

# GAN 으로 합성된 흉부 X-ray 를 활용한 의료 인공지능 교육 모델에 관한 사례 연구

이규빈<sup>1\*</sup>, 윤예빈<sup>1\*</sup>, 함소진<sup>1\*</sup>, 배현진<sup>2</sup>, 유원상<sup>1</sup>

<sup>1</sup>선문대학교 정보통신공학과

<sup>2</sup>프로메디우스(주)

\*공동주저자

askailak@gmail.com, qsxdr0@naver.com, gakhls23@gmail.com,

hjbae@promedius.ai, wyou@sunmoon.ac.kr

## A Case Study on an Educational Model of Medical AI Using Chest X-ray Synthetized by GAN

Gyubin Lee<sup>1\*</sup>, Yebin Yoon<sup>1\*</sup>, Sojin Ham<sup>1\*</sup>, Hyun-Jin Bae<sup>2</sup>, Wonsang You<sup>1</sup>

<sup>1</sup>Dept. of Information and Communications Engineering, Sun Moon University

<sup>2</sup>Promedius Inc.

\*equally contributed

### 요 약

최근 AI 를 활용한 의료 진단 솔루션 시장이 크게 성장함에 따라 의료 인공지능 기술에 대한 대학 교육에 대한 수요가 증가하고 있지만, 개인정보 유출의 위험성 등으로 인하여 의료 데이터를 대학 교육에 활용하기 어려운 실정이다. 본 논문에서는 실제 의료 데이터 대신 생성적 적대 신경망(GAN)으로 합성된 흉부 X-ray 영상을 활용한 의료 인공지능 교육 모델의 사례를 제시한다. 프로메디우스(주)에 의해 제공받은 흉부 X-ray 합성영상을 사용하여, VGG-16 모델을 훈련하고 성능을 검증 및 평가하며 미세조정을 통해 성능을 개선하는 교육 모델을 구성하였다. 또한 교육모델이 의료 인공지능에 대한 학생들의 이해력 향상에 기여한 효과를 정량적으로 평가하였다.

### 1. 서론

인공지능(AI)을 활용한 의료 진단 솔루션이 병원, 대학 및 기업을 중심으로 국내외에서 활발하게 연구되고 있고 관련 시장이 크게 성장하고 있다. 이에 따라 의료 인공지능 전문가를 양성하기 위한 전문 교육 프로그램에 대한 수요가 증가하고 있다. 국내에서 교육 프로그램이 개발되고 있지만, 개인정보 유출의 위험성으로 인하여 대학 및 기업에서는 여전히 의료 데이터를 인공지능 교육 및 연구를 위해 활용하기에 어렵다.

이러한 문제를 해결하기 위해, 생성적 적대 신경망(Generative Adversarial Network, GAN) 등으로 합성된 의료영상을 활용한 의료 인공지능 모델 개발에 관한 연구가 최근 제안되었다. GAN 은 생성 모델과 판별 모델이 경쟁하면서 실제와 가까운 이미지, 동영상, 음성 등을 자동으로 만들어 내는 기계학습 방식의 하나이다[1]. Salehinejad et al.은 X-ray 영상에 대한 인공지능 분류 모델을 만드는 과정에서 실제 영상만을 사용한 경우보다 GAN 으로 생성된 영상을 추가하여 학습


하는 경우 실제 영상만을 사용한 경우보다 20% 높은 성능을 보임을 증명하였다[2]. 이후 GAN 으로 생성한 의료영상을 활용한 딥러닝 모델에 관한 연구가 활발히 이루어져 왔다[3-5].

GAN 으로 합성된 의료영상은 연구의 목적 뿐만 아니라 대학이나 기업에서 교육용으로도 활용할 수 있다. 고가의 의료 데이터를 구매하는 대신 합성영상을 저가에 확보하여 의료 인공지능 교육에 다양하게 활용할 수 있다.

본 연구에서는 GAN 으로 합성된 의료영상을 활용한 의료 인공지능 교육 모델의 사례를 제시한다. 2020년 11 월부터 2021년 1 월까지 선문대학교 정보통신공학과에서 여성공학 교육 프로그램의 일환으로 진행된 프로젝트로서, 의료인공지능 회사 프로메디우스(주)에 의해 제공받은 흉부 X-ray 합성영상을 사용한 의료 인공지능 교육 모델을 개발하고 시험하였다.

### 2. 흉부 X-ray 진단 모델

AI 기반 흉부 X-ray 진단 모델로서 VGG-16 모델을 사용하였다. VGG-16은 2014년 옥스포드 대학 연구팀



(그림 1) VGG-16 모델의 구조도

에 의하여 개발된 합성곱 신경망(convolutional neural network, CNN)의 네트워크이다[6]. 그림 1 과 같이 합성곱 계층(convolutional layer)과 풀링 계층(pooling layer)으로 구성되며, 완전 연결 계층(Fully connected layer)과 합성곱 계층 등 16 개의 층으로 심화한 것이 특징이다. 3x3 의 작은 필터를 사용한 합성곱 계층을 연속으로 거치고, 합성곱 계층을 연속으로 풀링 계층을 두어 크기를 절반으로 줄이는 과정을 반복하고 마지막에 완전 연결 계층을 통과하여 정상 및 비정상 여부의 확률을 예측한다. 확률에 기반하여, 입력 영상이 정상인지 비정상인지 여부를 분류한다.

각 계층에 적용되는 합성곱 필터는 크기가 클수록 연산량은 많아지고 학습할 파라미터의 수가 증가한다[7]. 활성화 함수(activation function)는 딥러닝 네트워크에서 각 계층에서 출력되는 값들을 비선형적으로 다음 계층에 전달하는 함수이다[7]. Sigmoid 함수는 입력 값이 일정 이상 올라가면 미분값이 0 으로 수렴하는 미분값 소실(Gradient Vanishing) 현상이 발생할 수 있고 함수값 중심이 0 이 아니므로 학습이 느려질 수 있다. Tanh 함수는 Sigmoid 와 유사하면서도 출력의 중심이 0 에 있어서 학습이 느려지는 문제는 보완할 수 있지만 미분값 소실 문제는 여전히 존재한다. ReLU(Rectified Linear Unit) 함수는 값이 0 보다 작거나 같으면 0, 0 보다 크면 선형 함수에 값을 대입한다. ReLU 는 음수 정보는 과감히 무시하고 양수 정보는 선형적으로 수용하기 때문에 다른 활성화 함수들보다 연산이 빠르고, 수렴 속도 또한 빠르다. 하지만, 값이 음수일 경우는 뉴런이 죽는(Dying ReLU)현상이 발생할 수 있다. 이러한 문제를 해결하기 위해 ELU(exponential linear unit) 함수는 지수 함수를 이용하여 입력이 음수일 경우 부드럽게 작은 음수 출력값을 허용한다.

합성곱 커널과 활성화 함수 등 모델 하이퍼 파라미터(hyperparameter)의 적절한 선택은 과적합을 예방하는데 중요하다. 과적합(overfitting)은 학습 데이터에만

나타나는 부수적인 특성들을 과하게 학습시켜서 새로운 데이터에 대하여 결과를 잘 예측하지 못하게 되는 문제를 말한다.

### 3. 실험 방법

총 5 명의 3~4 학년 학부생들이 실험에 참여하였다. 학부생들은 기계학습 및 합성곱 신경망 등에 대한 사전지식을 갖고 있었고, Keras API 를 사용하여 VGG-16 모델을 구현하였다[8]. 모델 훈련 및 실험은 프로메디우스(주)에서 제공한 아마존 웹 서비스(AWS) 클라우드 서버 상에서 수행되었다.

인공지능 교육에 사용할 데이터로서, 프로메디우스(주)가 서울아산병원 의료 데이터에 기반하여 GAN 으로 합성한 흉부 X-ray 영상 데이터셋을 사용하였다. 데이터셋은 정상 데이터 10,000 개와 비정상 데이터 10,000 개로 구성되었다. 비정상 데이터는 다양한 흉부 질환을 포함한다. 데이터는 훈련 데이터 60%, 검증 데이터는 20%, 테스트 데이터 20%로 구분하였다.

VGG-16 모델의 미세조정을 위해, 학생들로 하여금 합성곱 계층의 필터 크기 및 활성화 함수가 미치는 영향을 분석하도록 하였다. 먼저 합성곱 필터의 크기(kernel size)는 3x3 과 7x7 로 적용하였을 때 성능의 차이를 분석하였다. 다음으로 활성화 함수가 성능에 미치는 영향을 분석하였다. 본 실험에서는 학생들로 하여금 Sigmoid, Tanh, ELU 의 세가지 활성화 함수가 모델 성능에 미치는 영향을 분석하도록 하였다.


### 4. 실험 결과

그림 2 는 GAN 에 의해 합성된 흉부 X-ray 영상의 예시를 보여준다. 실제 촬영한 영상과 큰 차이가 없음을 알 수 있다. 모델의 훈련을 위한 모든 실험에서 batch\_size 는 64, epoch 스텝 수는(steps per epoch)는 94, epoch 의 수는 100, 검증 스텝(validation steps)은 25 로 동일하게 적용하였다.

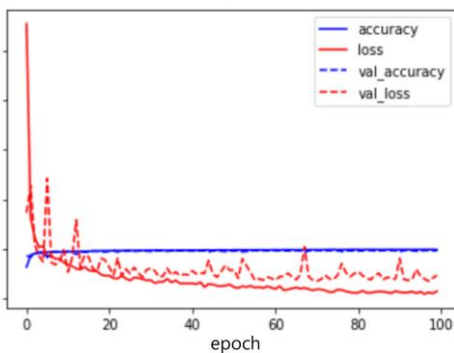


(그림 2) GAN 으로 합성된 흉부 X-ray 영상의 예

그림 3 은 합성곱 필터의 크기(kernel size)가 모델 성능에 미치는 영향을 분석한 결과를 보여준다. 훈련을 위한 손실함수(loss function)는 커널의 크기 7x7 보다 3x3 일 때 더 빠르게 감소한다. 또한, 검증을 위한 손실함수(validation loss)도 커널의 크기가 3x3 일 때 더 안정적으로 감소할 뿐만 아니라 훈련 손실(training loss)와의 격차도 적다. 이러한 결과는 커널의 크기가 3x3 일 때 7x7 일때보다 더 빠르게 모델 훈련이 이루어지며 과적합(overfitting) 문제가 더 작게 일어난다는 사실을 알 수 있다.




(a) 합성곱 필터 3x3 인 경우




(b) 합성곱 필터 7x7 인 경우

(그림 3) 합성곱 필터의 크기가 모델 성능에 미치는 영향


그림 4 는 활성화 함수가 모델 성능에 미치는 영향에 관한 결과를 보여준다. Sigmoid 와 Tanh 함수를 사용하였을 때 epoch 이 진행됨에 따라 훈련 손실함수와 검증 손실함수 사이에 큰 격차가 발생하였다. 반면, ELU 함수를 사용하였을 때는 훈련 손실함수와 검증 손실함수 사이에 큰 차이가 없었다. 이러한 사실은 ELU 함수를 사용하여 과적합 문제를 예방할 수 있음을 보여준다.



(a) 활성화 함수 Sigmoid 를 사용한 경우



(b) 활성화 함수 Tanh 를 사용한 경우




(c) 활성화 함수 ELU 를 사용한 경우

(그림 4) 활성화 함수가 모델 성능에 미치는 영향

다음으로 모델의 성능을 ROC curve 를 사용하여 비교하였다. ROC curve 는 True Positive Rate 와 False Positive Rate 에 대하여 다양한 임계값(threshold)에 대

한 이진분류기의 성능을 표시한 것이다. ROC curve 가 좌상단에 붙어있는 것이 좋은 성능을 표현하게 된다. 그림 5 는 세가지 활성화 함수에 대하여 모델의 성능을 ROC curve 를 사용하여 시각화한 결과를 보여준다. ELU, Tanh, Sigmoid 의 순으로 큰 AUC (Area under Curve) 값을 가지며 따라서 더 나은 분류 성능을 보임을 알 수 있다(AUC=0.996 for ELU, 0.976 for Tanh, 0.91 for Sigmoid).



(그림 5) 활성화 함수 간 ROC curve 비교

실험이 종료된 후 학생들에게 의료 인공지능 실무 능력과 이해도 향상에 관한 설문조사를 실시하였다. 설문은 1~5 등급으로 나누어 하나에 체크하도록 하였다. 설문 결과 총 5 명의 학생 중 3 명의 학생이 5 등급, 2 명의 학생이 4 등급에 체크하여, 평균적으로 92%의 만족도를 보였다.

## 5. 결론

본 연구에서는 GAN 으로 합성된 흉부 X-ray 영상을 활용한 의료 인공지능 교육 모델의 사례를 제시하였다. 의료인공지능 회사 프로메디우스(주)에 의해 제공받은 흉부 X-ray 합성영상을 사용하여 한 의료 인공지능 교육 모델을 개발하고 시험하였다.

본 연구는 합성 의료영상을 활용한 의료 인공지능 교육 모델을 교육 현장에서 성공적으로 실험한 사례를 보여준다. 92%의 만족도에서 나타나듯, 학생들은 VGG-16 모델을 직접 구축하고 미세 조정을 통해 합성곱 계층이 모델 훈련의 성능에 미치는 영향을 이해할 수 있었다. GAN 으로 합성된 흉부 X-ray 영상을 활용하여 AI 모델을 의료 진단에 적용하기 위한 실무 능력을 향상시킬 수 있었다.

후속 연구로서 합성 의료영상을 활용한 다양한 의료 인공지능 교육 모델을 개발할 계획이다. 흉부 X-ray 뿐만 아니라 MRI, CT 등 다양한 의료영상을 활용할 수 있고, DNA 염기서열에 관한 합성 데이터도 활

용하여 바이오인포매틱스 교육에 활용할 수 있을 것이다. 인공지능 모델도 VGG-16 뿐만 아니라, ResNet, AlexNet 등 다양한 모델의 적용과 전이학습(Transfer learning) 등 다양한 학습 기법의 활용이 가능한 교육 프로그램으로 확장할 계획이다. 본 연구는 합성 의료 데이터를 활용한 의료 인공지능 교육 모델의 모범적인 사례를 제시하고 의료 AI 교육이 나아갈 길을 제시해 준다.

## 참고문헌

- [1] I. J. Goodfellow et al., "Generative Adversarial Networks," *Commun. ACM*, vol. 63, no. 11, pp. 139–144, 2014.
- [2] H. Salehinejad, S. Valaee, T. Dowdell, E. Colak, and J. Barfett, "Generalization of Deep Neural Networks for Chest Pathology Classification in X-Rays Using Generative Adversarial Networks," in *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 990–994, 2018.
- [3] V. Kovalev and S. Kazlouski, "Examining the Capability of GANs to Replace Real Biomedical Images in Classification Models Training," S. V Ablameyko, V. V Krasnoproschin, and M. M. Lukashevich, Eds. Cham: Springer International Publishing, pp. 98–107, 2019.
- [4] M. Kim and H.-J. Bae, "Data Augmentation Techniques for Deep Learning-Based Medical Image Analyses," *J. Korean Soc. Radiol.*, vol. 81, no. 6, p. 1290, 2020.
- [5] H. Y. Park et al., "Realistic High-Resolution Body Computed Tomography Image Synthesis by Using Progressive Growing Generative Adversarial Network: Visual Turing Test," *JMIR Med. Informatics*, vol. 9, no. 3, p. e23328, 2021.
- [6] K. Simonyan and A. Zisserman, "Very Deep Convolutional Networks for Large-Scale Image Recognition," 2015,
- [7] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*. MIT Press, 2016.
- [8] F. Chollet and others, "Keras." GitHub, 2015.