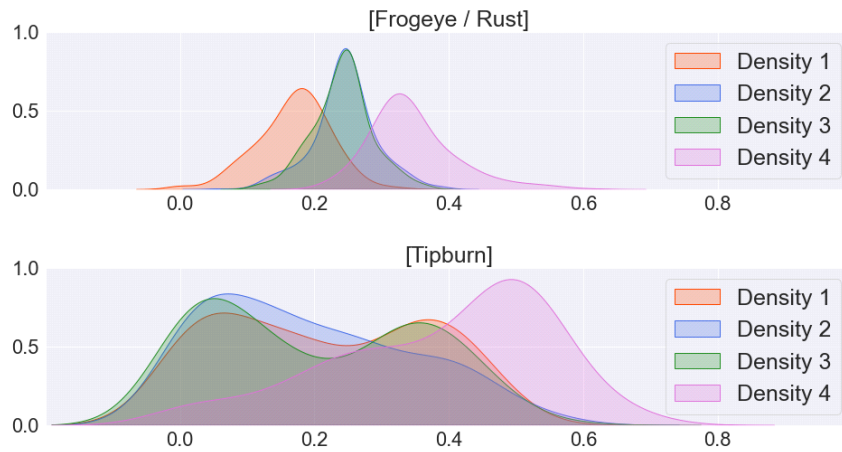


그림 7. Frogeye와 tipburn 클래스에 대한 밀도 분포
Fig. 7. Density distributions for frogeye and tipburn classes

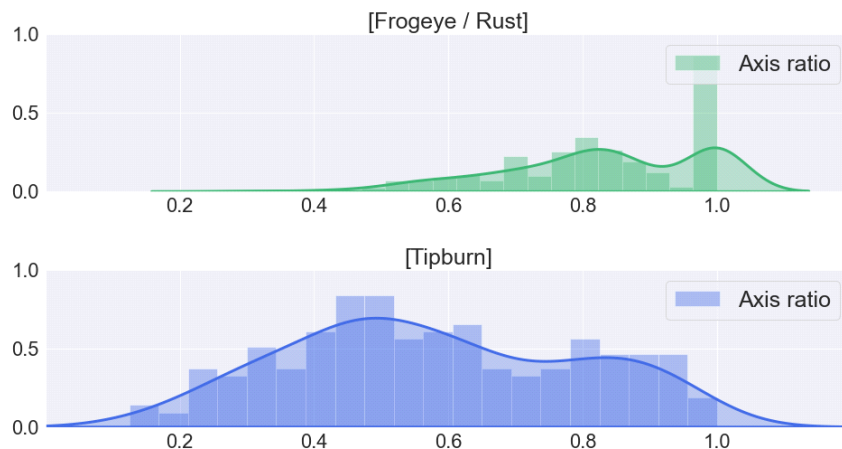


그림 8. Frogeye와 tipburn 클래스에 대한 장 단축 비율 분포
Fig. 8. Distribution of long-short axis ratio for frogeye and tipburn classes

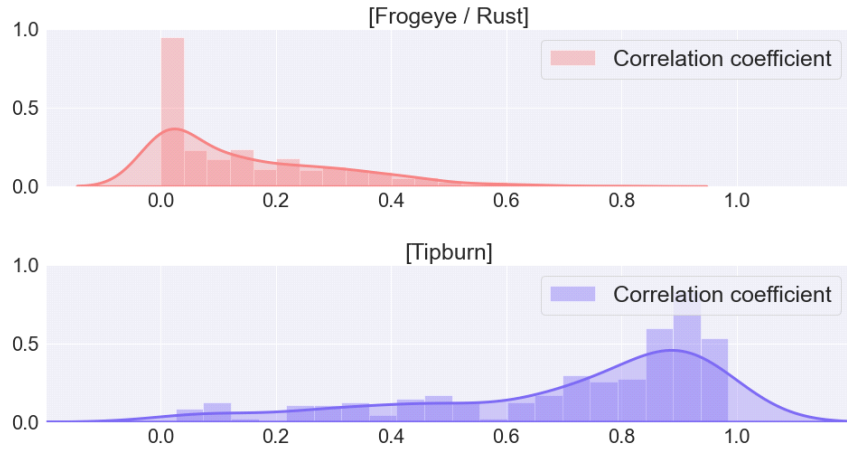


그림 9. Frogeye와 tipburn 클래스에 대한 (x, y) 좌표 상관계수 분포
 Fig. 9. Distribution of (x, y) correlation coefficients for frogeye and tipburn classes

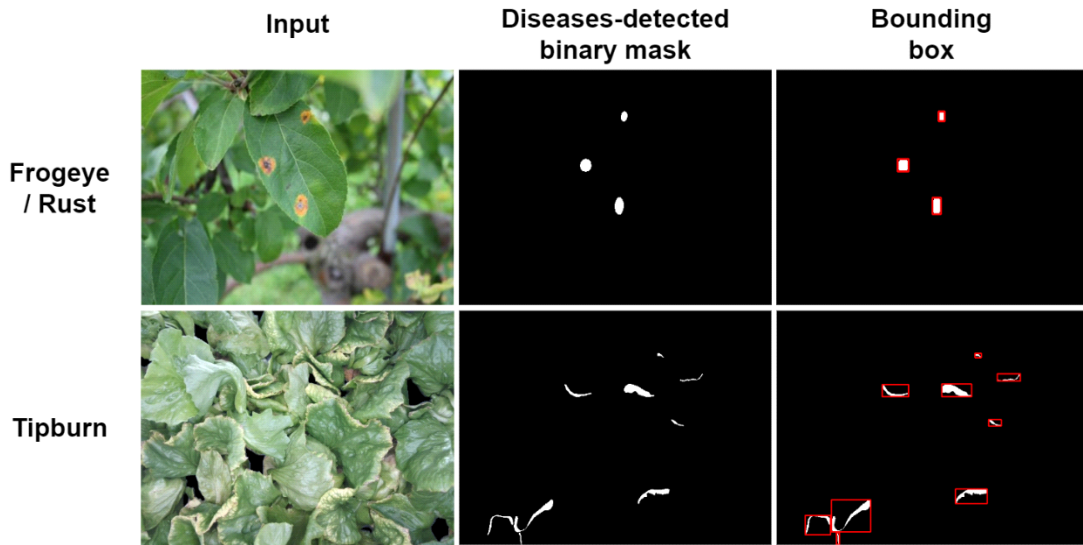


그림 10. 클래스별 질병 영역 이진 마스크와 비운딩 박스
 Fig. 10. Binary masks and bounding boxes for frogeye and tipburn diseases

4. 다층 퍼셉트론 기반의 네트워크 모델 설계

일반적인 합성곱 신경망 기반의 딥러닝 모델은 이미지 전체를 입력 데이터로 활용해 특징 정보를 추출하는데, 본 논문의 데이터셋 경우에는 식물 잎의 질병 영역이 매우 조그맣고 미세하므로 네트워크 계층을 2~3회 통과하면 특징 정보 학습이 잘되지 않는다. 또한, 합성곱 신경망 기반의 모델은 평균적으로 무거울 뿐 아니라, 많은 양의 데이터가 필요하고, 고사양의 GPU와 같은 하드웨어 시스템이 필요

하므로, 모바일 환경을 주로 이용하는 스마트팜 시스템에서는 적절하지 않다고 판단된다.

위와 같은 조건을 고려하여 본 논문에서는 5개의 은닉층으로 구성된 다층 퍼셉트론 구조의 네트워크를 설계하여 적용하였다. 제안하는 방법에서는 영상 자체를 학습하지 않고 컬러 및 형태 특징 파라미터를 추출하여 네트워크의 입력으로 사용하기 때문에 합성곱 신경망 구조는 필요하지 않으며, 간단한 다층 퍼셉트론 구조로도 컬러 정보와 형태 정보를 충분히 학습하고 판별할 수 있다. 또한, 형태 파라미

터를 모든 영역마다 추출하지 않도록 3개의 단계로 나눔으로써, 컬러 분할과 형태 파라미터를 추출하는데 소요되는 연산량을 감소시켜 하드웨어와 시간상으로 효율적인 시스템이 되도록 제안하였다.

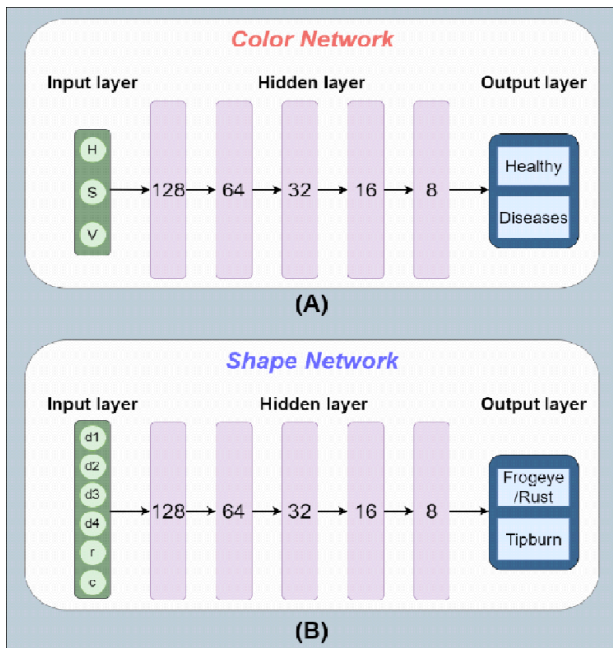


그림 11. 다층 퍼셉트론 네트워크 구조 (A) Color Network, (B) Shape Network

Fig. 11. MLP network structures (A) Color Network, (B) Shape Network

그림 11에서는 본 논문에서 설계한 다층 퍼셉트론 구조의 Color Network와 Shape Network를 보여주고 있다. Color Network의 경우 색상, 채도, 명도 파라미터를, Shape Network의 경우 밀도(d1~d4), 장 단축 비율(r), (x, y) 좌표 상관계수(c) 파라미터를 입력 데이터셋으로 사용한다. 컬러 HSV 값과 형태 파라미터 6가지는 실수값으로 입력되어 처리된다. 은닉층 후에 ReLU 활성화 함수를 사용하고, 마지막에는 Softmax 함수를 사용하여 해당 클래스를 판별 및 분류한다. 정규화 기법으로는 Dropout(p=0.2), 손실 함수로는 Categorical crossentropy, Optimizer는 Adam을 사용했다.

5. 테스트 프로세스

그림 12에서는 본 논문에서 제안하는 테스트 과정을 보여주고 있다. 1단계로 영상 전체의 히스토그램을 통해서 질병의 존재 여부를 우선으로 판단하고, 질병 가능성이 있으면 다시 작은 영역 단위로 컬러 분할하여 영역 별로 컬러 파라미터를 추출하여 2단계의 Color Network를 통해 질병 여부를 판별한다. 3단계에서는 Color Network에서 질병으로 판정된 작은 영역에 대하여 형태 파라미터를 추출하여 Shape Network를 통해 질병 유형을 분류한다.

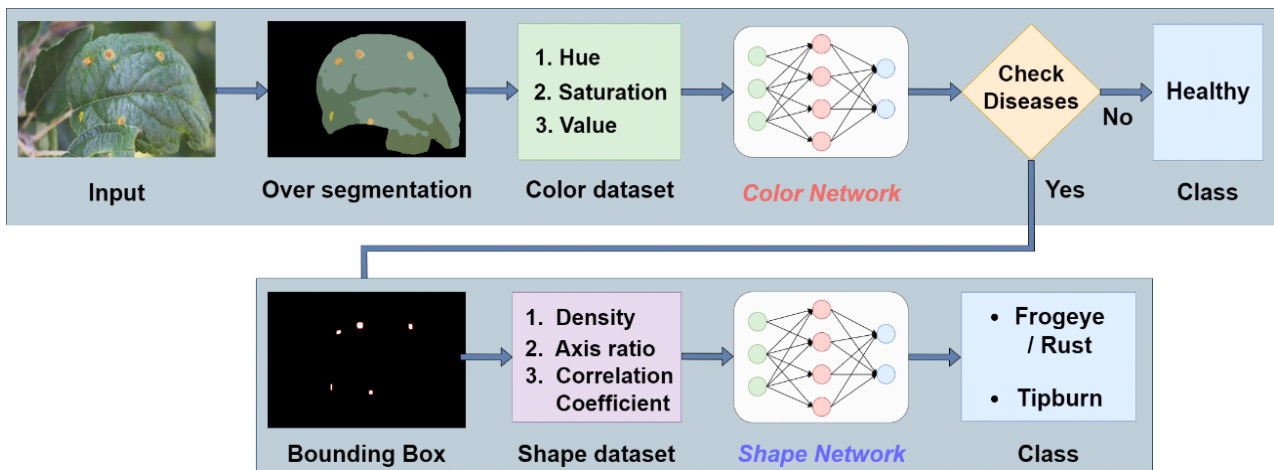


그림 12. 제안하는 방법의 테스트 과정

Fig. 12. Test process of proposed method

III. 실험 결과 및 분석

1. 실험 데이터셋

본 논문의 실험에 사용된 식물은 사과나무와 결구형 상추의 한 종류인 아이스버그로 구성하였다. 사과나무 잎 데이터는 CVPR 2021의 Plant Pathology 21-FGVC8 워크숍에서 제공하는 Kaggle competition 데이터셋으로, 본 논문에서는 사과나무 잎 질병 중 Frogeye와 Rust를 활용하여 하나의 클래스로 분류하였다, 아이스버그는 스마트팜 피노믹스 시스템에서 직접 재배한 식물로, 2022년 3월 6일부터 2022년 4월 4일까지 총 4주간 아이스버그 잎의 상부 영상을 촬영한 데이터셋으로 구성하였다.

Frogeye의 정식 명칭은 Frogeye leaf spot이며, Botryosphaeria obtusa 곰팡이에 의해 감염된 잎 질병이다^[6]. 곰팡이가 잎에 보라색 반점을 일으키면서 시작하며, 나중에는 큰 반점이 생겨서 갈색으로 변하는 특징이 있다. Rust는 복잡한 곰팡이에 의해 발생하는데, 사과나무 잎에서 가장 흔한 Rust 질병은 Gymnosporangium juniperi-virginianae 곰팡이에 의해 감염되는 잎 질병이며, 잎에 주황색 또는 노란색 반점이 나타나는 특징이 있다^[7]. Tipburn의 경우, 스마트팜 피노믹스 시스템에서 정식 후 4주쯤 영양액의 pH 값이 내려가면서 뿌리가 점차 상하기 시작하고 뿌리가 녹아 영양액과 섞이며, pH 값이 더 내려가는 악순환으로 인해 잎의 증산작용이 더딘 현상으로 인해 발생했다. Tipburn 질병은 기존의 옅은 녹색을 띠는 아이스버그에서 잎의 끝부분이 타들어 가고 갈색으로 변질하는 특징이 있다^[8].

Frogeye와 Rust는 비슷한 컬러 히스토그램 분포를 가지기 때문에 비전문가가 육안으로 분류하기 쉽지 않다. 또한 두 질병 모두 원형에 가까워서 형태 정보를 통해 분류하기도 어렵다. 따라서 본 논문에서는 두 질병을 사과나무에서 발생하는 하나의 클래스로 분류하며, 최종적으로 본 논문에서 제안하는 식물 질병 검출 및 분류 모델을 통해 사과나무 잎에서 발생하는 질병인 Frogeye 또는 Rust와 아이스버그에서 발생하는 질병인 Tipburn으로 분류하도록 학습을 진행하였다.

2. 실험 과정

본 논문의 컬러 데이터셋과 형태 데이터셋에는 각각 클래스 불균형이 존재하기 때문에, 소수 클래스를 반복해서 넣어 일종의 가중치를 증가시키는 효과를 주는 랜덤 오버샘플링(Random oversampling) 기법을 통해 데이터 비율을 맞춰 학습하였다^[9]. 표 1은 각각 분할된 컬러 데이터셋과 형태 데이터셋의 개수를 보여준다. 모델 학습의 경우 Epoch(300), Batch size(8), Patience(20), Learning rate($1e-3$)의 하이퍼 파라미터(Hyper parameter)를 설정했고, Color Network의 경우 검증(Validation) 데이터의 재현율(recall)이 최대가 되도록, Shape Network의 경우 검증 데이터의 정밀도(precision)가 최대가 되도록 학습하여 총 20번의 Patience를 초과할 시 학습이 조기 종료되고 가장 좋은 가중치를 저장하도록 진행했다.

표 1. 컬러 데이터셋과 형태 데이터셋의 분할 개수

Table 1. Number of divisions of color and shape datasets

Division	Color dataset	Shape dataset
Train	1,547	614
Validation	387	154
Test	512	142
Total	2,446	937

3. 실험 결과

Color Network는 입력된 식물 잎의 질병 유무를 판별하는 모델로, 식물 잎에 조금이라도 질병이 존재한다면 이를 효과적으로 검출하는 것이 중요하다고 볼 수 있다. 본 논문에서는 이러한 상황을 고려하여 해당 세그먼트의 HSV 값이 건강하다고 분류하더라도, 질병일 확률이 일정 임계 값을 넘을 때 질병 클래스로 판별한다. 이러한 임계 값 처리를 거치게 되면 실제 질병 클래스 중에서 모델이 질병이라고 예측한 비율인 재현율을 높일 수 있다^[10]. 표 2는 임계 값

표 2. 임계 값 처리를 통한 Color Network 재현율 비교

Table 2. Color Network recall comparison through threshold processing

Thresholding (N/Y)	Predicted (Actual)	Recall (%)
N	324 (351)	92.308
Y	331 (351)	92.458

처리 여부에 따른 질병 클래스 중에서 올바르게 분류한 표본의 비교를 보여주며, 실제로 건강 클래스의 7개의 테스트 표본이 본 논문에서 실험한 0.4의 임계 값 확률을 넘었기 때문에 질병 클래스로 재분류되었고, 이를 통해 질병 클레

스의 재현율이 92.308%에서 92.458%로 상승한 것을 확인할 수 있었다.

그림 13은 *Color Network*를 통해 검출된 각 질병 클래스의 검출 결과를 보여준다. 정답 마스크가 실제 세그먼트보

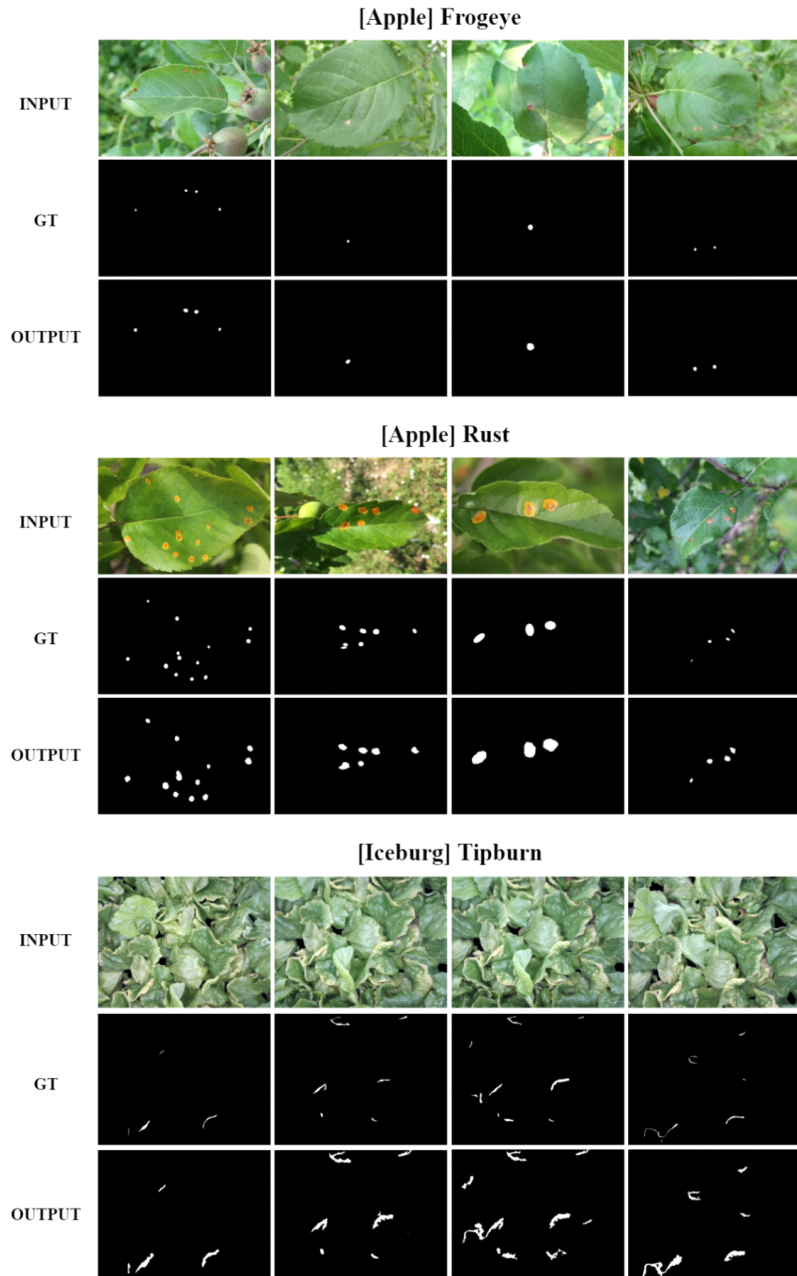


그림 13. 클래스별 입력 이미지, 정답 마스크, 질병 영역 이진 마스크
 Fig. 13. Input image, GT mask, and disease area binary mask for each class

다 좁게 라벨링 된 것에 비해, 질병으로 판별된 세그먼트의 HSV 값이 역 투영된 이진 마스크가 더욱 정확하게 질병 영역을 검출하는 것을 확인할 수 있다.

표 3은 객체인식에 널리 활용되는 YOLOv5 모델을 동일한 데이터셋으로 학습하여 본 논문의 제안 기법과 비교한 분류 평가 결과를 보여준다. *Color Network*는 식물 질병 세그먼트를 약 92%의 재현율로 검출하며, *Shape Network*는 *Frogeye*와 *Rust* 클래스와 *Tipburn* 클래스를 약 96%의 정확도로 분류하는 것을 알 수 있다. 입력 이미지에 평균적으로 질병 세그먼트가 2개 이상 존재하기 때문에, 영상을 기반으로 질병을 검사할 때 더 높은 정밀도와 재현율을 가질 수 있음을 보여준다.

표 3. 분류 평가 결과
 Table 3. Classification evaluation result

Network	Class	Scores (%)		
		Precision	Recall	F1-Score
YOLOv5	Frogeye & Rust	57.7	95.7	71.993
	Tipburn	56.3	27.9	37.31
<i>Color Network</i>	Diseases	100	92.458	96.081
	Healthy	85.083	100	91.94
<i>Shape Network</i>	Frogeye & Rust	87.5	97.674	92.308
	Tipburn	98.936	93.939	96.373

YOLOv5 모델의 경우, 두 클래스의 질병에 대해 현저히 낮은 정밀도와 재현율을 가지며, 특히나 불균형적인 형태의 틱번 질병의 경우 *Shape Network*의 재현율의 약 1/3 밖에 미치지 못하는 것을 볼 수 있다. 이는 많은 양의 데이터를 필요로 하는 YOLOv5 모델을 학습시키기에 충분치 않다고 판단되며, 본 논문의 두 네트워크는 적은 양의 데이터셋으로도 90%가 넘는 F1-Score 값을 보여 주었다.

IV. 결 론

본 논문에서는 스마트팜 환경에서 재배 중인 잎 식물의 질병 여부를 조기에 발견하고, 질병 유형을 분류하는 방법을 제안하였다. 제안한 방법에 따르면, 우선 컬러 영역 분할을 통하여 영상을 세부 영역으로 분할한 후, 각 영역 단위로

컬러 정보를 이용하여 1차적으로 질병과 정상으로 판별하고, 질병으로 판별된 영역에 대해서는 해당 영역의 형태 정보를 2차적으로 판별하여 질병 유형을 분류하였다. 잎의 컬러 정보는 HSV 색 공간에서 추출하였으며, *Color Network*라고 명명한 다층 퍼셉트론 모델을 설계하여 학습하였다. 형태 정보는 질병 영역에 대해서만 추출하였으며, 질병 영역의 4분할 영역별 밀도, 질병 영역의 장 단축 비율, 질병 영역의 (x, y) 좌표 간의 상관계수로 구성된 6가지 파라미터를 추출하여 *Shape Network*라고 명명한 다층 퍼셉트론 모델에서 학습하였다. 정상적인 잎 영역의 형태는 매우 다양하고, 형태 정보를 모든 영역에서 추출하는 데에는 많은 시간과 메모리가 필요하여 형태 정보는 질병 영역에서만 추출하여 학습 및 판별하였다. 크게 *Frogeye/Rust*와 *Tipburn*, 두 가지로 분류한 질병 유형에 대하여 사과나무 잎과 서양양상추(*Iceberg*)로 실험한 결과, 분할된 작은 영역 단위는 92.3%, 한 장의 영상 단위로는 99.2% 이상의 검출률을 보였다. 보통 영상에서는 2개 이상의 질병 영역이 존재하며, 이를 하나라도 검출하면 질병을 검출한 것으로 판정하므로, 영상 단위의 검출에서 훨씬 높은 검출률을 보인다.

본 논문에서 제안한 방법은 카메라 영상으로부터 식물 잎의 질병 유무를 자동으로 신속하게 검출하도록 하며, 유사한 질병 유형을 묶은 질병에 대해서도 분류할 수 있도록 2단계 네트워크 모델을 설정하였다. 따라서, 다양한 식물 잎의 생장 상태를 분석하는데 확대 적용이 가능하며, 컬러 정보만을 이용한 1차적인 모델 학습을 통하여 처리 속도와 하드웨어 구성에도 많은 이점을 갖고 있다. 향후 더욱 다양한 잎 질병에 대한 실험과 학습을 통하여 제안하는 기법을 검증하고, 적용 범위를 확대하고자 한다.

참 고 문 헌 (References)

- [1] Skobelev, Petr Olegovich, et al. "Development of a knowledge base in the "smart farming" system for agricultural enterprise management." *Procedia Computer Science* Vol. 150, pp.154-161, 2019. doi: <https://doi.org/10.1016/j.procs.2019.02.029>
- [2] Singh, Vijai, and Ak K. Misra. "Detection of plant leaf diseases using image segmentation and soft computing techniques." *Information processing in Agriculture* Vol4, No.1, pp.41-49, 2017. doi: <https://doi.org/10.1016/j.inpa.2016.10.005>

- [3] Jadhav, Sachin B. "Convolutional neural networks for leaf image-based plant disease classification." IAES International Journal of Artificial Intelligence, Vol.8, No.4, pp.328-341, Dec 2019.
doi: <http://doi.org/10.11591/ijai.v8.i4.pp328-341>
- [4] Comaniciu, Dorin, and Peter Meer. "Mean shift: A robust approach toward feature space analysis." IEEE Transactions on pattern analysis and machine intelligence, Vol.24, No.5, pp.603-619, May 2002.
doi: <https://doi.org/10.1109/34.1000236>
- [5] Kim, Yejin, et al. "Determination of shape parameters of sands: a deep learning approach." Acta Geotechnica, Vol.17, No.4, pp.1521-1531, Jan 2022.
doi: <https://doi.org/10.1007/s11440-022-01464-1>
- [6] Venkatasubbaiah, P., T. B. Sutton, and W. S. Chilton. "Effect of phytotoxins produced by Botryosphaeria obtusa, the cause of black rot of apple fruit and frog-eye leaf spot." Phytopathology, Vol.81, No.3, pp.243-247, 1991.
doi: <https://doi.org/10.1094/phyto-81-243>
- [7] Crowell, Ivan H. "The hosts, life history and control of the cedar-apple rust fungus gymnosporangium juniperi-virginianae schw." Journal of the Arnold Arboretum, Vol.15, No.3, pp.163-232, July 1934.
doi: <https://doi.org/10.5962/p.185310>
- [8] Macias-González, M., et al. "Genetic architecture of tipburn resistance in lettuce." Theoretical and Applied Genetics, Vol.132, No.8, pp.2209-2222, May 2019.
doi: <https://doi.org/10.1007/s00122-019-03349-6>
- [9] Mohammed, R., Rawashdeh, J., & Abdullah, M. "Machine learning with oversampling and undersampling techniques: overview study and experimental results." 11th international conference on information and communication systems (ICICS), pp. 243-248, April 2020.
doi: <https://doi.org/10.1109/ICICS49469.2020.239556>
- [10] Berger, Anna, and Sergey Guda. "Threshold optimization for F measure of macro-averaged precision and recall." Pattern Recognition, Vol.102, pp.107250-107259, 2020.
doi: <https://doi.org/10.1016/j.patcog.2020.107250>


저 자 소 개

박 관 익




- 2021년 : 한성대학교 IT응용시스템공학과 졸업(학사)
- 2021년 ~ 현재 : 한양대학교 컴퓨터소프트웨어학과 석사과정
- ORCID : <https://orcid.org/0000-0003-4491-1108>
- 주관심분야 : 영상 처리, 컴퓨터 비전, 딥러닝

심 규 등



- 2015년 : 한양대학교 융합전자공학부 졸업(학사)
- 2015년 ~ 현재 : 한양대학교 컴퓨터소프트웨어학과 박사과정
- ORCID : <https://orcid.org/0000-0001-6405-0099>
- 주관심분야 : 하이퍼스펙트럴 이미징, 색 보정, 컴퓨터 비전

건 민 수



- 2021년 : 서원대학교 정보통신공학과 졸업(학사)
- 2022년 ~ 현재 : 한양대학교 컴퓨터소프트웨어학과 석사과정
- ORCID : <https://orcid.org/0000-0002-3142-2842>
- 주관심분야 : 영상 처리, 컴퓨터 비전, 딥러닝

저 자 소 개



이 상 화

- 1994년 : 서울대학교 전자공학과 졸업(학사)
- 1996년 : 서울대학교 전자공학과 졸업(석사)
- 2000년 : 서울대학교 전자공학과 졸업(박사)
- 2005년 ~ 2011년 : 서울대학교 BK21정보기술사업단 BK조교수
- 2011년 ~ 현재 : 서울대학교 연구조교수/연구부교수
- ORCID : <https://orcid.org/0000-0003-0228-0459>
- 주관심분야 : 비디오/영상 신호처리, 패턴인식 및 자동화, 컴퓨터 비전



백 정 현

- 1997년 ~ 2022년 : 한양대학교 수학과 재학
- 2004년 ~ 2006년 : 대덕대학교 마이크로로봇 전문학사
- 2006년 : 학점은행제 전자공학 학사
- 2007년 ~ 2009년 : 한밭대학교 제어계측공학 석사
- 2006년 ~ 2007년 : D2E로보틱스 선임연구원
- 2008년 ~ 현재 : (주)케이엠씨로보틱스 연구소장
- ORCID : <https://orcid.org/0000-0002-9851-7803>



박 종 일

- 1987년 : 서울대학교 전자공학과 졸업(학사)
- 1989년 : 서울대학교 전자공학과 졸업(석사)
- 1995년 : 서울대학교 전자공학과 졸업(공학 박사)
- 1992년 ~ 1994년 : 일본 NHK방송기술연구소 객원 연구원
- 1996년 ~ 1999년 : 일본 ATR지능영상통신연구소 연구원
- 1999년 ~ 현재 : 한양대학교 공과대학 교수
- ORCID : <https://orcid.org/0000-0003-1000-4067>
- 주관심분야 : 컴퓨터 비전/그래픽스, 증강현실 가상현실, HCI