JKIICE Journal of the Korea Institute of Information and Communication Engineering

한국정보통신학회논문지 Vol. 23, No. 4: 381~387, Apr. 2019

딥 러닝을 이용한 안면 여드름 분류 모델

정지오[1] · 여일연[1] · 정회경[2*]

Classification Model of Facial Acne Using Deep Learning

Cheeoh Jung[1] · Ilyeon Yeo[1] · Hoekyung Jung[2*]

[1]Graduate Student, Department of Computer Engineering, Paichai University, Daejeon, 35345 Korea
[2*]Professor, Department of Computer Engineering, Paichai University, Daejeon, 35345 Korea

요 약

의학계에 다양하게 인공지능을 적용하는데 있어 한계는 우선적으로 해석자의 병증 이미지를 해석하는데 주관적 견해와 광범위한 해석자, 육체적 피로감 등이다. 그리고 병증마다 주석 달린 데이터 셋을 수집하는데 기간이 오래 걸린다는 것과 개발된 딥러닝 학습 알고리즘의 성능 저하가 없으면서도 충분한 훈련 데이터를 얻을지에 대한 의문이 있다는 것이다.

이에 본 논문에서는 여드름 데이터 셋을 기준으로 기본 이미지를 수집할 때 선정 기준과 수집 절차에 대해 연구하고, Sequential 구조로 딥 러닝 기법을 적용하여 적은 손실률(5.46%)과 높은 정확도(96.26%)로 데이터를 분류하는 모델을 제안한다. Keras에서 기본 제공하는 모델과 비교실험을 통해 제안 모델의 성능을 비교 검증한다. 향후 본 논문에서 제안하는 여드름 분류 모델에 유사 현상들 적용하여 의학 및 피부 관리 분야에도 적용 가능할 것으로 예상된다.

ABSTRACT

The limitations of applying a variety of artificial intelligence to the medical community are, first, subjective views, extensive interpreters and physical fatigue in interpreting the image of an interpreter's illness. And there are questions about how long it takes to collect annotated data sets for each illness and whether to get sufficient training data without compromising the performance of the developed deep learning algorithm.

In this paper, when collecting basic images based on acne data sets, the selection criteria and collection procedures are described, and a model is proposed to classify data into small loss rates (5.46%) and high accuracy (96.26%) in the sequential structure. The performance of the proposed model is compared and verified through a comparative experiment with the model provided by Keras. Similar phenomena are expected to be applied to the field of medical and skin care by applying them to the acne classification model proposed in this paper in the future.

키워드 : 딥 러닝, 분류, 상관분석, 여드름, 컨볼루션 뉴럴 네트워크

Keywords : Deep Learning, Classification, Correlation Analysis, ACNE, CNN

Received 22 January 2019, **Revised** 10 February 2019, **Accepted** 4 April 2019

***Corresponding Author** Hoekyung Jung(E-mail:hkjung@pcu.ac.kr, Tel:+82-42-520-5640)
Professor, Department of Computer Engineering, Paichai University, Daejeon, 35345 Korea

Open Access http://doi.org/10.6109/jkiice.2019.23.4.381 print ISSN: 2234-4772 online ISSN: 2288-4165

ⓒThis is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(http://creativecommons.org/li-censes/by-nc/3.0/) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.
Copyright Ⓒ The Korea Institute of Information and Communication Engineering.

Ⅰ. 서 론

딥 러닝은 다양한 분야에 적용되는 다층 구조의 복잡한 신경망으로 기존의 복잡한 특징 추출과 패턴 분류의 두 단계를 한 단계로 통합하여 해결하는 자동화 기술이다[1]. 의료분야에서도 높은 신뢰도를 요구하는 인공지능 기술이 안전하고 효과적으로 적용되도록 돕는 방안들이 요구된다[2,3,4]. 큰 장벽 중 하나는 모든 병증마다 주석 달린 데이터 셋을 사용하기에 양이 충분하지 않다는 것이다. 또한, 딥 러닝 학습 알고리즘의 성능저하가 없으면서도 충분한 훈련 데이터를 얻을 수 있는지에 대한 의문을 갖는다[5,6,7].

이를 해결하기 위해 본 논문에서는 딥 러닝 학습 알고리즘의 성능저하가 없으면서도 충분한 훈련 데이터를 얻을 수 있도록 데이터를 수집 증량하여 학습해도 성능저하가 없는 분류모델을 제안한다. 실험에 사용하는 데이터는 다각적 기준을 설정하여 수집한 여드름 관련 데이터를 사용한다. 그리고 기존방법의 모델 2종과 비교실험하여 성능 평가하고자 한다. 이를 통해 데이터 셋이 제공되지 않는 분야의 정보 수집 방안 도출 및 산업계로의 관련 기술 확산과 유사 특징의 산업계로도 적용할 수 있을 것으로 사료된다.

Ⅱ. 분류 데이터 선정 및 데이터 셋 수집

데이터 셋이 존재하지 않는 새로운 시장에 딥 러닝 등의 기술을 적용하기 위해서는 시장의 성장성이 객관적으로 있는지부터 판단해야 하며, 관련 이미지들을 수집할 때 다각적으로 오해나 문제의 소지가 없는지 파악해야 한다. 이를 위한 순서를 살펴보면 그림 1과 같다. 우선적으로 접근하고자 하는 시장의 데이터 셋이 공동데이터 포털 등에서 존재 및 제공여부를 우선 확인할 필요가 있다. 존재한다면 제공받아 사용하면 된다. 공식적으로 제공되는 데이터 셋은 검증된 자료들로써 각종 법률적인 보호를 받을 수 있기 때문이다. 존재하지 않는다면 데이터 셋의 법적 검토 및 다각적 기준 설정을 통해 선정·수집해야 한다. 일반적으로 웹 서치를 통해 검색 되고, 수량이 10개 이상이 된다면 일괄 다운로드 프로그램의 도움으로 쉽게 수집하고 기준에 따라 개별적으로 분류한다. 기준별 기준 이미지들을 가능하면 많이 수집한다. 유관 이미지들을 구매하는 방법도 있으나 종류나 범위가 제한적이다.

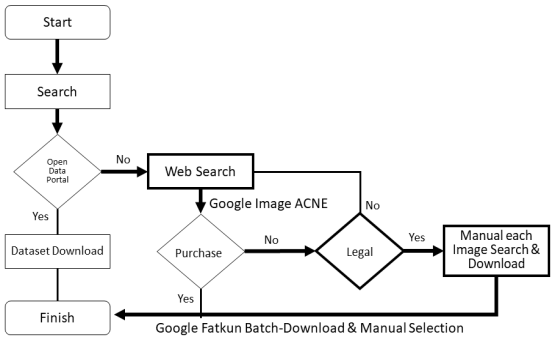

Fig. 1 Image Collection Procedure

본 논문에서 데이터 셋으로 선정한 여드름은 국가질병코드 L70으로 지정되어 있고, 양의학 및 한의학, 피부미용학 등에서 다각적인 치료 및 처치에 대한 접근이 가능한 특징이 있다[8,9]. 여드름은 특성상 각 땀샘구멍 단위로 진행되는 질병으로 시간의 흐름에 따라 면포성, 구진성, 농포성, 결절낭 여드름 순으로 진행된다. 특징을 살펴보면 단위 면적 당 여러 종류가 공존할 수도 있다. 우선 면포성 여드름(acne blemish)은 모낭 상부의 지방덩어리가 모공을 데워 그 위에 피부 각층이 덮여있어 하얗게 보이는 화이트 헤드와 모공으로 노출되면 시간이 지남에 따라 산소와 결합하여 검게 변하는 블랙헤드로 나뉜다. 구진성 여드름(acne vulgaris)은 눈에 띄는 면포, 붉은 구진, 고름이 나타나며, 농포가 뒤엉켜 중증 상태가 된다. 잘못 제거하면 부위가 빨갛게 충혈되거나 노란 염증 증상이 나타난다. 농포성 여드름(acne pustulosa)은 여드름이 각각 화농이 되어 피부 깊숙이 농포가 있게 된다. 노랗게 농이 잡혀 있는 단계로 겉보다 피부 속이 곪아 고름 주머니가 커진다. 잘못 건드리면 흉터가 된다. 마지막으로 결절낭 여드름(nodulocy-stic acne)은 치료시기를 놓치거나 잘못 치료하면 혹처럼 겉은 매우 딱딱하게 올라온 형태가 되고, 속으로 깊은 고름 주머니를 갖고 있다[8]. 위에서 언급된 현상은 산업현장의 판재를 기본으로 가공하는 관련 산업의 결함요인들과도 유사하다. 수집된 데이터 셋은 표 1과 같다.

Table. 1 Collected Images by Type

Types	Images
blemish	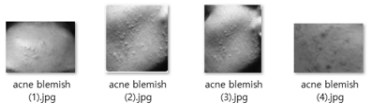 acne blemish (1).jpg acne blemish (2).jpg acne blemish (3).jpg acne blemish (4).jpg
pustulosa	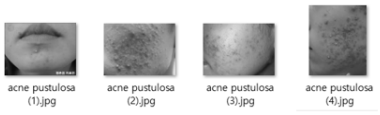 acne pustulosa (1).jpg acne pustulosa (2).jpg acne pustulosa (3).jpg acne pustulosa (4).jpg
vulgaris	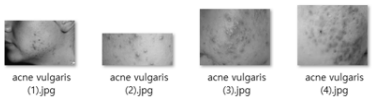 acne vulgaris (1).jpg acne vulgaris (2).jpg acne vulgaris (3).jpg acne vulgaris (4).jpg
nodulocystic	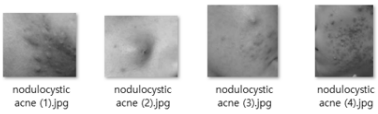 nodulocystic acne (1).jpg nodulocystic acne (2).jpg nodulocystic acne (3).jpg nodulocystic acne (4).jpg

데이터 셋 전처리 과정으로 딥 러닝 기법을 사용하기 위해서는 그림 2와 같이 일정량(Dp : Data proper amount) 이상의 데이터가 확보되어야 한다. 데이터 양이 많을수록 데이터 특성을 구축모델이 충분히 학습할 수 있고, 학습오류를 줄이고 분류에 대한 정확도를 증진시킬 수 있기에 Keras에서 제공하는 ImageGener ‐ ator를 활용한다.

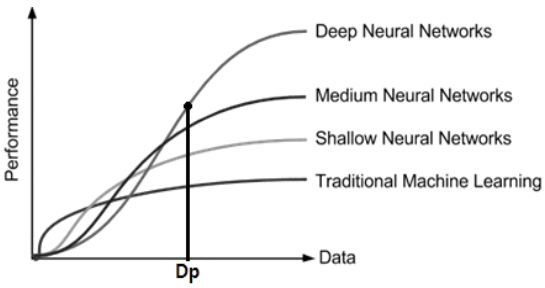

Fig. 2 Correlation between data amount and performance

증량된 데이터 셋은 개별 수집 분류할 때 발생될 수 있는 오류를 줄이고자 무작위로 섞은 후 학습용 데이터 셋과 검증용 데이터 셋으로 나누어 준비한다. 보통 비율은 7:3 혹은 7.5:2.5 등으로 한다. 상기 과정들을 도식화하면 그림 3과 같다.

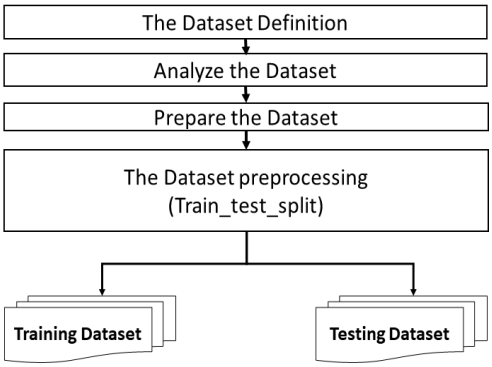

Fig. 3 Preprocessing of Dataset

Ⅲ. 이미지 분류 모델 설계 및 구현

본 장에서 모델 설계 및 구현에 사용한 개발 도구는 Keras (Anaconda3) 환경이며 H/W와 S/W의 주요 환경은 표 2와 같다. 모델 구현에는 Keras 환경에서 제공하는 Python Package 등을 사용한다.

Table. 2 Development Environment

Type	Description
Hardware	- OS : Windows10 (64bit) - CPU : Intel(R) Core i5-7200 2.50 GHz - RAM : 8 GB
Software	- Python 3.6.3 - Keras 1.0.6 - Tensorflow 1.10.0 - Scikit-learn 0.20.1

이미지 분류 모델은 Keras에서 제공되는 Sequent -ial 모델을 기준으로 구성하였다. Sequential 모델 클래스로 객체를 생성한다. add 메서드로 입력단부터 순차적으로 [Conv → Conv(+ReLu) → Pool → Drop → Conv(+ ReLu) → Pool → Dense(+ReLu) → Pool → Drop → Flat → Dense (+ReLu)] 등으로 계층을 추가한다. 입력 형태를 Image- Width × Image-Height × depth(32×32×3)로 정형화 하고, filter size는 3×3, Pooling size는 2×2로 통일하여 구성한다. Activation인수로 활성화함수(ReLu)를 설정한다. 단위 기능 계층들과 활성화 함수 등을 순차적으로 적층하여 사용할 수 있어 복잡한 구조에서 쉽게 적용가능한 장점이 있다. 구성된 모델은 그림 4와 같다.

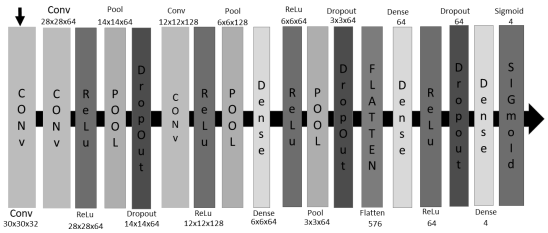

Fig. 4 Proposed Model Architecture

Compile 메서드로 모델을 완성한다. Loss 함수로 비용함수를 가장 많이 쓰이는 MSE(평균제곱오차)함수나 cross-entropy(교차 엔트로피) 혹은 자체 제작한 특정 함수로 설정할 수 있다, optimizer 함수로 SGD(확률적 경사하강법), Momentum, RMSProp, Adam 중에 택일하여 최적화 알고리즘을 설정한다. metrics로 손실률과 정확도로 성능을 평가한다. Fit 메서드로 훈련 데이터와 epoch를 통해 epoch 횟수만큼 순환반복 학습을 한다. 통상 32회로 설정하나 구성한 네트워크 에 따라 과적합화 문제가 발생될 수 있어 시행오차를 거쳐 횟수를 설정한다. 전체적인 모델 구성과 데이터 흐름은 그림 5와 같다.

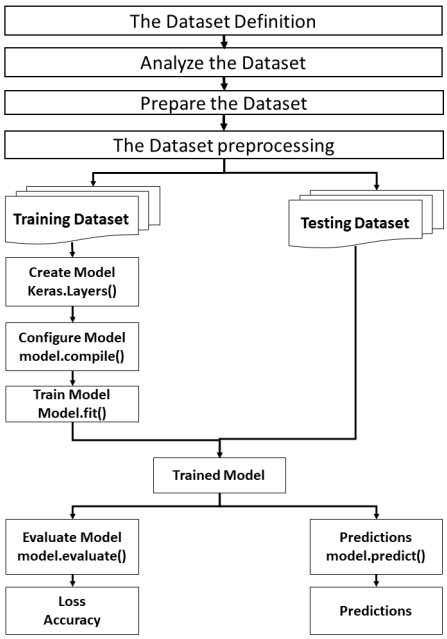

Fig. 5 Overall structure and data flow of the proposed model

앞서 언급된 선정 기준 등에 맞춰 개별 수집된 기준 이미지들을 증량기법을 통해 정리한 데이터 셋은 그림 6과 같다. 수량은 학습용 데이터 셋(X_train) 15594개, 검증용 데이터(X_test) 5199개로 총 20,793개이다.

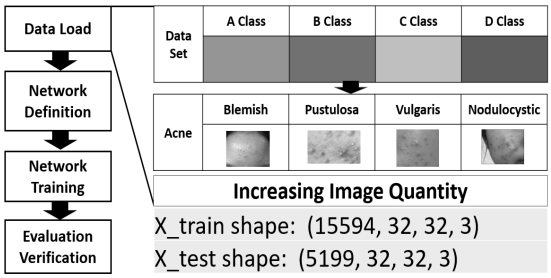

Fig. 6 Loading prepared dataset

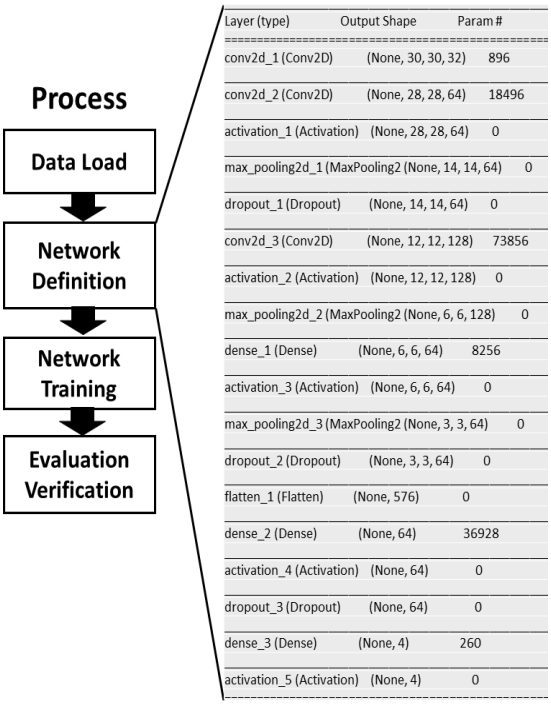

Fig. 7 Network Definition

앞서 언급된 설계 모델을 구현하면 그림 7과 같다. 모델을 어떻게 학습할 지를 loss는 cross entropy로, optimizer는 adam을 사용한다. 모델을 직접 학습시키는 것은 과적합화 문제가 있을 수 있어 epoch는 24회를 시행한다. 검증데이터를 통해 손실률과 정확도로 수치화

하여 재검증 한다. 실제 사용가능 여부를 판단하기 위해 예측검증을 실행한다.

Ⅳ. 실 험

제안 모델의 실험은 앞서 언급한 그림 5와 같은 순서로 진행한다. 최종적으로 분류 정확도와 손실률을 측정하고 예측 5회를 실시하여 모델의 사용가능성을 확인한다. 비교실험을 위해 대상을 Keras에서 예제로 제공하는 일반적인 CNN 모델(KECNN)과 Vgg 모델(KEVGG)로 한다.

공통적인 실험 조건은 표 3과 같다. 증량된 학습데이터를 32×32×3(ImageWidth×ImageHeight×depth) 형태로 정형화하여 15594개의 훈련 데이터를 입력하여 24회 순환 학습 반복하였다. 검증데이터로 5199개 사용하였다. 이 때, 기준 분류에 따른 오류를 줄이기 위한 무작위로 섞어서 훈련데이터와 검증데이터를 7:3으로 나누었다. 예측검증은 5회 실시하였다.

Table. 3 Conditions

• X_train shape	(15594, 32, 32, 3)
• X_test shape	(5199, 32, 32, 3)
• Train samples(Ea)	15594
• Validation samples(Ea)	5199
• Epoch(#)	24
• Predict(#)	5

결과적으로 첫 번째 Keras에서 예제로 제공하는 일반적인 CNN 모델(KECNN)의 실험 결과는 손실률 11.66%, 정확도 94.80%다. 그리고 순환반복 훈련에 따른 손실률(하향 수렴곡선) 및 정확도(상향 수렴곡선)의 수렴곡선은 그림 8과 같다. 데이터 셋의 무작위성으로 순환반복 훈련시 epoch 19~20회에서 손실률 및 정확도가 낮게 평가됨을 알 수 있다.

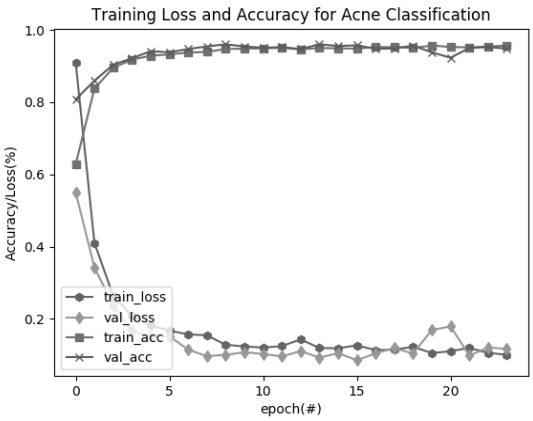

Fig. 8 Loss rate and Accuracy Convergence Curve (Typical CNN model provided by Keras)

두 번째로 Keras에서 예제로 제공하는 Vgg 모델(KEVGG)의 실험결과는 손실률 11.77%, 정확도 94.32%다. 그리고 순환반복 훈련에 따른 손실률(하향 수렴곡선) 및 정확도(상향 수렴곡선)의 수렴곡선은 그림 9와 같다. 데이터 셋의 무작위성으로 순환반복 훈련시 epoch 19~20회에서 손실률 및 정확도가 낮게 평가됨을 알 수 있다.

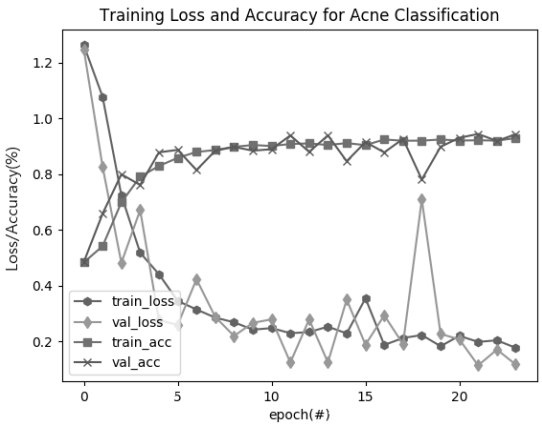

Fig. 9 Loss rate and Accuracy Convergence Curve (VGG model provided by Keras)

비교 실험 결과를 종합하면 표 4와 같다.

Table. 4 Result Composite Table

	KECNN	KEVGG	P.Model
Loss	11.66%	11.77%	5.46%
Accuracy	94.80%	94.32%	96.26%
Predict (#5)	100%	100%	100%
	True : 1, Predict : 1 True : 3, Predict : 3 True : 0, Predict : 0 True : 3, Predict : 3 True : 0, Predict : 0	True : 1, Predict : 1 True : 3, Predict : 3 True : 0, Predict : 0 True : 3, Predict : 3 True : 0, Predict : 0	True : 1, Predict : 1 True : 3, Predict : 3 True : 0, Predict : 0 True : 3, Predict : 3 True : 0, Predict : 0

제안 모델의 정확도는 96.26%, KECNN 모델은 94.80%, KEVGG모델은 94.32%로 측정되었다. 손실률은 제안 모델은 5.46%, KECNN 모델은 11.66%, KEVGG모델은 11.77%로 측정되었다. 예측 검증 5회 실시하였을 때 모든 모델이 5회 모두 예측되었다. 예측 검증을 통해 수집 제안한 데이터 셋을 기준으로 모두 사용 가능하다는 것이 검증되었다.

Ⅴ. 결 론

본 논문에서 제안하는 모델은 딥 러닝을 이용하는 이미지 분류 모델로 여드름(L70, Acne) 4종(면포성 : blemish, 농포성 : pustulosa, 구진성 : vulgaris, 결절낭 : nodulocystic)을 분류하는 연구를 하였다. 그리고 모델의 성능을 검증하기 위해 기능 실험을 진행하였다. 제안 모델에서는 성능 평가로 정확도와 손실률을 사용하며 모델의 정확도는 96.26%로 손실률 5.46%의 성능을 얻었다. 모델이 사용가능한지 판별하기 위해 예측실시결과 5회 모두 예측되어 여드름 이미지 분류에 적합한 모델이라고 검증하였다. 비교 실험으로 동일조건하에 Keras에서 제공하는 예시 2종(일반적인 CNN모델과 Vgg모델)을 사용하였다. 결과적으로 일반적인 CNN모델보다는 정확도가 1.46%, 손실률은 6.2%, Vgg모델보다는 정확도 1.94%, 손실률은 6.31% 차이가 났다.

향후 연구과제로는 기본 기술화된 CNN 및 딥 러닝 기법을 이용한 좀 더 대중성을 갖춘 DAQ 및 Smart Manufacture관련 분야 및 의료정보 관련분야에 적용하는 연구가 필요하며 이를 통해 정확성과 신뢰성을 개선할 수 있을 것으로 판단된다.

REFERENCES

[1] L. Liu, W. Ouyang, X. Wang, P. Fieguth, J. Chen, X. Liu, and M. Pietikainen, “Deep Learning for Generics Object Detection : A Survey”, *International Journal of Computer Vision*, pp. 1-30, Sep. 2018.

[2] H. Pratt, F. Coenen, S. Harding, and Y. Zheng, “Convolutional Neural Networks for Diabetic Retinopathy,” *International Conference On Medical Imaging Understanding and Analysis*, vol. 90, pp. 200-205, Jul. 2016.

[3] H. Bilen, and A. Vedaldi, “Weakly Supervised Deep Detection Networks,” *The IEEE Conference on Computer Vision and Pattern Recognition*, pp. 2846-2854, Dec. 2016.

[4] C. Cao, F. Liu, H. Tan, D. Song, W. Shu, W. Li, Y. Zhou, X. Bo, and Z. Xie, “Deep Learning and Its Applications in Biomdicine,” *Genomics, Protenomics & Bioinformatics*, vol. 16, Issue1, pp. 17-32, Feb. 2018.

[5] M. I. Razzak, S. Naz, and A. Zaib, “Deep Learning for Medical Image Processing: Overview, Challenges and Future,” *Computer Vision and Pattern Recognition*, vol. 26, pp. 323-350, Nov. 2017.

[6] E. Klang, “Deep learning and medical imaging,” *Journal of Thoracic Disease*, vol. 10, no. 3, pp. 1325-1328, Feb. 2018.

[7] G. Litjens, T. Kooi, B. E. Bejnordi, A. Arindra, M. Ghafoorian, and C. I.Sánchez, “A survey on deep learning in medical image analysis,” *Medical Image Analysis,* vol. 42, pp. 60-88, Dec. 2017.

[8] A. L. Zaenglein, A. L. Pathy, B. J. Schlosser, A. Alikhan, H. E. Baldwin, D. S. Berson, W. P. Bowe, E. M. Graber, S. W. Kang, J. E. Keri, J. J. Leyden, R. Reynolds, N. B. SilverBerg, L. F. SteinGold, M. M. Tollefson, J. S. Weiss, N. C. Dolan, A. A. Sagan, M. Stern, K. M. Boyer, and R. Bhushan, “Guidelines of care for the management of acne vulgaris,” *Journal of the American Academy of Dermatology*, vol. 74, no. 5, pp. 945-973, May. 2016.

[9] J. K. Than, L. F. Stein Gold, A. F. Alexis, and J. C. Harper, “Current Concepts in Acne Pathogenesis: Pathways to Inflammation,” *Seminars in Cutaneous Medicine and Surgery*, vol. 37, no. 3S, pp. 60-62, Jun. 2018.

정지오(Chee-Oh Chung)

1998년 금오공과대학교 전자통신공학과(공학사)
2000년 금오공과대학교 전자통신공학과(공학석사)
2019년 배재대학교 컴퓨터공학과 (공학박사)
※관심분야 : App Application, Cloud, IoT, DAQ Machine Learning

여일연(Ilyeon Yeo)

2000년 경북대학교 전자공학과(공학사)
2002년 경북대학교 전자공학과(공학석사)
2017년 ~ 현재 배재대학교 컴퓨터공학과(박사과정)
2002년 ~ 현재 한국과학기술정보연구원 선임연구원
※관심분야 : 그리드 컴퓨팅, 병렬 컴퓨팅, 보안, 정보 추천

정회경(Hoe-Kyung Jung)

1985년 광운대학교 컴퓨터공학과(공학사)
1987년 광운대학교 컴퓨터공학과(공학석사)
1993년 광운대학교 컴퓨터공학과(공학박사)
1994년 ~ 현재 배재대학교 컴퓨터공학과 교수
※관심분야 : 멀티미디어 문서정보처리, USN, IoT, Machine Learning, BigData, Embedded System