

An Experimental Comparison of CNN-based Deep Learning Algorithms for Recognition of Beauty-related Skin Disease

Chang-Hui Bae*, Won-Young Cho*, Hyeong-Jun Kim*, Ok-Kyoon Ha*

*Undergraduate student, Dept. of Aeronautical Software Engineering, Kyungwoon University, Gumi, Korea

*Undergraduate student, Dept. of Aeronautical Software Engineering, Kyungwoon University, Gumi, Korea

*Undergraduate student, Dept. of Aeronautical Software Engineering, Kyungwoon University, Gumi, Korea

*Professor, Dept. of Aeronautical Software Engineering, Kyungwoon University, Gumi, Korea

[Abstract]

In this paper, we empirically compare the effectiveness of training models to recognize beauty-related skin disease using supervised deep learning algorithms. Recently, deep learning algorithms are being actively applied for various fields such as industry, education, and medical. For instance, in the medical field, the ability to diagnose cutaneous cancer using deep learning based artificial intelligence has improved to the experts level. However, there are still insufficient cases applied to disease related to skin beauty. This study experimentally compares the effectiveness of identifying beauty-related skin disease by applying deep learning algorithms, considering CNN, ResNet, and SE-ResNet. The experimental results using these training models show that the accuracy of CNN is 71.5% on average, ResNet is 90.6% on average, and SE-ResNet is 95.3% on average. In particular, the SE-ResNet-50 model, which is a SE-ResNet algorithm with 50 hierarchical structures, showed the most effective result for identifying beauty-related skin diseases with an average accuracy of 96.2%. The purpose of this paper is to study effective training and methods of deep learning algorithms in consideration of the identification for beauty-related skin disease. Thus, it will be able to contribute to the development of services used to treat and easy the skin disease.

▶ **Key words:** Deep Learning, CNN, Beauty-related Skin Disease Recognition, Image Recognition, Algorithm Comparison, Experimental Comparison

• First Author: Chang-Hui Bae, Corresponding Author: Ok-Kyoon Ha

*Chang-Hui Bae (qockd6410@ikw.kr), Dept. of Aeronautical Software Engineering, Kyungwoon University

*Won-Young Cho (cliffclimber@ikw.kr), Dept. of Aeronautical Software Engineering, Kyungwoon University

*Hyeong-Jun Kim (siannyu@ikw.kr), Dept. of Aeronautical Software Engineering, Kyungwoon University

*Ok-Kyoon Ha (okha@ikw.ac.kr), Dept. of Aeronautical Software Engineering, Kyungwoon University

• Received: 2020. 10. 14, Revised: 2020. 11. 19, Accepted: 2020. 11. 19.

• This paper is a revised and expanded version of a paper entitled "A Design of Application using Deep Learning Image Recognition for Identification of Individual Skin Diseases" presented at the 61th conference of KSCI, January, 2020.

[요 약]

본 논문에서는 딥러닝 지도학습 알고리즘을 사용한 학습 모델을 대상으로 미용 관련 피부질환 인식의 효과성을 실험적으로 비교한다. 최근 딥러닝 기술을 산업, 교육, 의료 등 다양한 분야에 적용하고 있으며, 의료 분야에서는 중요 피부질환 중 하나인 피부암 식별의 수준을 전문가 수준으로 높은 성과를 보이고 있다. 그러나 아직 피부미용과 관련된 질환에 적용한 사례가 다양하지 못하다. 따라서 딥러닝 기반 이미지 분류에 활용도가 높은 CNN 알고리즘을 비롯하여 ResNet, SE-ResNet을 적용하여 실험적으로 정확도를 비교함으로써 미용 관련 피부질환을 판단하는 효과성을 평가한다. 각 알고리즘을 적용한 학습 모델을 실험한 결과에서 CNN의 경우 평균 71.5%, ResNet은 평균 90.6%, SE-ResNet은 평균 95.3%의 정확도를 보였다. 특히 학습 깊이를 다르게하여 비교한 결과 50개의 계층 구조를 갖는 SE-ResNet-50 모델이 평균 96.2%의 정확도로 미용 관련 피부질환 식별을 위해 가장 효과적인 결과를 보였다. 본 논문의 목적은 피부 미용과 관련된 질환의 판별을 고려하여 효과적인 딥러닝 알고리즘의 학습과 방법을 연구하기 위한 것으로 이를 통해 미용 관련 피부질환 개선을 위한 서비스 개발로 확장할 수 있을 것이다.

▶ **주제어:** 딥러닝, CNN, 피부미용 질환 인식, 이미지 인식, 알고리즘 비교, 실험적 비교

I. Introduction

도시화 및 환경오염의 증가 등의 외부적인 요인과 심리적, 정서적 스트레스 등 간접적인 영향으로 인해 다양한 피부질환이 발생하고 있다. 피부질환의 경우 사람마다 발병 부위, 모양, 색상 등의 차이가 존재하기에 전문가 정확한 판단에 따른 치료가 필요한 분야임에도 불구하고 다수의 사람들은 피부질환을 병으로 여기지 않는 경향으로 인해 잘 개선되지 않는 질환이다.

실제로 직장인 대상의 조사 결과 67.7%가 제때 병원을 가지 않아 병을 키운 경험이 있으며, 병원에 가지 않은 이유로는 ‘업무 때문에 병원에 갈 시간이 없어서’가 21.9%, ‘상사의 눈치가 보이거나 업무에 지장을 줄까 봐’가 19.5%, ‘참을 만해서’가 16.7%, ‘시간이 지나면 자연 치유 됨’이 15.5%로 대부분이 업무로 인해 병원을 가지 못하거나 피부질환 자체를 가볍게 여기고 있는 현실이다.¹⁾ 더불어 20세 이상 남성을 대상으로 피부 고민에 대한 조사결과 여드름 등의 피부 트러블(44%)에 스트레스가 높게 나타났으며, 자기 관리의 일환으로 피부관리에 대한 관심(70.4%)을 가지고 있는 등 피부관리의 필요성이 증가하고 있다.²⁾

한편, 최근에는 딥러닝(Deep Learning)[1-2] 분야 알고리즘의 발전으로 인해 다양한 분야에 기술을 접목하여 눈에 띄는 성과를 이루고 있다. 특히, 의료분야에서 딥러닝 기술을 이용한 영상 및 이미지 인식 방식을 이용하여

녹내장[3], 유방암[4], 당뇨병[5] 등 다양한 질병을 판별하는 기술에 가시적인 성과를 보이고 있다.

특히, 구글의 Inception 알고리즘을 이용한 피부암 판독 기술과 IBM Watson 기반의 딥러닝을 통한 피부암 진단 기술은 정확도 면에서 약 95%로 개선되었으며, 이는 전문분야의사의 진단 정확도보다 딥러닝을 통한 진단 정확도가 높은 수준까지 도달했다는 평가를 받는다 [6]. 이처럼 피부암에 관해서는 많은 연구가 이루어지고 있지만, 피부미용 부분에서는 딥러닝을 이용한 관련 사례들이 아직까지 활발하게 이루어지지 않고 있다.

본 논문에서는 다수의 분야에서 좋은 성과를 보인 CNN(Convolutional neural network)[7], ResNet (Residual neural networks)[8], SE-ResNet (Squeeze-and-Excitation ResNet)[9]을 대상으로 미용과 관련된 피부질환인 건선, 사마귀, 여드름, 한포진을 판별하기 위한 학습을 통해 그 정확도를 실험적으로 비교평가 한다. 각 알고리즘을 적용한 학습 모델을 실험한 결과에서 CNN의 경우 평균 71.5%, ResNet은 평균 90.6%, SE-ResNet은 평균 95.3%의 정확도를 보였고, 학습 깊이를 다르게하여 비교한 결과 50개의 계층 구조를 갖는 SE-ResNet-50 모델이 평균 96.2%의 정확도로 가장 효과적인 결과를 보였다.

1) 『벼룩시장구인구직(job.findall.co.kr) 직장인 대상 설문조사』2014.8.4.

2) 『오픈서베이(opensurvey.co.kr/) "남성 그루밍 트렌드 리포터 2019"』2019.02.25

본 논문은 2장에서 CNN 기반의 딥러닝 알고리즘과 이를 이용한 피부질환 인식 관련 연구를 살펴보고, 3장에서 미용 관련 피부질환 인식을 위한 딥러닝 알고리즘 비교 실험을 설계한다. 딥러닝 학습의 비교 실험 결과와 분석은 4장에서 제시하고, 5장에서 결론 및 향후 과제를 제시한다.

II. Background

딥러닝 기술을 활용하는 응용은 질병을 포함한 다양한 분야에서 지속적으로 연구가 진행되고 있으며, 결과 또한 높은 정확도를 나타내는 것으로 알려져 있다. 본 절에서는 CNN기반의 딥러닝 알고리즘과 피부질환을 대상으로 적용한 관련 연구를 간략하게 소개한다.

1. Deep Learning Algorithms based on CNN

합성곱 신경망(CNN, Convolutional neural network) [7]은 이미지, 텍스트, 사운드 등을 분류하는데 사용되는 인공지능망이다. 딥러닝에서는 이를 심층 신경망으로 분류되며, 시각적 이미지 분석에 널리 적용된다. 이미지 및 비디오 인식, 추천 시스템, 이미지 분류, 의료 이미지 분석 및 자연어 처리에 응용된다.

ResNet(Residual neural network)[8]은 마이크로소프트사에서 개발한 알고리즘으로 기존의 알고리즘 보다 대폭 증가된 152개의 계층(Layer)으로 구성된 신경망(Networks)을 적용한다. 또한, 기존의 신경망과 차별화 되는 지름길(shortcut) 개념을 적용하여 입력값을 출력값에 더해줌으로써 목표값을 찾는 함수를 최적화하기 쉽게 최소화하는 방법을 사용한다.

CNN 알고리즘은 모델의 학습 깊이가 깊어질수록 오히려 성능이 떨어지는 현상이 생긴다. 이는 layer가 깊어질수록 미분 계산이 점차 많아지기 때문에, 역전파를 해도 미분값이 작아져 출력값에 영향을 미치는 정도가 작아진다. 이로 인해 완벽한 학습 데이터라도 학습이 제대로 이루어지지 않는 결과를 초래한다.

ResNet은 이러한 현상을 방지하고자 제안된 알고리즘이다. CNN은 Fig. 1. (a)와 같이 입력값에 대한 weight layer를 거친 출력값이 다음 layer에 적용되지만, ResNet은 layer의 입력을 layer의 출력에 연결하는 "skip connection"을 사용하여 layer가 아무리 깊어져도 출력값이 1 이상의 값을 가지게 하여 학습 깊이가 깊어져도 성능이 떨어지는 현상을 방지할 수 있다.

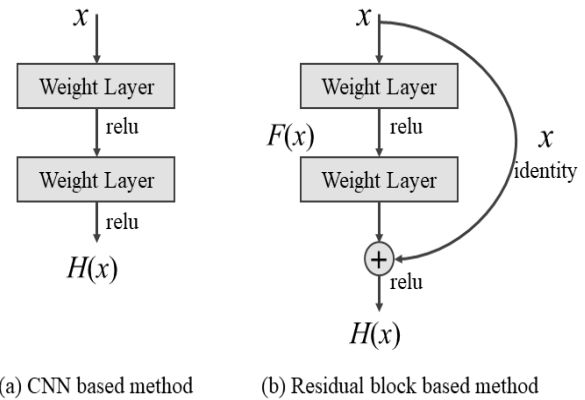


Fig. 1. Block diagrams for CNN and ResNet
Image Source: modified using CNN and ResNet concepts in [8]

Fig. 1. (b)는 ResNet의 핵심인 Residual Block의 개념도이다. 그림에서 $H(x)$ 는 신경망의 입력값 x 를 타겟값으로 매핑하기 위한 함수로, 중간 함수 $F(x)$ 와 입력값 x 의 합으로 구성된다. ResNet은 이러한 $F(x) + x$ 를 최소화하기 위해 $F(x)$ 를 위한 잔차(Residual) $H(x) - x$ 가 최소가 되게 학습함으로써 계층이 증가하더라도 학습 에러(Training error)는 줄어들게 한다. 여기서, 잔차는 학습을 위한 표본집단에서 도출된 회귀식을 통해 얻은 예측값과 실제 관측값의 차이를 의미한다.

SE-ResNet은 ResNet의 Residual 모듈 다음 단계에 SENet[9]의 SE block을 추가한 것이다. SE block은 CNN 계열의 알고리즘의 컨볼루션 단계에서 생성된 특성을 채널별 중요도를 고려하여 재보정(Recalibration)한다.

Fig. 2는 ResNet에 SE block을 결합한 개념도를 보인다. 그림에서 SE block 내부의 Global pooling을 통해 다수 채널의 특성맵들을 대상으로 하나의 값으로 압축하고, 두 개의 Fully-connected층과 시그모이드 단계를 거쳐 채널별 상대적 중요도를 반영하여 활성화함으로써 재보정이 가능하게 한다.

CNN은 각 layer에서 내부의 연산 및 분해를 중점으로 하였지만, SENet은 채널의 관계에 중점을 두어 채널 간 상호 관계를 명시적으로 모델링 한다. 따라서 SENet의 SE block은 각 채널의 특성맵을 추출하여 압축(Squeeze)하고, 재조정하는 과정에서 채널 간 의존성을 계산하여 활성화(Excitation)함으로써 추가적인 연산량이 적으면서도 우수한 성능의 모델 생성이 가능하다.

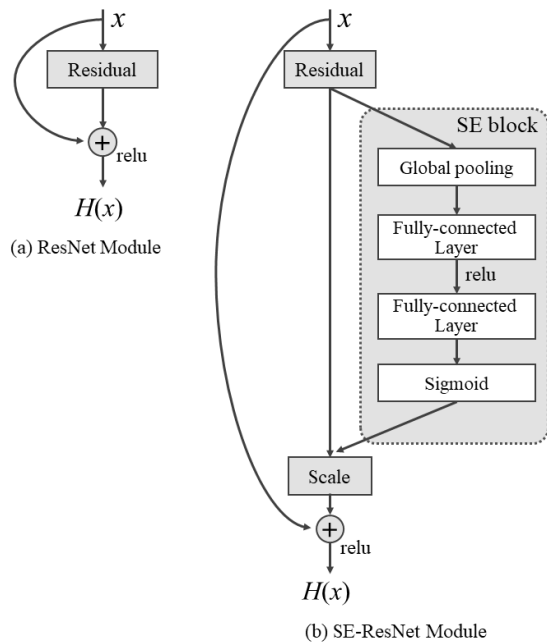


Fig. 2. Block diagrams for ResNet and SE-ResNet
Image Source: modified using SE-ResNet concept in [9]

2. Related Work

딥러닝을 적용하여 피부암과 같은 질환을 진단하기 위한 다수의 연구가 이루어지고 있다. Abedini 등의 연구 [6]에서는 158개의 피부암 종류에 대한 소규모 학습 데이터를 이용하여 약 90%의 정확도를 보여주었으며, 2,761개의 이미지로 구성된 대규모 학습 데이터로 확대 적용하여 약 95% 이상의 정확도를 보인바 있다. 이는 전문의의 진단 정확도를 상회하는 수준으로 평가받고 있다.

Esteva 등의 연구[10]에서는 VGG 알고리즘[11]을 이용하여 피부암을 분류하고 식별하는 시스템을 구현하였다. 이 연구에서는 약 13만 개의 피부질환 이미지를 사용하여 VGG 알고리즘으로 학습을 진행하였고, 각각 60.0%와 80.3%의 Top-1과 Top-3의 정확도를 기록하였다. 이러한 결과는 학습이 완료된 모델의 경우 전문의와 비슷한 수준의 판단 능력을 보인 것으로 분석하였다.

Dorj[12] 등의 연구팀은 AlexNet[13]을 이용하여 피부암을 분류하는 연구를 진행하였다. 실험을 위해 피부암 이미지는 인터넷에서 수집하여 노이즈를 제거하고 4가지 종류의 피부암 이미지 총 3,753 장을 사용하였다. 실험결과 정확도는 편평 세포 암종 약 95.1%, 광선 각화증 약 98.9%로 높은 정확도를 보였고 흑색종은 약 90.7%, 기저 세포 암종 약 91.8%의 정확도로 다소 낮은 정확도를 보여주었지만 AlexNet의 피부암에 대한 활용도를 제시하였다.

Tschandl 등은 [14]의 연구를 통해 진단하기 어려운 비 색소 피부암을 신경망을 이용하여 전문가만큼 정확하

게 분류할 수 있는지 연구하였다. 사용된 이미지는 피부암 판독 도구를 이용하여 얻은 7,895장의 이미지와 클로즈업된 5,829장의 이미지를 사용하였다. CNN으로 검증한 결과 판독 도구를 이용한 이미지에서 평균 AUC는 0.725인 반면 전문가는 평균 AUC 0.695를 기록하였다. 이는 딥러닝 학습 결과가 경험 많은 전문가만큼 분류할 수 있으며, 경험이 적은 전문가보다는 높은 정확도로 분류할 수 있음을 실험적으로 보여주었다.

Alarifi 등의 연구[15]에서는 Inception 알고리즘[16]을 이용하여 피부 반점, 주름 등을 이용하여 피부 질을 평가하는 연구를 진행하였다. 피부 질은 3가지 분류로 나누었으며, 학습을 위한 데이터 세트는 다양한 인종의 고품질 얼굴 이미지를 이용하였다. 딥러닝 알고리즘을 활용한 피부 질 평가의 검증 결과는 약 89% 정확도를 기록하였으며, 이는 비 임상 피부 이미지 분류를 위한 딥러닝의 잠재적인 능력을 보여준다.

Ahmad 등의 연구[17]에서는 ResNet152와 Inception-ResNet-V2 [18]를 사용하여 여드름, 블랙헤드, 다크서클, 반점을 분류하는 실험을 진행하였다. 총 12,000 장의 입력 이미지와 2,000 장의 테스트 이미지를 사용하였으며, 테스트 이미지 중 10%를 검증 데이터로 사용하였다. 실험 결과는 ResNet152는 평균 84.91% 정확도, Inception-ResNet-V2는 87.42% 정확도를 기록하였다. 이는 미용관련 피부질환에 대한 딥러닝의 활용도를 제시한 사례이나 정확도가 기존 유사 연구에 비해 낮은 정확도의 결과를 보인다.

Pal 등이 실시한 학습모델 비교 연구[19]에서는 50개의 층으로 이루어진 ResNet-50과 DenseNet-121[20], MobileNet-50[21]의 조합을 통한 피부질환 식별 실험을 통해 3개의 알고리즘 중 ResNet-50이 77.3%로 높은 정확도를 보이고, ResNet-50과 다른 알고리즘의 조합으로 이루어진 학습 정확도가 77.5%로 가장 높은 것으로 분석하였다. 그러나, ResNet을 사용한 학습 결과가 높은 것을 확인할 수 있었지만, 피부암에 대해서만 특화되어있었고, 그 외 피부질환 대상의 의료용으로 개발되어 사람들에게 정확한 정보를 제공하기엔 낮은 정확도를 보였다.

III. Experimentation

본 절에서는 CNN 기반 딥러닝 알고리즘 3종을 대상으로 미용 관련 피부질환 이미지 학습과 인식 정확도 평가를 위한 실험 과정을 설명한다. 실험 단계는 다음과 같다.

- 학습 데이터 수집 및 전처리
- 딥러닝 모델별 학습
- 학습된 딥러닝 모델 결과 분석

1. Data Collection and Pre-processing

실험에 사용되는 미용 관련 피부질환 이미지 데이터는 피부질환의 치료 전·후 결과를 비교하기 위해 피부질환 발병 부위의 이미지 포함하여 피부질환 별로 수집하였다.




Fig. 3. The beauty-related skin disease images

수집된 피부질환의 종류는 Fig. 3과 같이 (a) 여드름, (b) 건선, (c) 사마귀, (d) 한포진으로 일상에서 자주 발병하는 피부질환으로 질환별 특징이 비교적 분명한 것을 대상으로 수집하였다. 수집된 데이터 집합은 배경의 영향을 최소화하기 위해 질환 발병 부위 위주로 추출하여 사용하였다. 또한, 데이터는 딥러닝 모델의 학습을 위한 학습용 데이터 집합과 테스트 집합을 구분하여 실험에 사용하도록 하였다.

원본 데이터는 다양한 경로를 통해 수집하여 일관성이 없어 학습을 위해 데이터를 일관성 있게 분류하고 학습 오류를 최소화하기 위한 추출, 변환, 증강의 데이터 전처리를 실시하였다. 먼저, 학습에 사용될 이미지의 크기는 학습 시 연산량과 GPU 메모리 크기를 고려하여 256×256 픽셀로 변환하였다. 또한, 수집 및 변환된 데이터의 양과 학습 효과 향상을 위해 데이터 증강 과정을 추가하였으며, 실험을 위해 이미지 회전, 좌우 대칭, 수직 및 수평 이동, 확대 및 축소를 사용하였다.




Fig. 4. The obtained images through pre-processing

Fig. 4는 하나의 건선 이미지를 대상으로 좌우 반전, 회전, 확대를 통해 증강된 데이터의 예를 보인다. 피부질환 판단을 위해 수집된 4종의 피부질환 원본 이미지는 약 3,500개이며, 데이터 전처리 과정을 통해 약 20,000개의 데이터로 증강하여 학습 데이터 집합과 테스트 데이터 집합으로 분류하여 실험에 활용한다. Table 1은 질환별 학습과 테스트에 사용한 데이터의 개수를 나타낸다.

Table 1. Organized dataset for experiments

| Disease | Training Dataset | Test Dataset |
|-------------|------------------|--------------|
| Pimple | 3,980 | 786 |
| Psoriasis | 4,711 | 904 |
| Wart | 4,163 | 819 |
| Dyshidrosis | 4,357 | 825 |
| Total | 17,211 | 3,334 |

2. Training

실험은 Intel i7 CPU와 GTX 1070Ti GPU 기반 서버 컴퓨터에 Windows 10 운영체제를 사용하였고, 딥러닝 라이브러리 사용을 위해 TensorFlow와 이를 Back-end로 사용하는 Keras를 설치하여 파이썬으로 알고리즘별 학습을 구현하였다. 또한, ResNet과 SE-ResNet은 에러율이 낮은 학습 깊이(신경망 계층)인 50, 101, 152으로 구분하여 학습하도록 하였다[8]. 학습 중 모델의 검증을 위해 학습용 데이터 집합 중 20%를 활용하였으며, 학습이 완료된 후 학습에 사용되지 않은 테스트 데이터 집합을 각 모델의 정확도 검증에 활용하였다.

모델별로 학습을 위한 반복횟수(epochs)는 CNN 알고리즘을 사용한 사전 조사를 바탕으로 과적합(Overfitting) 발생을 방지할 수 있도록 50회로 설정하였다. 또한, 경사 하강법을 이용한 학습을 진행할 때 국소 최소값(Local minima)에 빠지는 문제를 해결하기 위해 Keras에서 제공하는 ReduceLROnPlateau 콜백 함수를 적용하였다.

IV. Results and Analysis

1. CNN Training Model

Fig. 5는 CNN 알고리즘의 학습 결과이고, Table 2는 학습 완료된 CNN 모델을 사용하여 테스트 데이터 집합을 사용하여 검증한 결과이다.

Table 2. The accuracy of CNN Model

| Disease | Accuracy |
|-------------|----------|
| Pimple | 89.3% |
| Psoriasis | 72.7% |
| Wart | 67.5% |
| Dyshidrosis | 56.5% |

Fig. 5의 결과에서 CNN 모델은 충분한 학습에도 불구하고 자체 검증 결과가 좋지 못한 결과를 보였고, 이는 테스트 데이터 집합을 이용한 정확도 검증에서도 4종의 피부질환에 대해 평균 71.5%로 여드름에 대해 89.3%로 가장 높고, 한포진은 56.5%의 낮은 정확도를 보여 학습 시 검증과 유사한 결과를 보인다.

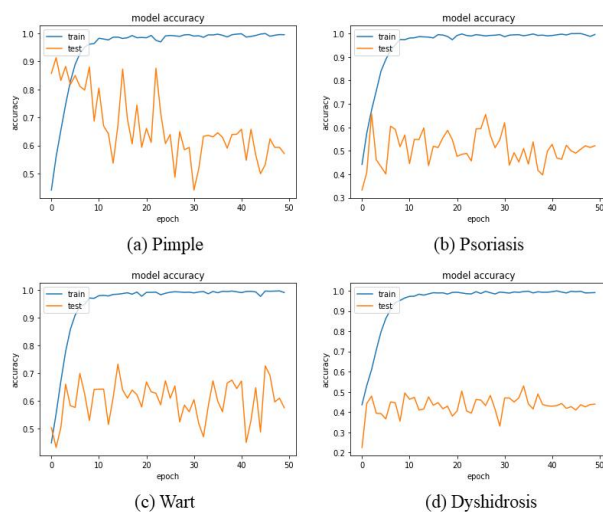


Fig. 5. The results of CNN training model

2. ResNet Training Model

ResNet 알고리즘은 신경망 계층의 수를 50, 101, 152로 구분하여 4종의 피부질환을 각각 학습하도록 하였다. Fig. 6~8은 학습 깊이 별 ResNet 모델의 학습 결과이다.

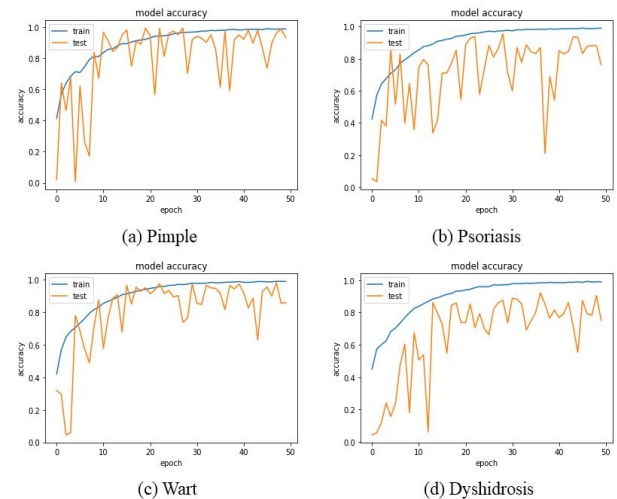


Fig. 6. The results of ResNet-50 training model

이상의 ResNet 학습 모델을 3,334개의 테스트 데이터 집합으로 4종의 피부질환을 식별한 결과는 Fig. 9와 같다. 정확도는 학습 깊이에 따라 차이가 있으며, 학습 깊이 50(ResNet-50)의 경우 평균 91.6%, 101(ResNet-101)의 경우 평균 93.6%, 152(ResNet-152)의 경우 평균 86.4%의 정확도를 보인다. 질환별 식별 정도는 3가지 학습 모델 모두 여드름과 사마귀에 대해 식별(95.1%)이 잘 이루어진 것에 반해 한포진의 식별(82.2%)이 다소 낮게 나타났다.

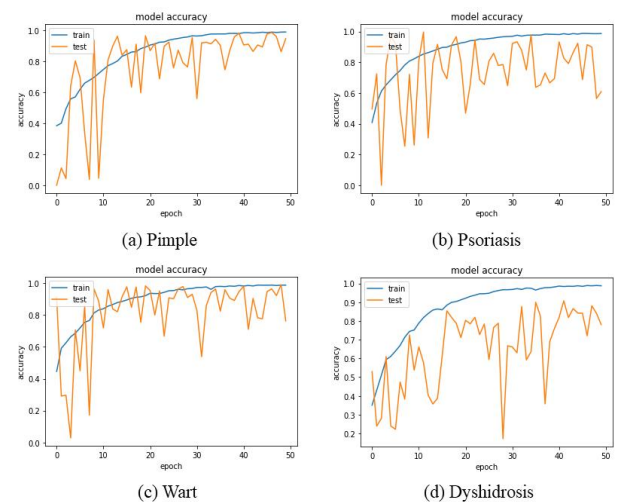


Fig. 7. The results of ResNet-101 training model

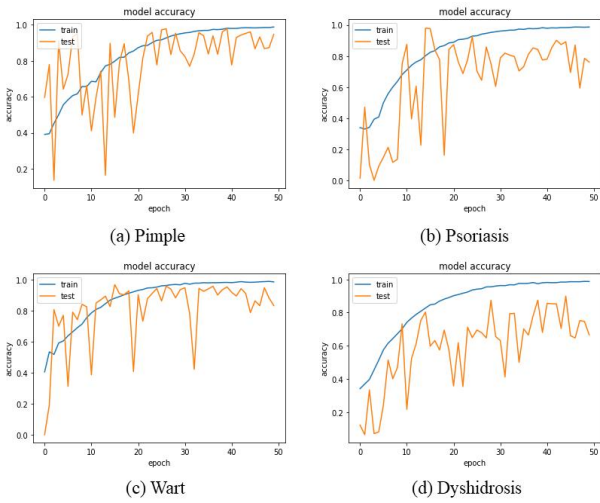


Fig. 8. The results of ResNet-152 training model

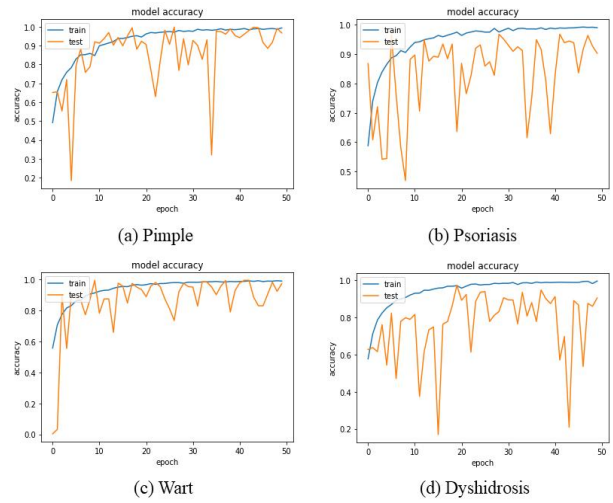


Fig. 10. The results of SE-ResNet-50 training model

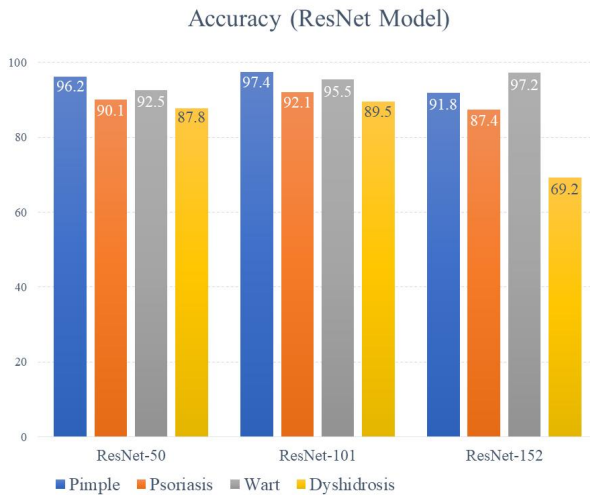


Fig. 9. The results of accuracy test under ResNet model

한편, 학습 깊이를 50에서 101로 증가시켰을 때 2%의 정확도 증가 효과를 볼 수 있었으나, 152로 증가시켰을 때는 오히려 정확도가 5.3% 감소하였다. 이는 CNN 기반 ResNet의 경우 학습 깊이가 일정 부분 이상 증가하면 학습효과가 감소하는 특성이 반영된 결과이다.

3. SE-ResNet Training Model

ResNet에 SE block을 추가한 SE-ResNet 알고리즘 역시 ResNet과 같이 학습 깊이를 50, 101, 152로 구분하여 4종의 피부질환을 학습하였으며, 이의 결과는 Fig. 10~12와 같다. 학습 진행 중 검증 결과에서 보이는 바와 같이 SE-ResNet의 4종의 피부질환에 대한 학습이 다른 두 알고리즘에 비해 대체적으로 잘 이루어지는 것으로 검증되고 있음을 알 수 있다. 특히 여드름과 사마귀의 학습이 잘 이루어진 것으로 확인되며, 한포진의 경우도 다른 두 알고리즘에 비해 개선되어진 결과를 보인다.

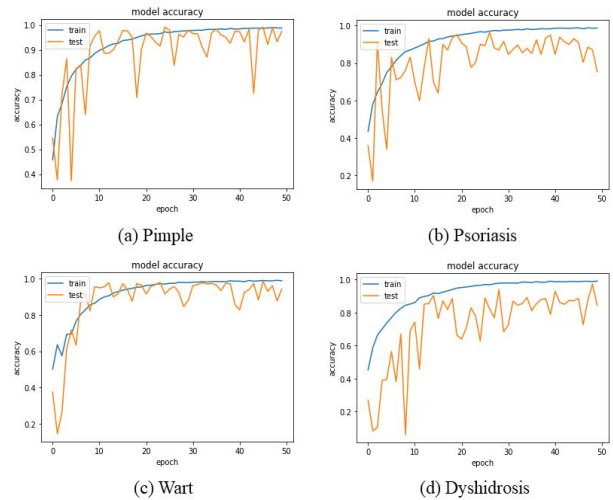


Fig. 11. The results of SE-ResNet-101 training model

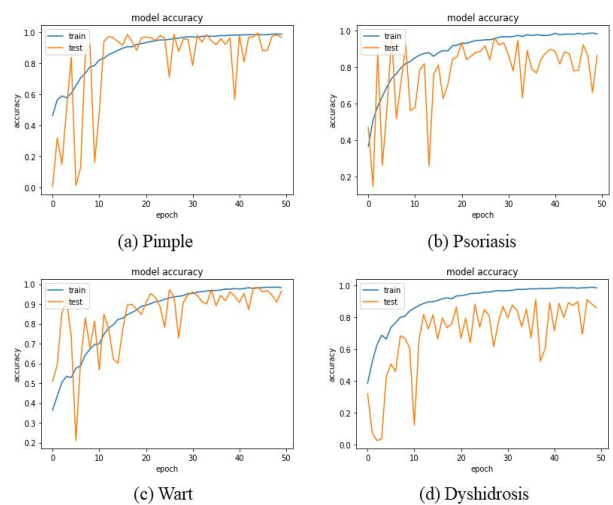


Fig. 12. The results of SE-ResNet-152 training model

학습이 완료된 SE-ResNet 모델을 학습에 사용하지 않은 3,334개의 테스트 데이터 집합으로 4종의 피부질환을 식별하여 모델의 정확성을 검증하였다. Fig. 13은 3종의 SE-ResNet 모델의 검증 결과이다.

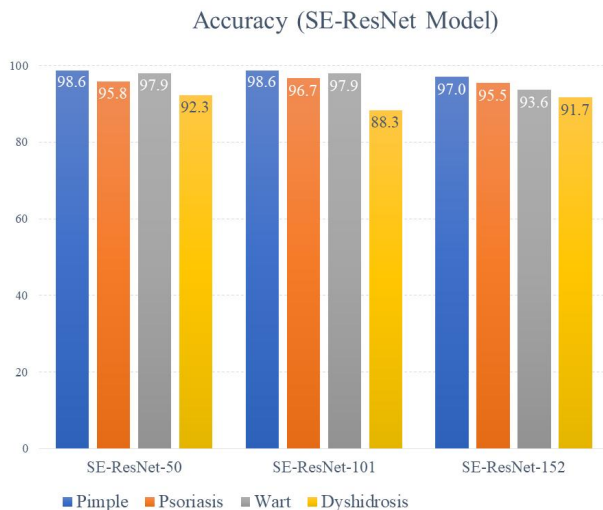


Fig. 13. The results of accuracy test under SE-ResNet model

정확도는 학습 깊이에 따라 큰 차이가 없으며, SE-ResNet-50의 경우 평균 96.2%, SE-ResNet-101의 경우 평균 95.4%, ResNet-152의 경우 평균 94.5%의 정확도를 보인다. 질환별 식별 정도는 3가지 학습 모델 모두 여드름에 대한 식별이 98.1%로 가장 잘 이루어졌고, 사마귀 96.5%, 건선 96.0%, 한포진 90.8% 순으로 식별되어 졌다. 또한, 학습 깊이 50에서의 정확성이 학습 깊이가 많은 다른 2종의 모델보다 우수한 결과를 보였다.

이상의 CNN 기반 딥러닝 알고리즘을 미용 관련 피부 질환에 적용하여 실험적으로 비교한 결과 CNN이 평균 71.5%, ResNet이 평균 90.6%, SE-ResNet이 평균 95.3%의 정확도를 보였고, 학습 깊이를 다르게하여 비교한 결과 50개의 계층 구조를 갖는 SE-ResNet-50 모델이 평균 96.2%의 정확도로 가장 효과적임을 보였다. 이를 미용 관련 피부질환을 대상으로 학습 데이터의 양과 질을 보다 확대한다면, 학습효과의 향상과 이를 기반으로 하는 서비스의 신뢰성 향상을 기대할 수 있다.

V. Conclusion

본 논문에서는 CNN 기반의 딥러닝 알고리즘 3종을 대상으로 미용 관련 피부질환인 여드름, 건선, 사마귀, 한포

진의 인식 효과성을 실험적으로 비교하였다. 실험결과 CNN 알고리즘 기반의 학습 모델이 평균 71.5%, ResNet 알고리즘 기반의 학습 모델이 평균 90.6%를 보였고, SE-ResNet 알고리즘 기반의 학습 모델이 평균 95.3%로 가장 높았다. 학습 깊이를 50, 101, 152로 구분하여 실험한 SE-ResNet의 결과에서 학습 깊이 50의 경우 평균 96.2%의 정확도를 보여 4종의 미용 관련 피부질환의 인식을 위해 가장 효과적임을 보였다. 특히 실험을 통해 피부 미용 관련 질환의 학습모델 개발을 위해서는 적절한 깊이의 학습이 필요 이상의 학습 깊이보다 우수한 정확도를 보임을 실험적으로 검증하였으며, 이를 통해 현실에서 손쉽게 활용할 수 있는 딥러닝 기반 피부질환 식별 모델 및 응용의 개발이 가능함을 보였다. 본 연구의 결과를 바탕으로 향후 학습 데이터의 양과 질의 확대를 통해 별도의 장비와 추가적인 지식 없이 일반인들도 쉽고 간단하게 미용 관련 피부질환의 인식 및 치료 방법 안내 등이 가능한 모바일 기반의 어플리케이션 개발 및 신뢰성 있는 피부질환 판단 정보를 제공하여, 피부 관리 및 피부질환 치료 솔루션과 연계할 수 있도록 치료와 개선을 위한 의료 및 미용 제품의 추천이 가능한 비즈니스 모델로 확장할 예정이다. 최종적으로 본 연구의 결과는 미용 관련 피부질환 식별을 위한 학습효과의 향상을 바탕으로 누구나 쉽게 사용할 수 있는 서비스의 신뢰성 향상과 언택트 기반의 피부미용 관련 산업의 활성화에 기여할 것으로 기대한다.

REFERENCES

- [1] Y. LeCun, Y. Bengio, and G. Hinton, "Deep Learning," *Nature*, Vol. 521, No. 7553, pp. 436-444, May, 2015. DOI: 10.1038/nature14539.
- [2] G. Litjens, T. Kooi, B. E. Bejnordi, A. Setio, F. Ciampi, M. Ghafoorian, J. Van der Laak, B. Van Ginneken and C. I. Sanchez, "A Survey on Deep Learning in Medical Image Analysis," *Medical Image Analysis*, Vol. 42, pp. 60-88, December, 2017. DOI: 10.1016/j.media.2017.07.005.
- [3] M. N. Bajwa, M. I. Malik, S. A. Siddiqui, A. Dengel, F. Shafait, W. Neumeier, and S. Ahmed, "Two-stage Framework for Optic Disc Localization and Glaucoma Classification in Retinal Fundus Images using Deep Learning," *BMC Medical Informatics and Decision Making*, Vol. 19, Article No. 136, July, 2019. DOI: 10.1186/s12911-019-0842-8.
- [4] P. Teare, M. Fishman, O. Benzaquen, E. Toledano, and E. Elnekave, "Malignancy Detection on Mammography Using Dual

- Deep Convolutional Neural Networks and Genetically Discovered False Color Input Enhancement,” *Journal of Digital Imaging*, Vol. 30, No. 4, pp. 499–505, August, 2017. DOI: 10.1007/s10278-017-9993-2.
- [5] M. N. Bajwa, Y. Taniguchi, M. I. Malik, W. Neumeier, A. Dengel, S. Ahmed, Y. Zheng, B. M. Williams, and K. Chen, “Combining Fine-and Coarse-Grained Classifiers for Diabetic Retinopathy Detection,” In *Proceedings of the Annual Conference on Medical Image Understanding and Analysis, CCIS*, Vol. 1065, pp. 242–253, July 2019. DOI: 10.1007/978-3-030-39343-4_21
- [6] M. Abedini, N. C. F. Codella, J. H. Connell, R. Garnavi, M. Merler, S. Pankanti, J. R. Smith, and T. Syeda-Mahmood, “A generalized framework for medical image classification and recognition,” *IBM Journal of Research and Development*, Vol. 59, No. 2/3, pp. 1:1-1:18, March, 2015. DOI: 10.1147/JRD.2015.2390017.
- [7] C.-C. Jay Kuo, “Understanding Convolutional Neural Networks with Mathematical Model,” *Journal of Visual Communication and Image Representation*, Vol. 41, pp. 406-413, November, 2016. DOI: 10.1016/j.jvcir.2016.11.003.
- [8] K. He, X. Zhang, S. Ren, and J. Sun., “Deep Residual Learning for Image Recognition,” in *Proc. of the IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2016*, pp. 770-778, IEEE, June, 2016. DOI: 10.1109/CVPR.2016.90.
- [9] J. Hu, L. Shen, and G. Sun, “Squeeze-and-Excitation Networks”, in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR 2018*, IEEE, pp. 7132-7141, June, 2018. DOI: 10.1109/CVPR.2018.00745.
- [10] A. Esteva, B. Kuprel, R. A. Novoa, S. M. Swetter, H. M. Blau, and S. Thrun, “Dermatologist-level Classification of Skin Cancer with Deep Neural Networks,” *Nature*, Vol. 542, pp. 115–118, February, 2017. DOI: 10.1038/nature21056.
- [11] K. Simonyan and A. Zisserman, “Very deep convolutional networks for large-scale image recognition,” *arXiv preprint arXiv: 1409.1556*.
- [12] U. Dorj, K. Lee, J. Choi, and M. Lee, “The Skin Cancer Classification using Deep Convolutional Neural Network,” *Multimed Tools and Applications*, Vol. 77, Issue 8, pp. 9909–9924, Springer, February, 2018. DOI: 10.1007/s11042-018-5714-1.
- [13] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” *Communications of the ACM*, Vol. 60, No. 6, ACM, May 2017. DOI: 10.1145/3065386.
- [14] P. Tschandl, C. Rosendahl, B. N. Akay, et al., “Expert-Level Diagnosis of Nonpigmented Skin Cancer by Combined Convolutional Neural Networks,” *JAMA Dermatol*, Vol.155, No. 1, pp. 58-65, American Medical Association, Jan. 2019. DOI: 10.1001/jamadermatol.2018.4378.
- [15] J. S. Alarifi, M. Goyal, A. K. Davison, D. Dancey, R. Chan, and M. H. Yap, “Facial Skin Classification using Convolutional Neural Networks”, *Proc. 14th Int. Conf. Image Anal. Recognit. (ICIAR 2017)*, LNCS, Vol. 10317, Springer, pp. 479-485, June, 2017. DOI: 10.1007/978-3-319-59876-5_53.
- [16] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna, “Rethinking the Inception Architecture for Computer Vision,” *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, December, 2016, pp. 2818-2826, DOI: 10.1109/CVPR.2016.308.
- [17] B. Ahmad, M. Usama, C. Huang, K. Hwang, M. S. Hossain and G. Muhammad, “Discriminative Feature Learning for Skin Disease Classification Using Deep Convolutional Neural Network,” *IEEE Access*, Vol. 8, pp. 39025-39033, IEEE, February, 2020. DOI: 10.1109/ACCESS.2020.2975198.
- [18] C. Szegedy, S. Ioffe, V. Vanhoucke and A. A. Alemi, “Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning”, in *Proceedings of the Thirty-First AAAI Conference on Artificial Intelligence (AAAI 2017)*, pp. 4278–4284, AAAI Press, February, 2017.
- [19] A. Pal, S. Ray, and U. Garain, “Skin Disease Identification from Dermoscopy Images using Deep Convolutional Neural Network,” *arXiv preprint arXiv:1807.09163*, 2018.
- [20] G. Huang, Z. Liu, L. V. D. Maaten, and K. Q. Weinberger, “Densely Connected Convolutional Networks,” in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017*, IEEE, pp. 2261-2269, July, 2017. DOI: 10.1109/CVPR.2017.243.
- [21] M. Sandler, A. Howard, M. Zhu, A. Zhmoginov, and L. Chen, “MobileNetV2: Inverted Residuals and Linear Bottlenecks,” in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, CVPR 2018*, IEEE, pp. 4510-4520, June, 2018. DOI: 10.1109/CVPR.2018.00474.

Authors



Chang-Hui Bae is an Undergraduate Student in Department of Aeronautical Software Engineering, Kyungwoon University. He is interested in A. I., embedded programming, and software testing.



Won-Young Cho is an Undergraduate Student in Department of Aeronautical Software Engineering, Kyungwoon University. She is interested in embedded programming, block chain, and computer security.



Hyeong-Jun Kim is an Undergraduate Student in Department of Aeronautical Software Engineering, Kyungwoon University. He is interested in embedded programming, big data, and software testing.



Ok-Kyoon Ha received the BS degree in Computer Science under the Bachelort's Degree Examination Law for Self-Education from National Institute for Lifelong Education, and the MS and Ph.D. degree in

Informatics from Gyeongsang National University in 2007 and 2012, respectively. He is currently a Professor in Department of Aeronautical Software Engineering, Kyungwoon University. His research interests including parallel and distributed programming, embedded system programs, dependable software, software testing, and software development activities for avionics.