

Deep Learning Based Tree Recognition rate improving Method for Elementary and Middle School Learning

Jung-Eun Choi*, Hwan-Seung Yong**

*Student, School of Software Education, Ewha Womans University, Seoul, Korea

**Professor, Dept. of Computer Science & Engineering, Ewha Womans University, Seoul, Korea

[Abstract]

The goal of this study is to propose an efficient model for recognizing and classifying tree images to measure the accuracy that can be applied to smart devices during class. From the 2009 revised textbook to the 2015 revised textbook, the learning objective to the fourth-grade science textbook of elementary schools was added to the plant recognition utilizing smart devices. In this study, we compared the recognition rates of trees before and after retraining using a pre-trained inception V3 model, which is the support of the Google Inception V3. In terms of tree recognition, it can distinguish several features, including shapes, bark, leaves, flowers, and fruits that may lead to the recognition rate. Furthermore, if all the leaves of trees may fall during winter, it may challenge to identify the type of tree, as only the bark of the tree will remain some leaves. Therefore, the effective tree classification model is presented through the combination of the images by tree type and the method of combining the model for the accuracy of each tree type. I hope that this model will apply to smart devices used in educational settings.

▶ **Key words:** Machine Learning, Deep Learning, Convolutional Neural Network, CNN, Inception V3, Smart Device Education

[요 약]

본 연구의 목적은 수업 시 스마트기기에 적용할 수 있는 나무 이미지를 인식하고 분류하여 정확도를 측정할 수 있는 효율적인 모델을 제안하는 것이다. 2015개정 교육과정으로 개정되면서 초등학교 4학년 과학교과서의 학습 목표에서 스마트 기기 사용한 식물 인식이 새롭게 추가 되었다. 특히 나무 인식의 경우 다른 사물 인식과 달리 수형, 수피, 잎, 꽃, 열매의 부위별 특징이 있으며, 계절에 따라 모양 및 색깔의 변화를 거치므로 인식률에 차이가 존재한다. 그러므로 본 연구를 통해 컨볼루션 신경망 기반의 사전 학습된 인셉션V3모델을 이용하여 재학습 전 후의 나무 부위별 인식률을 비교한다. 또한 각 나무의 유형별 이미지 정확도를 결합시키는 방식을 통해 효율적인 나무 분류 방안을 제시하며 교육현장에서 사용하는 스마트기기에 적용 할 수 있을 것이라 기대한다.

▶ **주제어:** 머신러닝, 딥러닝, 컨볼루션 신경망, 인셉션V3, 스마트기기교육

-
- First Author: Jung-Eun Choi, Corresponding Author: Hwan-Seung Yong
 - *Jung-Eun Choi (stella.choi35@ewhain.net), School of Software Education, Ewha Womans University
 - **Hwan-Seung Yong (hsyong@ewha.ac.kr), Dept. of Computer Science & Engineering, Ewha Womans University
 - Received: 2019. 10. 10, Revised: 2019. 12. 11, Accepted: 2019. 12. 13.

I. Introduction

알파고는 제 4차 산업혁명을 가능케 한 핵심 기술이 바로 인공지능이라는 것을 전국민에게 강하게 각인시켰다. 인공지능이 우리 삶의 방식을 근본적으로 바꿀 것을 예고한 것이다. 이러한 시대의 변화에 맞추어 교육의 목표, 내용 및 방법에서 혁신이 있어야 한다[1]. 이에 따라 정부는 2015년 교육 과정을 개정하면서 소프트웨어 교육을 강화할 것을 표명하고 2018년부터 실시하기로 하였으며[2], 소프트웨어교육 뿐만 아니라 수업에 사용되는 교구 또한 시대에 따라 변화하는 것을 2015년 개정교과서에서 확인 할 수 있었다[3].

2015년에 개정된 초등학교 4학년 과학교과서에는 식물을 생김새에 따라 분류해 보는 단원이 있다[3]. 2009년 개정 이전 교과서에서는 같은 단원 주제에 대해 눈과 돋보기를 이용해 식물을 분류 하도록 학습목표가 제시되었다면[4], 2015개정 교과서에는 여러 가지 식물을 눈으로 관찰할 뿐만 아니라 스마트 기기를 이용하여 종류별로 분류 하도록 방식이 추가되었다[3]. 시대의 변화에 따른 스마트기기의 도입에 대하여 학교에서 스마트 교육의 수행에 대한 긍정적인 분위기가 조성되어 있으며, 스마트 교육을 통해 기존과는 다른 교육이 가능 할 것을 기대할 수 있다[5]. 그러므로 본 연구에서는 과학 수업시간에 학생들이 스마트기기를 이용하여 식물판단에 이용할 수 있도록 컨볼루션 신경망(CNN)을 활용한 나무 인식 및 분류를 수행해 보고자 한다.

최근 딥러닝(Deep Learning)을 이용한 연구가 활발히 진행되고 있다. 딥러닝의 한 종류인 컨볼루션 신경망(CNN)에서는 Alexnet, VggNet, GoogleNet등이 나왔으며, 이 모델들을 이용하여 영상 분류(Image Classification) 및 사물인식, 질병판단(의학분야), IoT센서(산업분야)와 같이 다방면에 활용되고 있다[6-9].

또한 기존의 식물 인식을 시도한 유사 어플리케이션을 테스트해 본 결과 성능이 기대에 못 미친다는 한계점이 존재 하였다[10-12]. 특히 나무의 잎, 꽃, 열매는 계절에 따라 형태, 색깔 및 존재 유무가 변화 하므로 인식률에 차이가 존재하며, 잎이 모두 떨어지는 겨울에는 이미지 판별에 어려움이 있다. 본 연구에서는 이러한 점들을 개선하여 사계절 존재하는 나무 수피를 이용하여 계절에 관계없이 나무 종류를 판별 할 수 있도록 딥러닝 기술을 교육적 목적으로 사용하여 나무 수피 이미지 인식과 나무 분류 성능 향상방안에 초점을 맞추어 실험을 수행하였다.

II. Preliminaries

1. Related works

1.1 Study of existing image recognition model

기존의 사물인식 및 질병판단에서는 특징을 가지는 이미지 한 장을 이용하여 이미지를 판단하는 경우가 대부분이었으며[7][8], 입력된 이미지 한 장으로 전체적인 패턴과 형태를 분석하여 사물을 판단하는 기존의 유사한 어플리케이션들의 성능을 테스트하여 비교한 결과 Table 1.과 같았다.

초·중·고 교과서에 수록되어 있는 나무 25종 중 상위 8종(감나무, 느티나무, 단풍나무, 밤나무, 뽕나무, 사과나무, 소나무, 은행나무)의 총 40장의 이미지에 대하여 테스트를 진행하였으며, 특히 수피 이미지 정확도와 같이 나무의 종류를 판단하기에 다소 인식률이 부족한 경우가 존재하였다.

따라서 부족한 인식 정확도를 보완하기 위하여 나무의 각 부위별 이미지 정확도를 결합하여 나무의 인식률을 향상 시키는 방안을 제안한다.

Table 1. Comparison of Image Recognition Accuracy of Similar Applications According to Feature

Feature	Picture ThisAI	PlantSnap	Naver Smart Lens
Shape of tree	62.5%	50%	62.5%
Bark	37.5%	0%	0%
Leaf	75%	75%	25%
Flower	75%	75%	25%
Fruit	50%	62.5%	62.5%

1.2 Convolutional Neural Network(CNN) and Inception V3 Model

컨볼루션 신경망(CNN)은 사람이 직접 분석하기 어려운 수많은 데이터베이스에 대해 최적의 특징 추출 및 분류를 자동으로 수행하는 머신러닝(Machine Learning)으로, 본 연구에서는 최근 새로운 모델을 만들 때 기본 틀로 사용되는 컨볼루션 신경망 중의 하나인 인셉션V3(InceptionV3) 모델을 Fig 1.과 같이 적용하였다[6].

인셉션V3는 기존의 이미지 분류 기술인 CNN 기술에 망의 크기를 늘려 성능을 향상 시킨 기술을 말하며[13], ImageNet 데이터베이스의 백만 개가 넘는 이미지들에 대해서 사전학습(Pre-trained) 된 컨볼루션 신경망으로 이미지를 키보드, 마우스, 연필 및 각종 동물 등의 1000가지

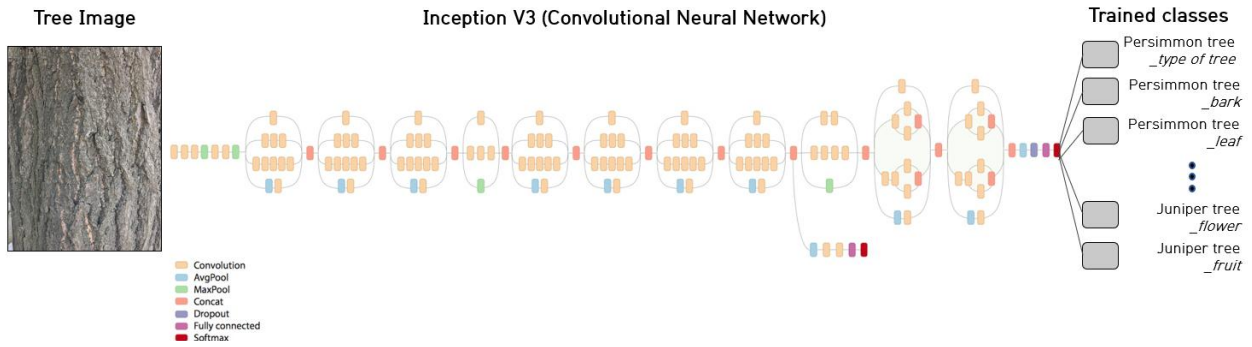


Fig. 1. Structural example applying bark image to convolutional neural network (CNN) Inception V3 model

이상의 사물 범주로 분류가 가능하다는 특징을 가진 모델이다. 네트워크 이미지의 입력크기는 299x299 픽셀(pixel) 사이즈의 RGB 이미지를 취급하며, 네트워크의 재학습(Re-training)이 가능하므로 본 연구에서는 재학습 전인 사전학습 상태와 재학습 후 상태에서의 나무 분류 성능을 비교 분석하였다.

III. The Proposed Scheme

1. Analysis of tree data of elementary, middle and high school textbooks

학습에 적용할 나무 종류를 분석하기 위해 초등학교, 중학교, 고등학교의 과학 교과서를 중심으로 조사하였다. 교과서 분석날짜를 기준으로 2015 개정 교육과정에 의해 개발된 교과서가 출판 이전인 학년에 대해서는 2009 개정 교육과정에 의해 개발된 교과서에 대해 분석을 실시하였다.

초등학교 통합교과서(1-2학년)와 과학교과서(3-6학년)

에 수록 되어 있는 나무를 조사한 결과 24종이 교과서에 수록 되어 있었다. 상수리나무와 떡갈나무는 같은 참나무과에 속하므로 참나무(oak tree)로 통일하여 Table 2.와 같이 총 22종으로 정리하였다.

중학교 과학1, 과학3 교과서에서는 12종의 나무가 수록되어 있었으며, 눈잣나무(pinuspumila)는 잣나무(nutpine)와 생김새가 매우 흡사하므로 잣나무(nutpine) 1종으로 통일하였다.

고등학교 생명과학1 교과서에서는 9종의 나무가 조사되어 최종적으로 교과서에 수록 된 나무의 종류는 Table 3.에서와 같이 최종 25종으로 정리 되었다.

추가적으로 교과서에 수록되어 있는 일반적인 나무 종류 이외에 주변에서 쉽게 볼 수 있는 꽃나무와 가로수 9종을 추가하여 학습에 적용할 나무 종류를 34종으로 구성하였다.

2. Collect training data set

컨볼루션 신경망 학습을 위해 나무 이미지를 수집하여 나무 학습 데이터셋(Data set)을 구축하였다.

34종에 대하여 Table 4.의 예시 이미지에서와 같

Table 2. Analysis of Tree species in Elementary, Middle and High School Textbooks

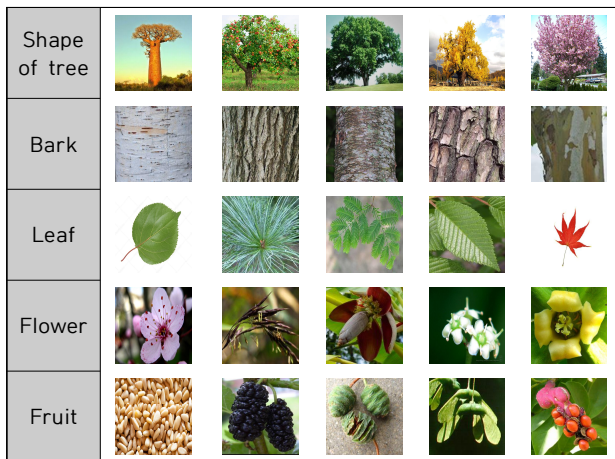
School	Revision Year	Textbook	Tree species
Elementary School	2015 revision	Grade 1-2 Integrated Textbook	24 Kinds of trees (The final 22 Kinds of trees)
	2015 revision	Grade 3-4 Science Textbook	
	2009 revision	Grade 5-6 Science Textbook	
Middle School	2015 revision	Science 1	12 Kinds of trees (The final 11 Kinds of trees)
	2009 revision	Science 3	
high school	2015 revision	Biology 1	9 Kinds of trees

Table 3. Tree species in tree dataset (34 species in total)

25 Kinds of trees in textbooks	Adansonia, Apple tree, Bamboo, Banana tree, Birch tree, Camellia, Cherry tree, Chestnut tree, Elm tree, Ginkgo tree, Grapevine, Juniper tree, Mangrove, Maple tree, Mesquite tree, Mulberry tree, Nutpine, Oak tree, Orange tree, Pear tree, Persimmon tree, Pine tree, Spindle tree, Willow tree, Zelkova tree
9 Additional tree Kinds	Azalea, Chionanthusretusus, Cornus Officinalis, Forsythia, Magnolia, Metasequoia, Platanus, Poplar, Royalazalea

이 환경에 따른 특징을 지닌 나무의 전체 모양을 뜻하는 수형(樹形), 나무의 껍질을 가리키는 수피(樹皮), 잎, 꽃, 열매의 총 5가지의 각 유형별로 구글(Google)과 네이버(Naver)에서 웹검색을 통해 이미지를 수집하였다.

Table 4. Data set example image(Type of feature)



주로 구글 이미지 검색을 통해 1,858장, 네이버 이미지 검색에서는 1,507장을 수집하였다. 쉽게 학교주변과 공원에서 접할 수 있는 은행나무·벚나무·단풍나무·소나무·목련·철쭉·개나리·동백나무는 직접 사진을 찍어 886장의 이미지를 데이터셋에 추가하였다.

최종적으로 Table 5.와 같이 4,251장의 나무 유형별 이미지 데이터셋을 구성하였다.

Table 5. Number of images in the tree dataset by feature

Feature	Number of Images
Shape of tree	775
Bark	1,025
Leaf	761
Flower	976
Fruit	714
Total	4,251

3. Recognition performance of improvement technique by combining accuracy of each tree part

기존의 유사한 기능을 가진 어플리케이션들을 분석한 결과 대부분에서 이미지 1장을 이용해 판별하는 방식을 적용하였다. 하지만 나무 같은 경우 크게 수형(樹形)·수피(樹皮)·잎·꽃·열매의 5가지의 다양한 유형이 존재한다는 특징이 존재한다. 그러므로 한 나무에 대하여 수피의 정확도가 떨어지는 경우 다른 부위별 유형 이미지를 여러 장을 추가로 제시할수록 판별 정확도를 향상시킬 수 있을 것으로, 본 연구에서는 판별 정확도 향상을 위해 여러 부위의 이미지 판별 정확도를 결합하는 방식을 제안한다.

정확도의 결합은 결합신뢰도 계산 공식에 적용하여 결합 정확도(Combined accuracy)를 도출한다.

결합신뢰도란 어떤 규칙이 추론 결과로 사실 A를 도출하는데 신뢰도가 cf1 이었고, 다른 규칙은 신뢰도가 cf2 로 사실 A를 도출하였을 때, 이 두 가지 신뢰도를 결합한 신뢰도는 다음공식과 같이 계산한다[14].

$$cf(cf1, cf2) = cf1 + cf2 \cdot (1 - cf1)$$

$$(if \ cf1 \geq 0 \ and \ cf2 \geq 0)$$

즉, 나무를 추론하는데 인식 가능한 나무 부위 유형별 이미지의 수가 많을수록 정확도를 향상시킬 수 있는 방안을 모형으로 만들어 분석해 보았다.

4. Experimental system environment and Retraining the Inception V3 Model

실험 시스템 환경은 PC Intel(R) Core(TM) i3-7100U CPU를 사용하였고 Microsoft Windows 10 Home x64와 구글 Tensorflow 1.12.0, 인셉션 V3를 사용하였으며, 언어는 Python 3.6.8, 오픈 소스로는 Anaconda3, 통합개발 환경(IDE)으로는 Spyder를 사용하여 수행하였다.

높은 정확도 인식을 위한 충분한 학습을 위하여 재학습을 위한 최소 이미지 수를 20장으로 설정하였다. 20장 이하의 이미지수를 가진 나무 유형 이미지와 재학습이 불가능한 이미지를 제외한 총 4,034장의 이미지에 대하여 재학습을 진행하였으며, 학습 횟수(Training Step)는 1,000

회를 수행하였다. 재학습에 사용된 나무 유형별 이미지 리스트는 Table 6.와 같다.

Table 6. List of images used for re-training

Tree Name	Shape of tree	Bark	Leaf	Flower	Fruit
adansonia	26	16	20	26	23
apple tree	21	22	22	25	14
azalea	33	13	21	73	21
bamboo	21	21	24	26	20
banana tree	21	23	21	23	21
birch tree	25	20	22	22	23
camellia	23	23	20	22	21
cherry tree	42	88	35	47	23
chestnut tree	21	25	24	23	20
chionanthusretusus	23	20	21	23	23
cornus officinalis	22	21	20	35	22
elm tree	20	21	21	27	24
forsythia	28	23	21	64	29
ginkgo tree	22	24	45	23	25
grapevine	21	20	20	22	25
juniper tree	21	22	22	25	20
magnolia	22	168	21	75	23
mangrove	22	20	20	21	5
maple tree	20	28	26	22	25
mesquite tree	23	6	11	10	13
metasequoia	21	15	21	15	21
mulberry tree	21	21	20	32	21
nutpine	21	25	21	23	24
oak tree	21	25	23	7	28
orange tree	23	11	22	26	22
pear tree	20	29	20	20	22
persimmon tree	21	25	23	26	23
pine tree	26	60	27	26	24
platanus	21	82	21	23	22
poplar	20	27	21	7	0
royalazalea	21	20	23	63	21
spindle tree	20	20	21	28	23
willow tree	21	21	20	24	20
zelkova tree	21	20	21	22	23
Total	775	1,025	761	976	714

5. Measurement results of tree image recognition before and after re-training

5.1 Accuracy of tree image recognition before re-training

재학습의 효과를 비교 검증하기 위하여 재학습전 학습을 하지 않은 상태에서 이미지넷(Imagenet)을 내장한 인셉션V3 모델에 대해 나무 부위유형별 샘플이미지 총 15장을 사용하여 성능을 측정하였다. 이미지의 평균 판별시간은 약 5.5초로 측정 되었으며, 샘플이미지 15장 중 2장(바나나꽃, 밤)에 대해서만 식별해 내었다.

5.2 Accuracy of trained tree image recognition after re-training and combined accuracy

재학습 효과를 검증하기 위해 재학습을 수행한 인셉션V3 모델을 이용하여, 나무 34종의 5가지 부위별 유형에 대해 각 5장씩 재학습 시 사용했던 이미지 총 765장을 이용하여 학습이 불가능한 경우들을 제외하고 테스트를 진행하였다. 테스트 결과 최대 64.38%, 최소 2.46%의 정확도를 나타내었으며, 전체 평균 정확도는 17.12%로 측정되었다.

또한 각 재학습에 사용된 나무 부위유형별 샘플 이미지 (Trained Sample Image)에 대한 정확도를 측정한 결과를 이용한 각 나무 종류별로 결합 정확도를 측정하였다. 각 정확도들 중에서 상위 2가지 결합 정확도(Top 2 Combined Accuracy), 상위 3가지 결합 정확도(Top 3 Combined Accuracy), 상위 4가지 결합 정확도(Top 4 Combined Accuracy), 상위 5가지 결합 정확도(Top 5 Combined Accuracy)를 정리하였으며, 상위 2가지 부위별 유형의 결합정확도를 구함으로써 나무의 한 가지 부위 유형에 대한 이미지의 정확도에 비해 최대 22.24%, 최소 8.07%의 증가율을 보였다. 상위 2가지 유형 결합정확도에서 추가적인 나무 유형 특징 이미지의 정확도를 결합한 상위 3가지 유형 결합정확도에서는 최대 13.11%, 최소 2.77%의 증가율을 보였으며, 상위 3가지 유형 결합정확도에서 추가적인 나무 유형 특징 이미지의 정확도를 결합한 상위 4가지 유형 결합정확도에서는 최대 7.31%, 최소 1.64%의 증가율을 보였다. 마지막으로 상위 4가지 유형 결합정확도에서 추가적으로 나무 부위 유형 이미지 정확도를 결합한 상위 5가지 유형 결합정확도에서는 최대 5.70%, 최소 0.72%의 증가율을 보였다. 최종적으로 Fig. 2와 같이 정확도를 결합하는 방식을 통해 정확도가 향상됨을 확인할 수 있었으며, 최대 22.24%, 최소 0.72%의 정확도를 높이는 것으로 측정되는 양상을 보였다.




Fig. 2. Increase of Combined Accuracy of Re-trained Images by Tree feature after Re-training

이번에는 재학습에 사용된 이미지들에 대하여 나무 종류에 따른 정확도를 높이는 부위별 유형 이미지 결합 조합을 분석하였다. 기준 정확도(Standard Accuracy)를 50%로 설정하여 연구에 사용한 34종의 나무에 대해 분석한 결과를 Table 7.에 제시하였다. 5가지 부위 유형의 정확도 결합을 통해 정확도 50%를 초과하는 나무는 해당하는 종류가 없었으며, 총 20종의 나무에 대해 1가지 부위유형으로 판별 가능한 나무는 감나무와 대나무로 2종이었으며, 2가지 부위유형으로 판별 가능한 나무는 동백나무, 바나나 나무, 오렌지나무, 은행나무, 자작나무, 철쭉, 포도나무, 플라타너스(버즘나무)로 총 8종으로 분석 되었다. 3가지 부위유형으로 판별 가능한 나무는 망그로브, 밤나무, 사철 나무, 산수유나무, 참나무로 총 5종으로 나타났으며, 4가지 부위유형으로 판별 가능한 나무는 느티나무, 단풍나무, 뽕나무, 이팝나무, 향나무로 총 5종으로 정리되었다.

5.3 Accuracy of new tree image recognition after re-training and combined accuracy

재학습을 실시한 후 재학습되지 않은 새로운 나무 이미지 샘플에 대해서 판별 정확도를 측정해 보았다. 나무 34종에 대해 수형, 수피, 잎, 꽃, 열매의 총 다섯 부위 유형별로 각 5장씩 총 765장의 이미지에 대해 정확도를 측정하였다. 정확도 측정 결과 최대 55.13%, 최소 0.53%의 정확도를 나타내었으며, 전체 평균 정확도는 8.67%로 측정되었다.

또한 각 재학습에 사용되지 않은 새로운 샘플 이미지(New Sample Image)에 대한 정확도를 측정한 결과를 이용하여 각 나무종류별 결합 정확도를 도출하였다. 나무의 한 가지 부위 유형에 대한 이미지의 정확도에 비해 상위 2

가지 유형 결합정확도를 구함으로써 최대 15.35%, 최소 1.24%의 증가율을 보였다. 상위 2가지 유형 결합정확도에서 추가적으로 나무 부위 유형 이미지 정확도를 결합한 상위 3가지 유형 결합정확도에서는 최대 9.96%, 최소 1.45%의 증가율을 보였으며, 상위 3가지 유형 결합정확도에서 추가적으로 이미지 정확도를 결합한 상위 4가지 유형 결합정확도에서는 최대 5.76%, 최소 0.5%의 증가율을 보였다. 마지막으로 상위 4가지 유형 결합정확도에서 추가적으로 이미지 정확도를 결합한 상위 5가지 유형 결합정확도에서는 최대 4.88%, 최소 0.41%의 증가율을 보였다. 최종적으로 Fig.3 과 같이 결합 정확도를 통해 정확도가 향상됨을 확인할 수 있었으며, 최대 15.35%, 최소 0.41%의 정확도를 높이는 것으로 측정되는 양상을 보였다.

또한 Table 8.과 같이 상위 2가지 유형 결합정확도에서는 수형과 수피의 결합조합이 효과적인 결합정확도를 나타내었다.

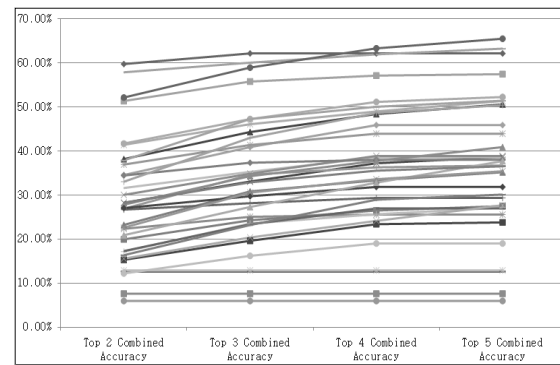


Fig. 3. Increase of Combined Accuracy of New Images by Tree feature after Re-training

Table 7. Tree that can be recognized by combining according to each feature

1 feature	persimmontree	Shape of tree			
	bamboo	Shape of tree			
	camellia	Leaf	Flower		
2 feature	banana tree	Fruit	bark		
	orange tree	Shape of tree	Fruit		
	ginkgo tree	Bark	Shape of tree		
	birch tree	Shape of tree	Bark		
	royalazalea	Flower	Shape of tree		
	grapevine	Fruit	Bark		
3 feature	platanus	Bark	Fruit		
	mangrove	Shape of tree	Bark	Leaf	
	chestnut tree	Fruit	Flower	Shape of tree	
	spindle tree	Flower	Bark	Leaf	
4 feature	cornus officinalis	Flower	Shape of tree	Leaf	
	oak tree	Fruit	Shape of tree	Bark	
	zelkova tree	Bark	Leaf	Fruit	Shape of tree
	maple tree	Shape of tree	Leaf	Bark	Flower
	mulberry tree	Fruit	Leaf	Bark	Flower
5 feature	chionanthusretusus	Fruit	Shape of tree	Bark	Flower
	juniper tree	Shape of tree	Leaf	Flower	Bark
No trees available					

상위 3가지 유형 결합정확도에서는 수형, 수피, 꽃의 결합조합이 효과적인 결합정확도 향상을 나타내었으며, 상위 4가지 유형 결합정확도에서는 수형, 수피, 꽃, 잎의 조합이 효과적으로 나타났다. 상위 5가지 유형 결합정확도에서는 수형, 수피, 꽃, 잎, 열매의 조합이 효과적인 결합정확도 성능을 보여주었다.

최종적으로 기존의 유사한 기능을 가진 어플리케이션과의 성능을 비교하기 위해 Table 1.의 테스트에 사용된 동일한 이미지 40장에 대하여 인셉션V3 학습모델에서 테스트를 진행하여 성능을 비교한 결과는 Fig.4 와 같다. 기존 유사 어플리케이션에 비해 인셉션 V3(Inception V3)의 재학습을 통해 특히 수피의 판별성능은 최대 80%, 최소 42.5% 증가하였으며, 꽃의 판별 성능은 최대 65%, 최소 15%, 잎의 판별 성능은 최대 51.67%, 최소 1.67%, 열매의 판별 성능은 최대 50%, 최소 37.5%, 수형의 판별 성능은 최대 13.34%, 최소 0.84% 증가한 것으로 분석되었다.

대해 연구하였다. 특히 사전 학습된 인셉션V3(InceptionV3)의 재학습 수행 전과 후의 나무 판별 정확도를 비교하여 인셉션V3 모델의 나무 분류 성능을 확인하였다. 또한 성능 향상을 위해 각 부위별 유형 이미지의 정확도의 결합을 통한 나무 분류를 수행하여 나무의 판별 정확도 향상을 위한 방안을 제시하였다.

실험결과를 통해 나무의 부위 유형별 정확도 결합(Combined Accuracy)이 판별정확도 향상에 영향을 주었음을 확인하였으며, 각 나무에 대해 어떤 부위를 잘 식별하고 어떤 부위유형의 이미지 조합이 최상의 나무 식별을 하는데 도움이 되는지 알 수 있었다.

재학습을 통해 나무의 판단정확도를 높일 수 있었지만 학습된 나무 이미지를 이용한 정확도 판단 결과에 비해 새로운 나무 이미지를 이용한 정확도 판단 성능이 다소 떨어지는 한계점이 존재하였다. 이에 대하여 앞으로 더 높은 정확도 향상을 위해 재학습에 사용되는 학습이미지의 각

Table 8. Combination by Tree Image Feature for Effective Combined Accuracy

Combined Accuracy by Feature	Conclusion
Top 2	Shape of tree + Bark
Top 3	Shape of tree + Bark + Flower
Top 4	Shape of tree + Bark + Flower + Leaf
Top 5	Shape of tree + Bark + Flower + Leaf + Fruit




Fig. 4. Performance comparison with Existing Similar Applications

IV. Conclusions

본 연구에서는 머신러닝을 통한 재학습을 통해 초·중·고등학교 주변의 나무를 식별 하는데 사용 될 수 있는 모델에

도 변경과 회전처리를 적용하여 데이터셋(Data set)의 수량을 늘린다면 나무분류 정확도와 인식률을 더욱 향상시킬 수 있을 것이라 기대한다.

향후, 본 연구를 적용한 학습용 나무 인식 스마트폰 어플리케이션을 제작하여 수업시간에 학생들이 직접 사용할 수 있도록 한다면, 학생들의 학습에 직접적인 도움이 가능할 것이다.

ACKNOWLEDGEMENT

The paper is a research conducted in 2017 with the support of the Ministry of Education and the National Research Foundation of Korea. (NRF-2017S1A5B6066963)

REFERENCES

- [1] Jin Hyung Kim, Fourth Industrial Revolution, Education in the Age of Artificial Intelligence. STSS The Sustainability Science Society Conference, Vol. 2016, No. 6, pp. 21-29, 2016.
- [2] YungJun Lee, Prepare for the introduction of the 2015 Revised Information Curriculum. The Korean Society Of Computer And Information, Vol. 23, No. 2, pp. 1-8, 2015.
- [3] Korean Ministry of Education, "(Elementary School) Science 4-2," Seoul: Visang education, 2018.
- [4] Korean Ministry of Education, "(Elementary School 3~4 Grade) Science 4-2," Seoul: Miraen, 2014.
- [5] Heeok Heo, Hyeonwoo Lee, Hyeonjin Kim, Kyu Yon Lim, Eui Sung Kang, Investigation on teachers' understanding of SMART education in Jeollanamdo. The Korean Association Of Computer Education Conference Presentations, Vol. 17, No. 1, pp. 3-7, 2013.
- [6] Yu Hwan Kim, Jeong Yoo soo, Chung Yun-su, Kil-Houm Park, Age Estimation Method based on Comparative Convolutional Neural Network using Inception Module. Journal of Korean Institute of Intelligent Systems, Vol. 2, No. 3, pp. 193-200, 2018. DOI: 10.5391/jkiis.2018.28.3.193
- [7] Vladimir V. Mokeev, On Application of Convolutional Neural Network for Classification of Plant Images. Global Smart Industry Conference(GloSIC), pp. 1-6, 2018. DOI: 10.1109/glosic.2018.8570141
- [8] Titus J. Brinker, Achim Hekler, Alexander H. Enk, et al, A convolutional neural network trained with dermoscopic images performed on par with 145 dermatologists in a clinical melanoma image classification task. European Journal of Cancer, Vol. 111, pp. 148-154, 2019.
- [9] YoonJoo Cho, Deep Learning Technology and Applications in the IoT Industry. Industrial Engineering Magazine, Vol. 26, No. 1, pp. 15-20, 2019.
- [10] PictureThisAI Application., <https://www.picturethisai.com>
- [11] PlantSnap Application, <https://www.plantsnap.com>
- [12] Naver Application SmartLens, https://blog.naver.com/naver_search/221047954593
- [13] Weol-Young Kim, Seung-Jung Shin, Large orchard apple classification system. The Journal of the Convergence on Culture Technology (JCCT), Vol. 4, No. 4, pp. 393-399, 2018.
- [14] Gunmyung Lee, "Artificial intelligence : From Turing Test to Deep Learning," Paju: Saengneung. Publication, 2018.
- [15] Tensorflow Github, <https://github.com/tensorflow/hub>

Authors



Jung-Eun Choi received the B.S. degrees in Computer Engineering from Hongik University, Korea in 2012 and M.S. degrees in Software Education from Ewha womans University, Korea in 2019, respectively.

Jung-Eun Choi is interested in Deep Learning, Data Mining, Machine Learning, Artificial Intelligence and Pattern Recognition.



Hwan-Seung Yong received the B.S., M.S. and Ph.D. degrees in Computer Science and Engineering from Seoul National University, Korea, in 1983, 1985 and 1994, respectively. Hwan-Seung Yong is currently a Professor in

the Department of Computer Science, Ewha Womans University. He is interested in Database, Data mining, OLAP, Multimedia Database and Ubiquitous computing.