

# A Study on Facial Skin Disease Recognition Using Multi-Label Classification

Chae Hyun Lim<sup>†</sup> · Son Min Ji<sup>††</sup> · Kim Myung Ho<sup>†††</sup>

## ABSTRACT

Recently, as people's interest in facial skin beauty has increased, research on skin disease recognition for facial skin beauty is being conducted by using deep learning. These studies recognized a variety of skin diseases, including acne. Existing studies can recognize only the single skin diseases, but skin diseases that occur on the face can enact in a more diverse and complex manner. Therefore, in this paper, complex skin diseases such as acne, blackheads, freckles, age spots, normal skin, and whiteheads are identified using the Inception-ResNet V2 deep learning mode with multi-label classification. The accuracy was 98.8%, hamming loss was 0.003, and precision, recall, F1-Score achieved 96.6% or more for each single class.

Keywords : Deep Learning, Multi-Label Classification, Skin Diseases

## 다중 레이블 분류를 활용한 안면 피부 질환 인식에 관한 연구

임 채 현<sup>†</sup> · 손 민 지<sup>††</sup> · 김 명 호<sup>†††</sup>

## 요 약

최근 안면 피부 미용에 대한 사람들의 관심이 높아짐에 따라 딥 러닝을 활용한 안면 피부 미용을 위한 피부 질환 인식 연구가 진행되고 있다. 이러한 연구들은 여드름을 비롯한 다양한 피부 질환을 인식한다. 기존의 연구들은 단일 피부 질환만을 인식하지만, 안면에 발생하는 피부 질환은 더 다양하고 복합적으로 발생할 수 있다. 따라서 본 논문에서는 Inception-ResNet V2 모델을 활용하여 다중 레이블 분류 방법으로 여드름, 블랙헤드, 주근깨, 검버섯, 일반 피부, 화이트헤드에 관한 복합적인 피부 질환을 인식한다. 사용한 평가 지표 중 정확도는 98.8%, 해밍 손실은 0.003을 달성하였고, 단일 클래스별 정밀도, 재현율, F1-점수는 모두 96.6% 이상을 달성하였다.

키워드 : 딥 러닝, 다중 레이블 분류, 피부 질환

## 1. 서 론

현대 사회에서 외향적인 요소가 중요해짐에 따라 남녀노소 모두 피부 미용에 관심이 많아지고 있다. 이런 안면 피부 미용에 가장 큰 방해물은 피부에 생기는 피부 질환이다. 피부에 생기는 피부 질환은 여드름, 블랙헤드, 주근깨, 검버섯, 화이트헤드 등 다양한 종류가 있다[1].

이런 피부 질환 중 특히 사람들을 괴롭히는 것이 여드름이다. 여드름은 털구멍이나 피지샘이 막혀서 생기는 피부

질환으로 사춘기 청소년 시절부터 성인에 이르기까지 나이에 상관없이 피부에 일어날 수 있는 흔한 피부 질환이다. 요즘 미세먼지와 COVID-19로 인해 마스크를 착용하는 경우가 증가함에 따라 안면 피부에 여드름의 발생이 더욱 증가하고 있다. 여드름의 경우 시간이 지남에 따라 사라지긴 하나 잘못 관리할 경우 염증이 더 심해져 흉터가 남을 수 있기 때문에 관리가 필요한 피부 질환이다.

여드름은 그 종류가 다양하다. 좁쌀 여드름이라고 부르는 화이트헤드, 코 주변에 피지가 검게 산화되어 변한 블랙헤드, 그리고 노란색에서 붉은색을 띄는 여드름까지 다양한 종류가 있으며 각기 다른 관리법이 요구된다.

여드름뿐만 아니라 사춘기 청소년들을 주로 괴롭히는 피부 질환에는 주근깨가 있다. 주근깨는 황갈색의 작은 색소 반점인데 특히 안면 전체적으로 발생하기 때문에 결점이 없는 피부를 원하는 경우에 큰 영향을 미치는 질환이다.

<sup>†</sup> 준 회원 : 송실대학교 소프트웨어학과 석사과정  
<sup>††</sup> 준 회원 : 송실대학교 융합소프트웨어학과 석사과정  
<sup>†††</sup> 종신회원 : 송실대학교 소프트웨어학과 교수  
Manuscript Received : March 29, 2021  
First Revision : May 18, 2021  
Second Revision : July 2, 2021  
Accepted : July 14, 2021  
\* Corresponding Author : Kim Myung Ho(kmh@ssu.ac.kr)

여드름과 주근깨가 청소년들의 피부 미용에 방해요소가 된다면 성인의 피부 미용을 방해하는 요소로 검버섯이 있다. 검버섯은 주로 40세 이상의 성인에게 많이 나타나는 연갈색에서 검은색의 반점이다. 최근에는 자외선 영향을 많이 받아 검버섯이 생기는 사람들이 늘고 있고, 발견되는 시기마저 앞당겨지고 있다.

이런 피부 질환을 분류하기 위해 많은 연구들이 진행되고 있고, 대부분의 연구에서 피부 질환 분류는 한 이미지에 한 가지 피부 질환만 인식이 가능하다. 하지만 피부 질환은 한 가지만 발견되지 않는다. 여드름만 하더라도 그 종류는 다양하며 동시에 발견 될 수 있다. 또한 나이에 따라 다르게 발견되었던 피부 질환마저도 자외선의 영향으로 나이의 경계가 모호해졌다. 기존의 연구로는 복합적으로 발견되는 피부 질환을 올바르게 인식할 수 없기 때문에 피부 질환을 복합적으로 인식하는 연구가 필요하다.

따라서 본 논문은 다중 레이블 분류 방식으로 Inception-ResNet V2 모델을 훈련하여 단일 피부 질환을 인식할 뿐만 아니라 복합 피부 질환을 인식할 수 있는 방법을 제안한다.

본 논문은 다음과 같이 구성된다. 2장에서는 피부 질환 관련 연구를 소개하고, 3장에서 분석 및 설계 방법을 설명한다. 4장에서는 실험 및 결과를 요약하고, 5장에서 결론 및 향후 연구를 기술한다.

## 2. 관련 연구

### 2.1 단일 클래스 분류

이미지에서 단일 클래스 분류를 할 때 한 장의 이미지에 하나의 클래스가 존재하는 데이터 셋을 사용한다. 이때 클래스 수는 두 가지 이상이 될 수 있으며 분류의 결과는 학습된 클래스 중 한 가지가 된다. 예를 들어 분류하고자 하는 클래스가 강아지, 고양이, 새의 세 가지라면 각각의 클래스에는 강아지만 있는 이미지, 고양이만 있는 이미지, 새만 있는 이미지가 사용되며 분류 모델을 학습한 후 추론하고자 하는 이미지에 대해서는 강아지, 고양이, 새 중 하나의 클래스가 목표 이미지의 클래스로 분류된다.

### 2.2 다중 레이블 분류

이미지에서 다중 레이블 분류는 한 장의 이미지에 한 개 또는 두 개 이상의 클래스가 존재하는 데이터 셋을 사용한다. 예를 들어 클래스가 강아지, 고양이, 새를 분류하는 경우 2.1에서 설명한 바와 같이 단일 클래스 분류에서 사용되는 단일 이미지 데이터 셋과 강아지와 고양이 클래스, 고양이와 새 클래스 등 두 개 이상의 클래스가 한 장의 이미지에 함께 존재하는 복합 이미지 데이터 셋을 함께 학습한다. 추론 시에 복합 이미지를 추론하고자 하는 목표 이미지로 삼으면 해당 이미지는 강아지, 고양이, 새 중 결핍에 따라 결정되는 클래스로 모두 분류된다.

### 2.3 피부 질환 연구

딥 러닝의 발달로 피부 질환을 인식하기 위한 연구가 진행되고 있다.

흔한 피부 질환에 대한 연구들은 주로 여드름을 중심으로 연구되어 왔다. 여드름의 종류를 나누어 여드름의 종류를 분류하거나 안면에 있는 여드름 개수에 따라 심각도를 나누는 연구가 있다[2,3]. 7가지 종류의 여드름을 분류하기 위해 VGG16 네트워크 모델을 기반으로 안면 이미지를 슬라이딩 윈도우 방식을 사용해 안면 이미지를 분할하고, 이를 입력 이미지로 사용해 먼저 피부인지 아닌지 이진 판별을 한다[4]. 그리고 피부로 분류된 이미지에 대해 다시 입력 이미지로 사용하여 구진, 낭포, 블랙헤드, 일반 피부, 농포, 화이트헤드, 결절의 7가지 클래스를 분류한다. AcneNet 모델은 47개의 컨볼루션 레이어를 쌓은 형태의 모델을 사용하며 화이트헤드, 낭포, 흉터종 여드름, 블랙헤드, 농포 등의 5가지 여드름을 분류한다[5].

심각한 피부 질환에 관한 연구들은 까만 점이 흑색종인지 악성 피부암인지 구분하는 등 심각한 피부 질환을 다룬다. 연구들은 의학적 관점에서 피부 질환을 분류하고 얼굴 뿐만 아니라 신체 모든 부위의 피부 질환을 다룬다. 얼굴에서 악성 흑색종, 복합 모반, 양성 각화증 등을 다루는 연구가 있으며[6,7], 신체 모든 부위에서 발생할 수 있는 악성과 양성 피부 질환들을 분류하는 연구가 있다[8-11].

하지만 기존의 연구들은 단일 클래스 분류를 통해 하나의 피부 질환 클래스를 추론한다. 안면에 블랙헤드와 여드름이 동시에 존재할 경우에도 한 가지 클래스로만 분류가 된다. 이러한 단일 클래스 분류 방식은 복합적으로 발생할 수 있는 안면 피부 질환을 두 개 이상 분류할 수 없다. 따라서 하나의 이미지에서 두 개 이상의 피부 질환 클래스를 복합적으로 인식하는 다중 레이블 분류 연구가 필요하다. 따라서 본 논문에서는 안면 피부 질환 이미지 인식을 다중 레이블 분류를 활용하여 복합 피부 질환 이미지를 분류하였다.

## 3. 분석 및 설계

3장에서는 3.1에서 피부 질환 분석, 3.2에서 사용한 데이터 셋을 소개하고, 3.3에서 사용한 모델과 구조를 소개한다.

### 3.1 피부 질환 분석

본 논문에서는 여드름(Acne), 블랙헤드(Blackhead), 주근깨(Freckle), 검버섯(Age Spot), 일반 피부(Skin), 화이트헤드(Whitehead)를 다룬다.

일반 피부는 아무 피부 질환이 없는 피부를 의미한다. 주근깨는 자외선의 영향을 받아 발생하고, 소아에게 흔하며 청소년에서 젊은 성인까지 주로 나타난다. 검버섯 또한 자외선의 영향을 받아 발생하고, 주로 40대 이상에게 발생한다. 주근깨와 검버섯은 같은 발생 원인을 가졌더라도 발생

하는 나이가 달라 동시에 나타나는 경우는 드물다. 반면에 여드름은 피지 분비에 영향을 받으며 블랙헤드와 화이트헤드가 원인이 되어 발생하기도 한다. 또한 나이와 관계없이 다양하게 발생한다. 그렇기 때문에 여드름의 경우 복합적으로 발생할 수 있다.

### 3.2 데이터 셋

본 논문에서는 여드름 클래스, 블랙헤드 클래스, 주근깨 클래스, 검버섯 클래스, 일반 피부 클래스, 화이트헤드 클래스로 총 6개의 단일 이미지를 가지는 클래스와 여드름과 블랙헤드 클래스, 여드름과 화이트헤드 클래스, 블랙헤드와 화이트헤드 클래스로 총 3개의 여드름 복합 이미지를 가지는 클래스를 다룬다. 이때 일반 피부 클래스를 다룬 이유는 정상 피부를 구별하기 위해서이다.

피부 질환 데이터 셋 중에서 안면이 포함된 피부 질환의 경우 공개된 데이터 셋이 많지 않다. 그래서 먼저 안면 피부 질환 이미지를 공개한 DermNet 공개 데이터 셋으로 데이터를 수집하였고, 부족한 데이터는 웹 서치를 통해 데이터를 수집하였다. 복합 이미지 경우 충분한 데이터 수를 확보하기 위해 포토샵을 사용하여 합성 이미지를 생성하였다. 각 클래스별로 300장의 이미지가 있으며, 훈련 셋과 테스트 셋을 무작위로 8:2로 나누어 훈련 셋으로 240장, 테스트 셋으로 60장을 사용하였다. 학습 데이터 수가 적을 경우 모델이 과적합에 빠질 수 있기 때문에 이를 방지하기 위해 이미지 증강 기법을 수행하였다. 이미지를 일정 크기 사이즈로 변경한 후 Inception-ResNet V2 모델의 입력 사이즈로 무작위 자르기(Random Crop) 하는 방법과 일정 확률로 이미지를 상하 반전, 이미지를 20도 좌우 회전하는 데이터 증강 기법을 활용한다. 클래스 별 이미지는 다음 Fig. 1과 같다.

### 3.3 모델 설명 및 다중 레이블 분류

Inception-ResNet V2 모델[12]은 Inception 모델[12]과 ResNet 모델[13]의 장점을 결합하여 기존의 두 모델보다 이미지 분류에서 좋은 성능을 보여준 모델이다.

단일 이미지 인식에서는 대부분 가장 밀단의 활성화 함수로 Softmax 함수를 사용한다. 하지만 Softmax 함수의 경우 출력값을 0에서 1 사이값으로 정규화하여 출력값들의 총합이 1이 되는 함수로 가장 큰 출력값을 가진 클래스가 해당 이미지의 클래스가 된다. 그렇기에 단일 클래스만을 분류하는 Softmax 함수로는 복합적인 피부 질환을 분류할 수 없다. 따라서 단일 클래스만을 분류하는 Softmax 함수 대신 0에서 1 사이값을 출력하는 Sigmoid 함수를 사용한다. Sigmoid 함수는 입력 이미지에 대해 각 클래스에 속할 확률을 계산한다. 입력 이미지의 클래스별 출력값이 지정 임계 값 이상인 경우 해당 클래스에 속함을 의미하며, 반대로 출력값이 지정 임계 값 이하인 경우 입력 이미지는 해당 클래스에 속하지 않음을 의미한다. 입력 이미지의 클래스별




Fig. 1. Examples of Skin Diseases Data

확률값 중 임계 값 이상인 클래스를 모두 인식할 수 있으므로 복합 이미지에 대한 다중 레이블 분류가 가능하다.

본 논문에서는 ImageNet으로 사전 훈련된 Inception-ResNet V2 모델을 가지고 분류기만 훈련하였으며, 가장 밀단의 활성화 함수를 Softmax에서 Sigmoid로 변경하여 다중 레이블 분류 방법으로 훈련한다. 본 논문에서 다중 레이블 분류를 적용하기 위해 사용한 모델 네트워크 구조는 다음 Fig. 2와 같다.

## 4. 실험 및 결과

본 논문에서는 평가 지표로 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1-점수, 해밍 손실(Hamming Loss)을 사용한다. 각 평가 지표는 다음 Equation (1)~(5)와 같다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

$$Hamming Loss = \frac{1}{NL} \sum_{i=1}^N \sum_{j=1}^L I(\hat{y}_i^j \neq y_i^j) \quad (5)$$

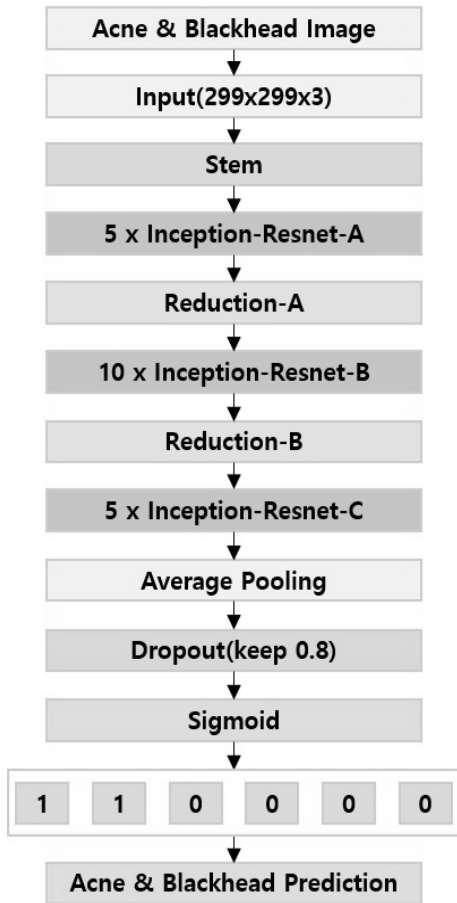


Fig. 2. Model Network with Multi-label Classification

수식에 사용된 기호들의 의미는 다음과 같다.  $TP$ (True Positive)는 정답이라고 예측했는데 실제로 정답인 경우,  $TN$ (True Negative) 틀렸다고 예측했는데 실제로 틀린 값인 경우,  $FP$ (False Positive)는 정답이라고 예측했으나 실제로는 틀린 값인 경우,  $FN$ (False Negative)는 틀렸다고 예측했으나 실제로는 정답 값인 경우를 의미한다.  $\hat{y}$ 은 모델이 예측한 값,  $y$ 는 실제 값을 의미하며,  $N$ 은 데이터의 수를 의미하고,  $L$ 은 라벨 수를 의미한다.  $y_i^j$ 는  $i$ 번째 데이터의  $j$ 번째 레이블을 의미한다.  $L$ 는 괄호 안에 조건을 만족하면 1 그렇지 않으면 0을 반환하는 함수이다. 평가 지표에서 정확도는 전체 예측값 중에서 올바르게 예측한 비율을 나타낸다. 정밀도는 모델이 정답이라고 분류한 것 중에서 실제 정답인 것의 비율이다. 재현율은 실제 정답인 것 중에서 정답이라고 예측한 것의 비율이다. 정밀도와 재현율은 서로 상호 보완적 관계이다. F1-점수는 정밀도와 재현율의 조화 평균을 구한 것이다. 이는 정밀도와 재현율을 모두 고려한 성능 평가 지표이다. 해밍 손실은 전체 레이블 중 잘못 분류된 레이블의 값을 구한 것으로 다중 레이블 분류에서 많이 사용되는 평가 지표이다. (1)-(4)의 평가 지표는 0에서 1 사이의 값을 가지며 1에 가까울수록 좋은 성능을 보이는 모델이

고, (5)의 평가 지표는 0에서 1 사이의 값을 가지며 0에 가까울수록 좋은 성능을 보이는 모델이다.

#### 4.1 단일 클래스 성능 평가 지표

Table 1은 단일 클래스 별 정밀도(Precision), 재현율(Recall), F1-점수에 관한 실험 결과이다. 예를 들어 복합 이미지를 가지고 있는 여드름의 경우 여드름 클래스, 여드름과 블랙헤드 클래스, 여드름과 화이트헤드 클래스에 여드름이 포함되기 때문에 성능 평가 시 여드름으로 분류한다. 다른 복합 이미지에서도 동일하게 적용한다.

대부분의 피부 질환이 좋은 성능을 보인다. 특히 여드름은 정밀도는 100.0%, 재현율은 98.8%, F1-점수는 99.3%를 달성하여 다른 피부 질환보다 잘 분류가 되었다. 여드름의 경우 다른 피부 질환들과 다르게 붉은색이라는 특징을 가지기에 모델이 잘 학습된 것으로 보인다. 다른 피부 질환들도 96.6% 이상을 달성하여 피부 질환을 잘 분류하였다.

#### 4.2 정확도 및 해밍 손실 실험 결과

Table 2는 데이터 셋을 무작위로 훈련 셋과 테스트 셋으로 8:2로 나누어 5회 반복한 정확도(Acc) 및 해밍 손실(HL)에 관한 실험 결과이다. 평균 정확도(Avg)는 97.4%를 달성하였고, 최고 정확도는 98.8%를 달성하였다. 최저 정확도는 96.6%를 달성하였다. 평균 해밍 손실은 0.005를 달성하였고, 최고 정확도 기준에서 해밍 손실은 0.003을 달성하였다. 최저 해밍 손실은 0.007로 각 레이블을 잘 인식하는 것으로 확인하였다.

#### 4.3 복합 이미지에 대한 혼동행렬

Table 3-5는 복합이미지에 대한 혼동행렬 표이다. Table 3-5에서 Fig. 1G - 1I는 Fig. 1에서 소개한 여드름과 블랙헤드, 여드름과 화이트헤드, 블랙헤드와 화이트헤드 피부 질환을 의미한다. 각 행은 모델이 예측한 피부 질환을

Table 1. Precision, Recall, F1-Score Experiment Results (unit : %)

	Precision	Recall	F1-Score
Acne	100.0	98.8	99.3
Blackhead	98.3	100.0	99.1
Freckle	98.3	100.0	99.1
Age Spot	100.0	96.6	98.2
Skin	98.3	98.3	98.3
Whitehead	99.4	99.4	99.4

Table 2. Accuracy and Hamming Loss with 5 Random Iterations

	1	2	3	4	5	Avg
Acc(%)	97.4	96.6	98.8	97.6	96.8	97.4
HL	0.006	0.007	0.003	0.006	0.007	0.005

Table 3. Confusion Matrix for Fig. 1G

Fig. 1G.		Actual	
		Positive	Negative
Prediction	Positive	60	1
	Negative	0	479

Table 4. Confusion Matrix for Fig. 1H

Fig. 1H.		Actual	
		Positive	Negative
Prediction	Positive	60	0
	Negative	0	480

Table 5. Confusion Matrix for Fig. 1I

Fig. 1I.		Actual	
		Positive	Negative
Prediction	Positive	60	0
	Negative	0	480

의미하고, 각 열은 실제 피부 질환을 의미한다. Table 4-5는 각 클래스에 대한 참긍정(True Positive) 60장, 참부정(True Negative) 480장을 잘 분류하였다. Table 3에서도 참긍정 60장은 잘 인식하였으나 거짓긍정(False Positive) 이미지가 하나 있는데, 이는 실제 여드름 이미지에서 여드름과 블랙헤드로 잘못 인식한 것으로 확인하였다. 각 혼동행렬표를 통해 복합 이미지 또한 잘 인식한 것을 확인하였다.

4.4 잘못 예측한 피부 질환 데이터

Fig. 3은 실험에서 잘못 인식한 피부 질환 데이터이다. 이는 최고 정확도 기준에서 평가하였다. Fig. 3A와 Fig. 3B를 보면 여드름을 블랙헤드, 여드름과 블랙헤드로 잘못




Fig. 3. False Case Skin Diseases Data (Actual Skin Disease / Predicted Skin Disease)

인식하였다. 여드름을 잘못 관리할 경우 검고 붉은색의 작은 흉터가 생길 수 있기 때문에 이와 비슷한 블랙헤드로 잘못 인식한 것으로 보인다. Fig. 3C와 Fig. 3D의 검버섯은 블랙헤드와 주근깨와 비슷한 갈색에서 검은색의 특징을 가지기 때문에 잘못 인식한 것으로 보인다. Fig. 3E와 Fig. 3F에서 알 수 있듯이 일반 피부와 화이트헤드도 서로 한 개씩 잘못 인식한 경우가 있는데 화이트헤드는 다른 피부 질환보다 붉거나 검은색을 띄기보다는 일반 피부와 비슷한 색을 띄고 피지가 올라온 특징을 가지기 때문에 서로 잘못 인식한 것으로 보인다. 이 외에 블랙헤드와 주근깨를 비롯한 복합 이미지 3개의 클래스를 모두 올바르게 인식한 것으로 보아 피부 질환의 복합 이미지를 잘 분류하는 것으로 확인하였다.

5. 결론

본 논문에서는 ImageNet 데이터 셋으로 사전 훈련된 Inception-ResNet V2 모델을 가지고 분류기만 다중 레이블 분류 방식으로 훈련하여 여드름, 블랙헤드, 주근깨, 검버섯, 일반 피부, 화이트헤드로 총 6개의 피부 질환과 여드름의 복합 이미지인 여드름과 블랙헤드, 여드름과 화이트헤드, 블랙헤드와 화이트헤드로 총 3개의 피부 질환을 인식하였다. 본 논문에서는 다양한 평가 지표를 사용하여 실험하였으며, 정확도는 데이터 셋을 무작위로 나누어 5회 반복하여 평가하였다. 평균 정확도는 97.4%를 달성하였고, 가장 높은 정확도는 98.8%를 달성하였다. 또한 다른 평가 지표에서도 좋은 성능을 보였다. 이를 활용하여 자신의 안면 피부 질환 이미지를 가지고 간편하게 진단하고 치료 및 관리가 가능할 것으로 보인다.

향후 연구로는 본 논문에서 분류한 피부 질환에서 클래스의 수와 복합 이미지의 수를 늘려 더 다양하고 정확한 피부 질환 분류를 할 수 있는 연구가 필요하다. 더욱 나아가 안면 피부 질환이 자주 발생하는 피부 영역인 이마, 코, 양볼, 턱 등으로 나누어 인식하거나 물체 탐지 모델로 확장하여 얼굴 전체에서의 피부 질환 위치까지 알려주는 작업이 필요하다.

References

[1] Korean Dermatological Society Textbook Compilation Committee, "Textbook of Dermatology," 6th ed., Korean Medical Books, 2014.  
 [2] X. Wu, N. Wen, J. Liang, Y. K. Lai, D. She, M. M. Cheng, and J. Yang, "Joint acne image grading and counting via label distribution learning," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp.10642-10651, 2019.

[3] T. Zhao, H. Zhang, and J. Spoelstra, "A computer vision application for assessing facial acne severity from selfie images," *arXiv preprint arXiv:1907.07901*, 2019.

[4] X. Shen, J. Zhang, C. Yan, and H. Zhou, "An automatic diagnosis method of facial acne vulgaris based on convolutional neural network," *Scientific Reports*, Vol.8, No.5839, pp.1-10, 2018.

[5] M. S. Junayed, A. A. Jeny, S. T. Atik, N. Neehal, A. Karim, S. Azam, and B. Shanmugam, "AcneNet-A deep CNN based classification approach for acne classes," in *2019 12th International Conference on Information & Communication Technology and System (ICTS)*, IEEE, pp.203-208, 2019.

[6] Z. Wu, et al., "Studies on different CNN algorithms for face skin disease classification based on clinical images," *IEEE Access*, Vol.7, pp.66505-66511, 2019.

[7] E. Goceri, "Analysis of deep networks with residual blocks and different activation functions: classification of skin diseases," in *2019 Ninth International Conference on Image Processing Theory, Tools and Applications (IPTA)*, IEEE, pp.1-6, 2019.

[8] M. A. Albahar, "Skin lesion classification using convolutional neural network with novel regularizer," *IEEE Access*, Vol.7, pp.38306-38313, 2019.


[9] X. Sun, J. Yang, M. Sun, and K. Wang, "A benchmark for automatic visual classification of clinical skin disease images," in *European Conference on Computer Vision*, Springer, Cham, pp.206-222, 2016.

[10] R. Sumithra, M. Suhil, and D. S. Guru, "Segmentation and classification of skin lesions for disease diagnosis," *Procedia Computer Science*, Vol.45, pp.76-85, 2015.

[11] N. Hameed, F. Hameed, A. Shabut, S. Khan, S. Cirstea, and A. Hossain, "An intelligent computer-aided scheme for classifying multiple skin lesions," *Computers*, Vol.8, No.3, pp.62, 2019.

[12] 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 AAAI Conference on Artificial Intelligence*, Vol.31, No.1, 2017.

[13] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp.770-778, 2016.



**임 채 현**

<https://orcid.org/0000-0002-3172-9772>  
 e-mail : immanual1995@naver.com  
 2019년 명지대학교 컴퓨터공학과(학사)  
 2019년 ~ 현 재 숭실대학교  
 소프트웨어학과 석사과정  
 관심분야 : 인공지능, 컴퓨터비전



**손 민 지**

<https://orcid.org/0000-0002-6595-1646>  
 e-mail : smgg@soongsil.ac.kr  
 2020년 숭실대학교 수학과(학사)  
 2021년 ~ 현 재 숭실대학교  
 융합소프트웨어학과 석사과정  
 관심분야 : 인공지능, 컴퓨터비전, 자연어처리



**김 명 호**

<https://orcid.org/0000-0002-1933-7987>  
 e-mail : kmh@ssu.ac.kr  
 1989년 숭실대학교 컴퓨터학부(학사)  
 1991년 포항공과대학교 전자계산학과  
 (석사)  
 1995년 포항공과대학교 전자계산학과  
 (박사)

1995년 ~ 현 재 숭실대학교 소프트웨어학과 교수  
 관심분야 : 프라이버시, 인공지능, 시스템소프트웨어,  
 공개 소프트웨어