

# Med-StyleGAN2: 의료 영상 생성을 위한 GAN 기반의 합성 데이터 생성

최재하<sup>1</sup>, 김성연<sup>2</sup>, 변해린<sup>1</sup>, 이세연<sup>3</sup>, 이정수<sup>4</sup>

<sup>1</sup>인천대학교 컴퓨터공학부 학부생

<sup>2</sup>중앙대학교 응용통계학과 학부생

<sup>3</sup>동국대학교 AI소프트웨어융합학부 학부생

<sup>4</sup>성신여자대학교 컴퓨터공학과 학부생

chlgoocks2000@inu.ac.kr, ksy974498@gmail.com, byun-@inu.ac.kr,

seyeon040768@gmail.com, latsyrc900@gmail.com

## Med-StyleGAN2: A GAN-Based Synthetic Data Generation for Medical Image Generation

Jae-Ha Choi<sup>1</sup>, Sung-Yeon Kim<sup>2</sup>, Hae-Rin Byeon<sup>1</sup>,

Se-Yeon Lee<sup>3</sup>, Jung-Soo Lee<sup>4</sup>

<sup>1</sup>Dept. of Computer Science Engineering, Incheon National University

<sup>2</sup>Dept. of Applied Statistics, Chung-Ang University

<sup>3</sup>Dept. of AI Convergence, Dongguk University

<sup>4</sup>Dept. of Computer Science Engineering, Sungshin Women's University

### 요약

본 논문에서는 의료 영상 생성을 위한 Med-StyleGAN2를 제안한다. 생성적 적대 신경망은 이미지 생성에는 효과적이지만, 의료 영상 생성에는 한계점을 가지고 있다. 따라서 본 연구에서는 의료 영상 생성에 특화된 StyleGAN 기반 학습 모델을 제안한다. 이는 다양한 의료 영상 어플리케이션에 활용할 수 있으며, 생성된 의료 영상에 대한 정량적, 정성적 평가를 수행함으로써 의료 영상 생성 분야의 발전 가능성에 대해 연구한다.

### 1. 서론

최근 딥러닝은 컴퓨터 비전 및 패턴 인식 분야에서 놀라운 성과를 가져왔다. 사용하는 모델의 깊이와 복잡성 증가로 인해 딥러닝은 자연어 처리, 의료 영상 분석 등 다양한 영역에서 활용된다. 특히, 생성적 적대 신경망(Generative Adversarial Network, GAN)은 이러한 발전을 확장하였다[1]. GAN은 생성자와 판별자라는 두 개의 신경망이 min-max 게임 형태로 경쟁하여 상호발전하는 구조로 딥러닝의 다양한 분야에서 활용되고 있다.

최근 의료 분야의 딥러닝 활용은 주목할만한 결과를 낳기도 한다. 그러나 실제 환자 데이터의 부족과 개인정보 보호의 문제로 인해 의료 영상 데이터 확보와 분석은 어려움을 겪고 있다. 따라서 합성 데이터 생성을 통한 딥러닝 모델 훈련은 질병 감지 및 분석에 중요한 역할을 할 수 있다. 그러나 의료 데이터 특수성을 고려하며 GAN을 이용하는 데에는 한계점들이 보고되고 있다[2]. 이에 본 논문에서는 StyleGAN2에 기반하여 흉부 X-ray 이미지 제작에 특화된 Med-StyleGAN2를 제안하고 생성된 데이터에 대해 Fréchet Inception Distance(FID)와 Learned Perceptual Image Patch Similarity(LPIPS)를 이용하여 품질을 평가한다[3, 4]. 제안하는 모델의 코드는 아래 링크1)에 있다.

### 2. 생성적 적대 신경망

GAN에서는 생성기와 판별기, 두 신경망의 경쟁을 위해 생성기의 손실함수( $Loss_G$ )와 판별기의 손실함수( $Loss_D$ )는 다음과 같이 정의한다.

$$Loss_G = E_z [\log(1 - D(G(z)))] \quad (1)$$

$$Loss_D = E_x [\log(D(x))] + E_z [\log(1 - D(G(z)))] \quad (2)$$

$G(\cdot)$ ,  $D(\cdot)$ 는 각각 생성기, 판별기의 함수이고  $z$ 는 임의의 잡음(noise)이다. 수식 (1)-(2)는 수식 (3)으로 정의된 최적화 수식을 만족하도록 학습한다.

$$\min_G \max_D V(D, G) = E_x [\log(D(x))] + E_z [\log(1 - D(G(z)))] \quad (3)$$

$V(D, G)$ 는 GAN의 목적 함수다.  $D(G(z))$ 는 생성기에서 생성한 데이터를 판별기에 입력하였을 때의 출력이고,  $D(x)$ 는 실제 데이터를 판별기에 넣었을 때 출력이다. 학습 시 생성기는 판별기가 구분하지 못하게  $D(G(z)) = 1$  되도록 학습한다. 판별기는 생성기가 만든 가짜 데이터를 잘 구분할 수 있도록  $D(x) = 1$ ,  $D(G(z)) = 0$ 이 되도록 학습한다. 학습 과정을 거쳐 두 신경망이 모두 만족한 값을 얻어 손실함수가 수렴할 때 학습이 종료된다.

1) <https://github.com/byunnn/Synthetic-data.git>

<표 1> FID, LPIPS 비교. Normal은 정상 이미지, COVID19는 코로나19 이미지, Non-COVID19는 비-코로나 감염을 의미함

	GAN	DCGAN	CycleGAN	Med-StyleGAN2 (Normal)	StarGAN	Med-StyleGAN2 (COVID19)	Med-StyleGAN2 (Non-COVID19)	RSGAN	SDGAN
FID (↓)	2446.535	153.014	-	55.796	-	62.599	81.230	-	-
LPIPS (↑)	-	-	0.099	0.199	0.212	0.222	0.239	0.315	0.514

### 3. 연구 방법

#### 3.1. 데이터 셋

본 논문에서는 총 33,920개의 흉부 X-ray 이미지를 포함하는 COVID-QU-Ex 데이터 셋을 활용한다. 이 중 11,956개는 코로나19, 11,263개는 비-코로나 감염, 그리고 10,701개는 정상 이미지이다[5].

#### 3.2. 모델 설계 및 학습

StyleGAN2은 고품질의 합성 이미지를 생성하는 모델이다[6]. StyleGAN2를 기반으로 한 Med-StyleGAN2는 데이터의 의료 특수성을 고려하여 이미지 구조의 시각적 인지 결과에 영향을 주지 않으면서 동시에 고주파 성분이 가져오는 noise를 최소화하기 위하여 High-Pass Filtering을 0으로 설정했다. 또한 도메인 간의 스타일 차이 손실의 가중치를 2로 설정하여 코로나19, 비-코로나 감염과 정상 이미지의 차이를 극대화해 의료 데이터로써 오류가 최소화하도록 설계했다.

제안하는 모델은 NVIDIA RTX 3060을 활용하여 각 모델 당 100 epochs 씩 학습하였다.

#### 3.3. 생성 데이터 평가

생성된 데이터는 FID와 LPIPS 매트릭을 통해 원본 데이터와의 차이를 평가한다. FID는 이미지 분포 간에 정의되며, LPIPS 지표는 인간의 시각적 지각과 관련된 특성을 고려하여 이미지 간의 유사성을 측정한다.

$$FID(x, g) = \|\mu_x - \mu_g\|^2 + Tr\left(\sum x + \sum g - 2(\sum x \sum g)^{\frac{1}{2}}\right) \quad (4)$$


여기서  $x$ 와  $g$ 는 각각 두 개의 다변량 정규분포로 가정된 실제 임베딩과 생성 임베딩이다.  $\mu_x$ 와  $\mu_g$ 는 벡터  $x$ 와  $g$ 의 크기이며  $Tr$ 은 행렬의 대각합이고,  $\sum x$ 와  $\sum g$ 는 벡터의 공분산 행렬이다.

Med-StyleGAN2의 성능을 평가하기 위해 같은 데이터 셋을 GAN, DCGAN으로 생성하여 각 모델의 FID값을 비교했다. GAN과 DCGAN은 원본 데이터 셋과 생성 데이터 셋 전체를 비교하여 FID를 계산했으며, Med-StyleGAN2은 정상 이미지, 코로나19, 비-코로나 감염의 생성 데이터 셋을 각각 8,000장씩 생성하여 원본 데이터와 비교하여 FID를 계산했다. 동등한 비교를 위해 FID와 LPIPS는 소수점 넷째 자리에서 반올림하여 나타냈다.

### 4. 결과

제안하는 모델의 실험 결과를 <표 1>에 나타내었으며, FID 수치를 GAN, DCGAN 보다 획기적으로 낮출 수 있음을 확인하였다. 또한 다른 흉부 X-ray 데이터 셋을 학습한 최신 모델인 SDGAN, RSGAN, StarGAN, CycleGAN와 LPIPS를 비

교하였을 때 준수한 성능을 보이는 것을 볼 수 있다[7, 8]. (그림 1)에서는 클래스 활성화 맵을 통해 폐 부근에 활성화가 됨을 관찰하였고, (그림 2)에서는 생성한 영상에 대한 정성적인 평가를 수행하여, 제안하는 모델이 원본 데이터와 유사한 정도의 시각 인지를 제공하는 이미지를 생성함을 확인하였다.



(그림 1) 코로나19, 비-코로나 감염의 분류 클래스 활성화 맵.



(그림 2) 좌측부터 각각 GAN, DCGAN, Med-StyleGAN2의 생성 이미지를 나타내었으며, 가장 우측 이미지는 원본 데이터이다.

※ 본 프로젝트는 과학기술정보통신부 정보통신망의인재양성사업의 지원을 통해 수행한 ICT 멘토링 프로젝트 결과물입니다.

#### 참고문헌

- [1] Goodfellow et al., "Generative Adversarial Nets", NIPS 2014.
- [2] Chen et al., "Generative Adversarial Networks in Medical Image Augmentation: A Review", CBM, 2022.
- [3] Heusel et al., "GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium", NIPS, 2017.
- [4] Zhang et al., "The Unreasonable Effectiveness of Deep Features as a Perceptual Metric", CVPR, 2018.
- [5] Chowdhury et al. "Can AI Help in Screening Viral and COVID-19 Pneumonia?", IEEE Access, 2020.
- [6] Karras et al., "Analyzing and Improving the Image Quality of StyleGAN", CVPR, 2020.
- [7] Han et al., "GAN-based disentanglement learning for chest X-ray rib suppression", Medical Image Analysis, 2022.
- [8] Kausar et al., "SD-GAN: A Style Distribution Transfer Generative Adversarial Network for Covid-19 Detection Through X-Ray Images", IEEE Access, 2023.