

이미지 인식 기반 국내 자생종 소나무 종 분류

신우철¹, 장동석², 홍윤식^{1*}

¹인천대학교 컴퓨터공학부, ²환경부 국립생물자원관

Image Recognition Based Classification of Native Pine Tree Species in Korea

Woo-Chul Shin¹, Dong-Seok Jang², Youn-Sik Hong^{1*}

¹Dept. of Computer Science & Engineering Incheon National University

²National Institute of Biological Resources

요약 국내 소나무과 나무는 국내 자생 침엽수의 절반을 차지할 만큼 종 다양성이 가장 높다. 소나무가 국내 산림의 60% 이상을 차지한 적도 있었지만, 현재는 재선충, 산불 등으로 그 비율이 25%로 감소하였다. 국내 자생종 소나무의 종 분류를 위해 국립생물자원관에서 보유 중인 표준 이미지 데이터셋을 사용하여 3종의 소나무를 분류하였다. 또한, 성능이 검증된 ResNet 50과 같은 사전 학습모델을 변형하는 대신 이미지 인식 모델을 직접 구현하여 종 분류를 진행 85%의 정확도를 나타내었고, 이후, 인식 과정에서 도출되는 특징들을 판별하였다. 이미지 크기 및 증식이 분류에 미치는 영향을 파악하고자 이미지 크기 및 이미지 증식을 통한 성능 평가를 수행 이미지 크기는 약 3% 그리고 이미지 증식의 경우는 약 6.4% 성능 향상을 가져왔다. 또한, 데이터 레이블링 방식의 기계학습 모델과도 분류 성능을 비교 정리하였다. 이미지 인식 과정에서 종 분류에 가중치가 높게 반영된 특징을 추출하였으며, 이를 레이블링 기법에 사용된 특징 중요도와 비교, 레이블링 기법과 이미지 인식 기반에서 종 분류에 가장 유효하게 나타난 특징은 유사한 것으로 나타났다.

Abstract Pine trees in Korea are the tree species with the highest diversity, accounting for half of the native coniferous trees. Pine trees once accounted for more than 60% of the nation's forests, but the proportion has decreased to 25% due to infestations and wildfires. To classify Korea's native pine trees, we use the standard image dataset held by the National Institute of Biological Resources to classify three species. Instead of modifying a pre-trained model like ResNet 50, which has been proven to perform well, we instead directly implement an image recognition model to perform species classification, which showed an accuracy of 85%, and then determined the features derived from the recognition process. To understand the impact of image size and growth on classification, we evaluated performance of the model through image size and image growth. The performance improvement was about 3% for image size and 6.4% for image growth. We also compare its performance with a machine learning model based on data labeling. We extract the most weighted features for species classification from the image recognition process and compare them with feature importance used in the labeling method, finding that the most effective features for species classification in the labeling method and image recognition are similar.

Keywords : Pine Tree, Image Classification, CNN, Data Labeling, Feature Importance

본 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임.

*Corresponding Author : Youn-Sik Hong(Incheon National Univ.)

email: yshong@inu.ac.kr

Received March 14, 2023

Accepted May 12, 2023

Revised April 25, 2023

Published May 31, 2023

1. 서론

소나무과(Pinaceae) 나무는 국내 자생 침엽수의 절반을 차지하여 종 다양성이 가장 높다. 국내 자생 소나무과 나무는 소나무속, 가문비나무속, 이깔나무속, 전나무속, 솔송나무속의 속하는 5속 16종이다[1]. 그러나, 산림의 60% 이상을 차지하던 소나무는 솔잎혹파리, 재선충, 산불 및 수종 갱신 등으로 인하여, 전체 산림의 25%로 감소하였다[2]. 관련 연구는 국내 소나무과 나무들의 생물 지리학적 관점에서 분류체계, 종 구성, 분포, 생태 등에 초점이 맞춰져 있다[3-5].

지금도 많은 신종 및 미기록 생물 종이 발견되고 있으며, 동·식물에 대한 종 동정·분류 판별은 매우 중요한 작업이다.

그러나, 다양한 변수와 외부요인으로 연구자와 조사자들이 종 분류에서 적지 않은 애로를 겪고 있다.

최근 국립생물자원관[6]이 보유 중인 소나무과 자료를 활용하여 소나무과 종 분류를 위해 데이터 레이블링(Labeling) 기반 기계학습을 적용한 연구를 발표하였다[7].

이 연구에서는 소나무과 나무 16종 중 5종 195개 데이터셋을 사용하였다. 그러나 식물인식분야의 대표적 학술대회인 LifeCLEF[8]의 경우 주로 휴대폰으로 촬영한 이미지를 인식하는 기술에 초점이 맞춰져 있다[8]. 또한, 실내식물 이미지 인식을 위해 사전학습 모델인 ResNet50을 기반으로 웹에서 획득한 27,785개의 이미지를 적용한 사례도 있다[9].

본 논문에서는 이미지 인식 기반 딥러닝을 적용하여 레이블링 기법에서 분류했었던 종과 동일한 소나무과 나무 종을 분류해 보고자 한다. 소나무의 경우 대한민국 국민들이 가장 친근하게 느끼는 나무이며, 전국 산림에서 25% 이상을 차지하고 있어 상당히 중요한 종이라고 볼 수 있어 채택하게 되었다.

다만 체계적 종 분류를 위해 웹에서 획득한 이미지 데이터셋이 아닌 국립생물자원관이 보유 중인 이미지 데이터셋을 사용했다. 참고문헌[8]에서 꽃, 줄기, 잎을 촬영했을 때 꽃을 이용한 이미지 분류가 성능이 가장 높았던 결과를 감안해, 이미지 인식 기반 종 분류에서 특징적인 부분들을 도출해보고자 한다.

이를 통해 다른 동·식물의 종 동정·분류 시 이미지를 통하여 분류하고자 할 때 인공지능경망 기술을 활용할 수 있는지 확인하여 도움이 되고자 한다.

또한, 선행연구[7]의 경우 데이터 레이블링 과정이 요구되어 종 분류를 진행하기 이전에 전처리 과정이 진행

되어야 하지만, 본 연구를 통하여 종 분류 시 레이블링 과정을 거치지 않고 이미지 자체를 사용하여 종 분류가 가능함을 확인하고자 한다.

본 논문은 다음과 같이 구성되어 있다. 2장 본론의 경우 본 연구의 필요성과 진행한 목적 그리고 데이터 레이블링 기법에 대한 설명이 있으며 3장 본론에서는 본 연구에서 사용한 CNN의 대한 설명과 추가적으로 과적합 방지를 위해 적용한 기법들을 설명하였다. 4장 결론에서는 본 연구에서 사용한 CNN과 다른 기법과 동시에 사용했을 때의 종 분류 시의 정확도를 표로 정리하였으며, 이후, 종 분류 시 레이블링 기법과 이미지 자체를 통해 진행했을 때 유효하게 작용한 특징점의 차이가 있는지 기술하였다.

2. 본론

2.1 연구의 필요성

소나무과는 전나무속과 소나무속으로 나눈다.

전나무속은 긴 가지만 있는 사례와 긴 가지와 짧은 가지가 함께 있는 사례도 있다. 둘 다 공존하는 경우 긴 가지에는 침엽이 1장씩 붙어있고, 짧은 가지에는 다수의 침엽이 뭉쳐있다. 소나무속은 전나무속과는 다르게 긴 가지와 짧은 가지를 함께 가지고 있으며, 긴 가지는 인편엽만으로 이루어지며, 그 액에서 나오는 짧은 가지는 인편이 있어 끝에 1~5장의 침엽이 붙어있다.

선행 연구[7]에서는 표 1과 같이 5가지 특징으로 분류한 데이터 레이블링을 통해 지도학습을 적용하였다.

Table 1. pine tree species selected with the specific features for data labeling[7]

Specific	the number of leaves	color of a tree bark	size (cm)	male flower	female flower
Pine	2	taupe	8~14	ellipse	ellipse
Black Pine	2	white	9~14	ellipse	egg-shaped
Pitch Pine	3	raddish brown	7~14	cyindrical	egg-shaped
Korean Pine	5	dark brown	7~15	ellipse	egg-shaped

본 연구에서는 데이터 레이블링 방식 대신 이미지를 사용한 분류 기법을 적용해 성능을 비교해 보고자 한다.

이미지 데이터셋은 국립생물자원관[2]에서 보유 중인 건조 표본 스캔 이미지 158개를 활용하였다.

분류 대상에서 이미지 데이터셋이 없는 곰솔은 제외하였다. CNN(Convolutional Neural Network)을 기본 모델로 구축하여 이미지 판별을 수행, 고화질이면서 이미 종 분류가 되어서 검증된 이미지 파일만을 사용하기 위하여 국립생물자원관에서 제공받은 이미지만 사용하였는데, 데이터셋이 소규모인 관계로 과적합(Overfitting) 방지를 위해 K-Fold 교차 검증 및 데이터 증식 기법을 적용하여 분류 성능을 개선하고자 하였다. 또한, 이미지 크기에 따른 분류 성능을 평가하여, 효과적 생물 종 분류 이미지 모델 구축 방안을 제시해보고자 하였다.

추가적으로, Grad-CAM을 활용하여 이미지 인식 과정에서 종 분류에 가중치가 높게 반영된 특징을 추출하여, 앞에서 분류에 주로 참고된 부위가 있는지를 확인하고, 이를 레이블링 기법에서 추출한 Feature Importance 와도 비교를 진행하여 분류에 특징적으로 작용한 부분이 있는지를 확인해보고자 하였다.

2.2 데이터 레이블링

데이터 어노테이션(Data Annotation)이라고도 하는 데이터 레이블링은 머신러닝 모델 개발 시 수행하는 데이터 전처리 단계의 일부를 뜻한다.

개발된 머신러닝 모델이 정확한 예측을 수행할 수 있도록 수집된 원시 데이터로부터 특징들을 정리한 후 해당 데이터에 하나 이상의 레이블을 추가하여, 해당 데이터에 대한 정보를 미리 학습시킴으로써, 후에 비슷한 이미지 등의 데이터를 입력받았을 때 분류할 수 있도록 해주는 것을 의미한다.

이미지 자체를 이용하여 종 분류를 진행하는 본 연구에 앞서 선행된 데이터 레이블링을 통한 종 분류[7]에서는, 스캔 이미지에 대해 소나무의 잎의 개수, 나무껍질(껍질), 잎의 길이 등을 사용해 데이터 스키마(Schema)를 구성, 이 스키마에 맞게 원시 데이터를 레이블링 하는

	A	B	C	D	E
1	sepal_length	sepal_num	pistillate_shape	staminate_shape	name
2	4.5	5	1	1	0 Pinus koraiensis
3	5	5	1	1	0 Pinus koraiensis
4	5	5	1	1	0 Pinus koraiensis
5	5.2	5	1	1	0 Pinus koraiensis
6	5.2	5	1	1	0 Pinus koraiensis
7	5.5	5	1	1	0 Pinus koraiensis
8	5.5	5	1	1	0 Pinus koraiensis
9	5.5	5	1	1	0 Pinus koraiensis
10	5.6	5	1	1	0 Pinus koraiensis

Fig. 1. samples of labeled data in CSV format

방식으로 진행 되었고, 레이블링한 데이터는 *.CSV 파일 포맷으로 저장하였다[7].

레이블링 과정이 적용된 후 저장된 데이터는 Fig. 1과 같으며, 총 4개의 특징을 가진 데이터셋으로 구성되어 있다.

각 Feature에서 sepal_length는 잎의 길이, sepal_num은 잎의 개수 그리고 pistillate_shape과 staminate_shape은 암술과 수술의 유무를 의미하며, 데이터 레이블링을 통한 선행연구에서는 이미지 수집이 완료되면, 데이터 레이블링 및 전처리를 진행, 레이블링된 자료는 최종적으로 CSV 형태의 파일로 출력되게 된다. 이후, 해당 데이터 파일을 이용하여 Table 2에서 서술된 머신러닝 알고리즘을 활용하여 반복학습을 진행하였고 학습된 데이터는 모델 파일로써 저장되며, 이후에 이루어질 새로운 종 분류 시 기준점으로써 작용, 신규 이미지 입력이 이루어지면 데이터 레이블링 도구를 활용하여 이미지 전처리 과정을 수행, 분류 예측을 통해 모델 파일과의 비교 후 최종적으로 분류 결과를 도출하는 과정을 거치게 된다.

Table 2. con and pros of the machine learning models used in data labeling[7]

Method	advantages	disadvantages
Linear regression	Speed of learning and prediction	unclear coefficient values and very difficult coefficient analysis
KNN	Easy to understand the model	Hardly used in the field
SVM	Both low-dimensional/high-dimensional behavior	Pre-processing and parameter settings required
Decision Tree	Easy to understand through visualization	Not valid for time series data
ensemble based	The most widely used algorithm	Slow training and prediction using more memory than linear models

본 연구에서는 선행연구에서 진행했던 결과에 추가적으로 각 Feature별 중요도의 추출을 진행했으며, 이를 위해 Fig. 2에 나열된 머신러닝 기법 외에 로지스틱 회귀도 추가 적용하여 Feature Importance 추출을 진행, 도출된 결과를 토대로 이미지 분류의 결과와 비교 분석하여 소나무의 종 분류를 함에 있어 유효하게 작용하는 Feature가 레이블링과 이미지 분류에서 동일하게 존재하는지 확인하는 작업을 진행해 보았다.

3. 연구 설계 및 구현 방식

3.1 CNN

CNN(Convolutional Neural Network)은 딥러닝 기반 이미지 분류 기술 분야에서 기존의 방식들보다 나은 성능을 보여주며[10], MLP(Multi-Layer Perceptron)의 변형으로 1980년대에 처음 사용된 방식이다. 기본적으로 깊은 구조를 가졌을 때 유리하다. 기본적인 구조는 인간의 두뇌에서 영감을 받아, 인간이 물체를 시각적으로 인식하고 식별하는 방식을 모델링한 것이 CNN이므로, 이미지 분석에 많이 사용된다. 또한, CNN은 적은 학습 데이터 셋의 경우에도 높은 정확도를 제공할 수 있다 [11].

기본적으로 CNN을 이미지 분류에 활용 시에는 이미지 자체를 입력 받아 Convolution과 Max Pooling 과정을 통해 필터링이 됨으로써 이미지를 분류하기 위한 특징 추출이 진행되며, flatten 을 통해 완전히 연결된 구조를 가지게 된다.

본 연구에서는 크기가 64 * 64인 이미지를 이용하여 3개의 Layer를 거쳐 필터링을 진행한 후, 과적합 방지를 위하여 Dropout 25%를 적용하여 진행했으며, 추가적으로 이미지 크기에 따른 차이도 알아보기 위하여 더 큰 사이즈인 128 * 128 사이즈의 이미지를 활용하여 추가적으로 실험을 진행, ImageGenerator를 통해 변형된 이미지도 추가 적용하여, 변형에 따른 차이도 확인해보았다.




Fig. 2. the layered architecture of the CNN

3개의 Layer와 25%의 Dropout 그리고 Flatten을 거치는 CNN의 구조도는 Fig. 2와 같으며, 이미지에서 특징 추출을 위해 진행되는 각 계층의 Filter의 모양은 Fig. 3에 나타나 있으며, 필터링 후의 이미지 파일은 Fig. 4와 같다.




Fig. 3. visualization of the last filter layer of the CNN




Fig. 4. Images generated after applying the last layer of Maxpooling

3.2 K-Fold

본 연구에서 적은 이미지 데이터셋으로 인한 과적합 방지를 위하여 사용한 방식으로, 인공지능경망을 사용한 분류 문제 처리에서도 많이 사용되는 방법이다. 데이터셋을 여러 개의 동일한 크기의 폴드(Fold)로 분할 후 각 폴드마다 한 번씩 순차적으로 Validation Set으로 활용하여 나눈 개수를 칭하는 Split의 수만큼의 학습을 진행하여 테스트 결과가 나오고, 테스트 결과의 평균을 통해 모델의 성능판별을 진행한다. 본 연구에서는 총 10개의 폴드로 분할하여 교차 검증을 진행하였고, 진행된 교차 검증은 Fig. 5와 같은 형태를 띄우게 된다.




Fig. 5. an example of 10-fold cross validation

3.3 ImageDataGenerator

이미지에 색상, 밝기 변형, 회전, 확대 등의 변형을 주어 이미지를 증식시키는 방식으로, 한정적인 데이터를 확장하여 더 높은 정확도를 얻어 낼 수 있도록 해준다. 하지만, 많은 변형을 줄 경우 원본 이미지의 형태가 무너져 의도한 결과와 다른 형태를 초래할 수 있으므로 변형을 위한 값 조절에 유의하여야 한다.

본 논문에서는 30도의 기울기 변형과, 약 6Pixel 단위로 가로와 세로를 이동, 0.8 ~ 1.2 배 만큼 이미지를 확대 및 축소함으로써 121개만큼의 데이터를 증식한 것을 Train Set에 포함해 사용하였고, ImageDataGenerator를 적용한 후의 이미지는 Fig. 6와 같다.

증식된 이미지는 Train set과 test set에 포함하여 적용함으로써 Table 3에서 CNN + ImageDataGen의 결과는 CNN 단독보다 더 많은 양의 샘플을 가지고 학습된 CNN이 분류해낸 결과이다.




Fig. 6. Images generated by applying ImageDataGenerator

3.4 Class Activation Map(CAM)

CAM은 인공신경망의 전역 평균 풀링 층의 출력과 완전 연결 층의 가중치(Weight) 정보를 활용하여 학습 결과에 따른 가중치 별 활성화 맵을 나타내는 기법이다. 하지만 CAM의 경우 전역 평균 층이 필요하다는 단점이 존재하여, 이러한 단점을 해결한 Grad-CAM을 활용하면 CAM에서 요구되는 전역 평균 층 의존도 문제 해결이 가능하다[12].

본 연구에서는, Grad-CAM을 사용하여 진행하였으며, Grad-CAM을 통해 소나무 중 분류 시 이미지의 어떤 특징적인 부분이 분류에 많이 관여하였는지 알아내어 추후, 다른 종 분류 시 이미지 전체가 필요한지 혹은 부분만이 필요한지 특정할 수 있는지 결정하기 위하여 진행하였다.




Fig. 7. the results of applying Grad-CAM to the source image (a) the Grad-CAM image heatmap (b) the result of superimposing the heatmap image on the source image.

Grad-CAM을 통하여 Heatmap을 얻어낸 후, 원본 이미지와 겹쳐 얻어낸 결과는 그림 Fig. 7과 같으며, 전체 이미지 중 한 개의 예시를 이미지로 첨부하였다.

그림을 참고하면 알 수 있듯이, 이미지 분류에 주요하게 작용한 부분은 잎의 시작 부분, 즉 잎의 뿌리쪽에 많은 특징이 추출된 모습을 확인할 수 있다.

이미지 상의 Heatmap을 육안으로 해석해보면, 잎의 뿌리부분에서 특징적으로 받아들일 수 있는 부분은 잎의 개수(가지 수)로 해석해 볼 수 있는데, 이는 선행연구[7]에서 sepal_num의 열로 이미 들어가 있어, sepal_num이 이미지 분류의 결과와 유사하게 가장 유효한 Feature로써 작용하였는지 알아보기 위해 레이블링 기법에서 사용된 각 Feature들의 importance를 추출해보았다.

4. 결과

4.1 분류 성능 비교

데이터셋은 소나무과에 속하는 소나무, 리기다 소나무, 잣나무 등 총 3종의 데이터를 이용, 158개의 이미지 파일을 사용하였다.

Train Set과 Test Set은 8대 2의 비율로 나누어 진행하였으며, 방식에 따라 편차는 존재하지만 평균 약 85% 내외의 정확도를 보여줬으며, K-Fold의 경우 10 split의 Accuracy의 평균값을 정확도로 작성하였다.

기본적으로 별다른 변형 없이 CNN 단일로 분류를 진행하는 것보다 K-Fold를 통한 교차 검증 혹은, ImageDataGenerator를 통해 데이터를 증식하여 진행하는 것이 좀 더 나은 결과를 보여주는 것을 Table 3의 Accuracy를 참고하면 알 수 있다.

또한, 이미지 크기의 영향을 알아보기 위하여

128 * 128 크기로 추가 실험을 진행해 보았으며, 기

존 64 * 64 보다 정확도가 약간 증가한 것으로 보아, 크기에 따른 영향은 존재한다고 볼 수 있다.

Table 3. Accuracy comparison for the 6 models

Data Labeling	Accuracy	Image Classification	Accuracy	Size (Image)
SVM	97.8%	CNN	82.4%	64*64
			85.0%	128 *128
KNN	100.0%	CNN + K-Fold	88.0%	64*64
			89.8%	128 *128
Random Forest	97.9%	CNN + Image-DataGen	88.8%	64*64
			94.4%	128 *128

4.2 Feature Importance 추출

CNN을 통한 이미지 분류를 통해 추출된 특징을 보면 잎의 시작점, 즉 가지가 갈라지는 기점과 잎의 수가 정해지는 시점으로 보이는데, 이는 “잎의 수가 유효한 Feature로써 작용한다” 라는 관점으로도 생각해볼 수 있다. 이를 확인해보기 위하여 레이블링 된 데이터를 이용하여 분류를 진행하였던 선행연구[7]에서 사용한 머신러닝 기법 중 Random Forest에서 추출을 진행, 추가적으로 Logistic Regression도 활용하여 추출해봤다.




Fig. 8. the feature importance

본 연구에서 Feature Importance는 각 변수가 종 분류 시 얼마나 자주 사용되었는지를 나타내는 값이다. 각 Feature별 Importance를 추출해 본 결과, Logistic Resression에서 Feature Importance는 Fig. 8 과 같으며, 가장 유효하게 작용한 Feature는 이미지 분류의 결과를 보고 생각한 바와 같이 잎의 개수가 유효하게 작용한 것으로 확인됐다.

또한, Random Forest에서도 각 Feature별 importance를 추출해본 결과 sepal_length 부터 차례로0.13970921, 0.5487987, 0.1643114, 0.14718069로 출력되어 sepal_num이 가장 유효하게 작용된 Feature로 나타났다.

5. 결론

본 논문에서는 인공지능망 기술인 CNN을 식물 종 분류에 이용함으로써, 자주 이용되는 붓꽃 데이터 레이블링 분류 방식을 따라서 다른 종의 분류를 진행하지 않고, 이미지 자체로 분류가 가능함을 확인하기 위해 진행하였다. 대표적으로 소나무의 종 분류를 진행, CNN 단독으로 사용시에는 약 85%의 정확도로 크게 높은 정확도를 보이진 않았으나, Table 3의 결과를 보면 이미지의 크기 변경과 증식기법을 통한 이미지양의 증가가 수반되면 94.4%까지 정확도가 상승하여 유의미한 증가량과 더욱 좋은 결과를 나타냈다.

이는, 원본 데이터셋의 수가 많지 않을 경우 원본 데이터셋으로 분류를 진행하는 것보다 교차검증과 이미지 증식을 통해 분류를 진행하였을 때 더 나은 값이 나타나는 것으로 보아 데이터의 양이 더 많으면 좋은 결과를 낼 수 있을 것으로 판단되며, 특징 추출을 시각화하기 위하여 진행된

Grad-CAM의 결과를 참조하여 다른 식물의 종 분류 시 잎을 사용할 경우 잎의 전체를 사용하여도 무방하지만 잎의 시작점을 특정지어 사용하여도 좋은 결과를 나타낼 수 있을 것으로 보인다.

또한, 이미지 분류에서 추출해 낸 Heatmap의 유효성을 확인하기 위하여, Heatmap의 해석을 진행, 잎의 시작점 즉 잎의 개수가 확정되는 시점임을 착안하여 레이블링 기법에서 sepal_num으로써 이미 선언되어있는 Feature임을 확인, 각 Feature별 Importance도 추출해본 결과, 레이블링 기법에서 또한 잎의 개수가 가장 유효하게 작용된 것으로 확인되었다.

이를 통해 추후, 다른 동 · 식물의 종 분류 시 충분한 양의 데이터셋이 확보가 된다면, 이미지의 전체가 아닌 특정 부분만을 사용해도 분류를 진행할 수 있음을 확인하였고, 레이블링 기법에서 Feature Importance를 추출한 결과와 이미지 분류기법을 비교 분석해본 결과, 두 방법에서 유효하게 작용된 Feature가 중첩된 것으로 보아, 동 · 식물의 종 분류 시 레이블링 기법이 아닌 이미지 자체 분류를 진행하는 것이 유효함을 확인할 수 있었다.

References

- [1] W. S. Kong. "Species Composition and Distribution of Native Korean Conifers.", *Journal of the Korean Geographical Society*, 39.4 (2004): 528-543.
- [2] Y. W. Jeon, "Our pine tree that we really need to know.", Hyeonam Temple, 2004.
- [3] W. S. Kong. "Biogeography of Native Korean Pinaceae." *Journal of the Korean Geographical Society*, 41.1 (2006): 73-93.
- [4] S. M. Lee, M. H. Ho "Vegetation Status and Characteristics of the Spatial Distribution in Taeanhaean National Park", *Korean Journal of Ecology and Environment*, 48.2 pp.122-128 (2015) : 122.
DOI: <https://doi.org/10.11614/KSL.2015.48.2.122>
- [5] J. Y. Lee, J. G. Oh, S.H. Jung, H.S. Kim. "Community Distribution on Mountain Forest Vegetation of the Geumsusan and Doraksan Area in the Worak National Park, Korea." *Korean Journal of Ecology and Environment*. Korean Society of Limnology, June 30, 2015.
DOI: <https://doi.org/10.11614/KSL.2015.48.2.129>
- [6] National Institute of Biological Resources,
<https://www.nibr.go.kr/>
- [7] D. S. Jang. "A Classification of Native Pine Trees using Data Labeling and Random Forest." Graduate School of Information Technology, Incheon National University, Korea's master's degree thesis, 2022. Incheon.
- [8] H. Goeau, P. Bonnet, and A. Joly, "Plant Identification Based on Noisy Web Data: the Amazing Performance of Deep Learning", *Conf. Labs Evaluation Forum*, pp. 1-13, 2017.
- [9] H. J. Shin, S. I. Lee, H. W. Jeoung, J. W. Park, "Indoor Plants Image Classification Using Deep Learning and Web Application for Providing Information of Plants", *Journal of Knowledge Information Technology and Systems (JKITS)*, vol.15, no.2, pp.167-175, 2020.
DOI: <https://doi.org/10.34163/JKITS.2020.15.2.002>
- [10] B. M. Kim, "Image Classification Technology Based on Deep Learning", *The Journal of The Korean Institute of Communication Sciences*, 35(12), 8-14. 2018.
- [11] Ahlawat, S., Choudhary, A., Nayyar, A., Singh, S., & Yoon, B. (2020). Improved handwritten digit recognition using convolutional neural networks (CNN). *Sensors*, 20(12), 3344.
DOI: <https://doi.org/10.3390/s20123344>
- [12] Y. J. Ji. "Decomposition of mixed defect pattern in wafer bin map via Grad-CAM(Gradient-Class Activation Map)", Graduate School of Hanyang University with a Master's Degree in Korea, 2021, Seoul.

신 우 철(Woo-Chul Shin)

[준회원]



- 2021년 2월 : 세명대학교 컴퓨터학부 소프트웨어학 (이학사)
- 2021년 8월 ~ 현재 : 인천대학교 컴퓨터공학과 석사과정

<관심분야>

인공지능, 헬스케어, 사물인터넷

장 등 석(Dong-Seok Jang)

[정회원]



- 2022년 2월 : 인천대학교 컴퓨터공학 (공학석사)
- 2022년 9월 ~ 현재 : 인천대학교 컴퓨터공학과 박사과정

<관심분야>

인공지능, 가상화, 블록체인

홍 윤 식(Youn-Sik Hong)

[정회원]



- 1983년 2월 : 한양대학교 전자공학과 (공학석사)
- 1989년 2월 : 한국과학기술원(KAIST) 전기 및 전자공학과 (공학박사)
- 1989년 3월 ~ 1991년 7월 : LG 전자(주)우면연구소 선임연구원
- 1998년 3월 ~ 1999년 12월 : LG정통신(주)단말연구소 자문교수
- 1991년 8월 ~ 현재 : 인천대학교 컴퓨터공학부 교수

<관심분야>

모바일 컴퓨팅, 사물인터넷, 헬스케어