

Cycle-GAN을 이용한 간 CT 이미지 생성 모델에 관한 연구

이진아, 한정아, 이현성, 최민지, 허용도*

건양대학교, 건양대학교, 건양대학교, 건양대학교, *건양대학교

jammanbooboo@gmail.com, hanjaja@gmail.com, hyen64@naver.com, miiingzz112@gmail.com,
*ydher@konyang.ac.kr

A Study on the Liver CT Image Generation Model Using Cycle-GAN

Lee Jin A, Lee Hyun Seong, Han Jeong A, Choi Min Ji, Her Yong Do*

Konyang Univ., *Konyang Univ.

요약

본 논문은 의료 AI 분야의 학습 데이터 확보의 어려움을 해결하기 위하여 고안되었다. 의료 분야의 데이터의 경우, 다양한 개인정보를 담고 있어 추가적인 가용 절차들이 요구되고 많은 시간적, 경제적 손실을 야기한다. 이를 해결하고자 Cycle-GAN(Cycle-Consistent Adversarial Networks)을 이용하여 가용성이 보장된 합성 의료 데이터를 생성하는 방법을 제안한다. 해당 모델의 생성 이미지에 대한 가용성 검증으로는 FID(Frechet Inception Distance) 수치를 통해 평가하여 Cycle-GAN을 이용한 간 CT 이미지 생성 모델에 관한 연구에 필요한 최적의 모델을 마련하였다.

I. 서론

최근 들어 인공지능 분야의 관심이 높아지면서 다양한 분야에서 접목되어 활발한 연구가 진행되고 있다[1]. 해당 인공지능 분야의 경우 모델 자체의 알고리즘도 물론 중요하지만, 학습에 사용될 데이터의 품질과 수량의 확보 역시 매우 중요하다[2]. 하지만 몇몇 분야에서는 학습 데이터를 확보하기에 어려움을 가지고 있다. 이는 대표적으로 의료 분야를 들 수 있다. 의료 분야의 데이터는 다양한 개인정보를 담고 있어 가명 처리, 비식별화와 같은 인증 절차를 추가적으로 요구한다. 또한, 병원마다 데이터 규격이 표준화되어 있지 않아 학습 데이터 확보에 어려움을 갖게 된다.

본 논문에서는 해당 요소 해결을 위하여 최근 이미지 합성 분야의 고성능 모델로 평가받고 있는 Cycle-GAN(Cycle-Consistent Adversarial Networks)을 이용하였다[3]. 이를 통하여 학습에 사용할 수 있을 만큼의 가용성이 보장된 합성 의료 데이터를 생성하고자 한다.

II. 본론

본 논문에서는 Cycle-GAN 모델을 사용하여 의료 데이터 합성을 진행하며 CANCER IMAGING ARCHIVE에서 획득한 간 CT 데이터를 활용한다[4].

CycleGAN Training process




그림 1. Cycle-GAN 모델 구조

그림 1은 본 연구에서 사용한 모델의 구조이다. 정상 간 CT 데이터(Normal) 도메인 X, 병변 간 CT 데이터(Lesion) 도메인 Y, 각각의 생성자를 G, 각각의 판별자를 D라고 가정한다. 이때, X와 Y의 정보를 통해 G는 X에서 Y로, Y에서 X로 합성을 진행하게 된다. 이렇게 생성된 합성 데이터는 D를 통해 실제 데이터와의 비교를 거쳐 손실 값을 측정하며 해당 값으로 G의 학습이 이루어지게 된다. 본 논문에서 사용된 데이터는 정상 간 CT 데이터 7,575장, 병변 간 CT 데이터 7,874장이며 이를 8:2의 비율로 나누어 학습과 평가를 진행하였다.

표 1. CASE에 따른 epoch, batchsize, learningRate, 정규화 비교

	epoch	batchsize	learningRate	정규화
CASE 1	200	32	0.0001	0.5, 0.5
CASE 2	200	32	0.0002	0.5, 0.5
CASE 3	200	8	0.0001	0.5, 0.5
CASE 4	200	4	0.0001	0.5, 0.5
CASE 5	200	1	0.0001	0.5, 0.5

표 1은 각 케이스에 따라 변화를 주어 측정하였으며 이를 비교하여 모델의 성능에 유의미한 변화를 보이는 요소를 산출한다. 산출된 요소들에 의하여 점진적인 수정을 진행하며 모델의 성능을 평가한다. 본 과정을 통해서 모델의 성능을 개선해나가고 최적의 모델을 구축한다.

표 2. CASE에 따른 FID 비교

	FID (real A ↔ fake A)	FID (real B ↔ fake B)
CASE 1	262.28	166.96
CASE 2	272.28	160.65
CASE 3	90.01	102.74
CASE 4	67.92	79.18
CASE 5	288.25	89.54

표 2는 시도 회차에 따른 FID(Frechet Inception distance) 수치를 나타낸 표이다. FID는 생성된 영상의 품질을 평가할 때, 영상 집합 사이의 거리(distance)를 나타내어 사용한다. 적대적 생성신경망(GAN, Generative Adversarial Network)을 사용해 생성된 영상의 집합과 실제 생성하고자 하는 클래스 데이터의 분포 거리를 계산하는 것이다[5]. 이는 거리가 가까울수록 좋은 영상으로 판단된다. 본 논문에서는 해당 수치를 통하여 생성된 모델의 성능을 측정하며 이는 0에 가까울수록 좋은 모델로 간주한다. 평가를 위해 학습으로 사용되지 않았던 정상 CT 데이터 1491장과 병변 CT 데이터 1603장에 대해 각각의 네트워크로 합성을 진행하였다.




그림 2. Case Index에 따른 FID Score

다음과 같이 예외적인 CASE 5를 제외한 나머지의 CASE 1~4는 꺾은 선 그래프를 통해 FID SCORE 수치가 감소 됨에 따라 성능이 향상된 모델임을 알 수 있다. CASE 4가 FID(real A ↔ fake A)는 67.92, FID(real B ↔ fake B)는 79.18로 가장 낮은 수치로 최고 성능을 기록하였다.

III. 결론




그림 3. 원본 이미지와 생성 이미지 비교

본 논문에서는 Cycle-GAN을 이용한 의료 데이터 생성에 관한 연구를 진행하였다. 의료 데이터는 간 CT 데이터를 활용하였으며 정상 CT 데이터를 병변 CT 데이터로, 병변 CT 데이터를 정상 CT 데이터로 생성하는 두 개의 네트워크로 구성되어 있다. 이때 모델은 epoch(200), batchSize(4), learningRate(0.0001)의 값을 최적으로 가지며, 각각의 네트워크를 통해 생성된 데이터는 실제 CT 데이터와의 유사도를 측정하여 이를 평가 지표로 활용하였으며 측정은 FID 수치를 통해 진행하였다.

그림 3은 간 CT 이미지 비교로, 정상 및 병변 간 CT 이미지 각각에 대하여 원본 이미지와 생성된 이미지를 비교한 것이며 매우 흡사한 결과물을 출력해냈음을 확인할 수 있다. 또한, 의료 데이터 생성 기술 연구에 대한 가능성을 확인하였다. 이러한 연구는 의료 분야에서 인공지능 기술을 활용하기에 앞서, 필요한 학습 데이터를 확보하는 과정에서의 어려움을 해결하여 해당 분야의 효율적인 연구 및 개발을 장려할 것으로 기대된다. 더불어 최적의 모델을 통하여 확보되는 데이터의 성능 가치를 높일 수 있을 것으로 기대된다. 향후 연구 계획으로는 다른 의료 데이터에 대한 생성 모델을 개발할 예정이다. 또한, 이미지의 유사도를 측정하는 것에 그치지 않고 해당 분야 전문의를 통해 데이터를 검증할 것이며 이를 통해 더욱 실효성 높은 데이터를 생성할 수 있을 것이다.

ACKNOWLEDGMENT

본 성과는 교육부와 한국연구재단의 재원으로 지원을 받아 수행된 3단계 산학협력 선도대학 육성사업(LINC 3.0)의 연구 결과입니다(NTIS 과제 번호: 1345356198).

참 고 문 헌

- [1] Mirsky, Y., Mahler, T., Shelef, I., Elovici, Y., "CT-GAN: Malicious Tampering of 3D Medical Imagery using Deep Learning", arXiv preprint arXiv:1901.03597, 2019.
- [2] Dodge, A., & Johnstone, E., "Using Fake Video Technology To Preempt Intimate Partner Abuse." Without My Consent, 2018.
- [3] ZHU, Jun-Yan, et al. "Unpaired image-to-image translation using cycle-consistent adversarial networks.", Proceedings of the IEEE international conference on computer vision. 2017, p.2223-2232.
- [4] "Multimodality annotated HCC cases with and without advanced imaging segmentation (HCC-TACE-Seg)", CANCER IMAGING ARCHIVE, last modified Oct 18, 2022, accessed Sep 20, 2022, <https://wiki.cancerimagingarchive.net/pages/viewpage.action?pageId=70230229>
- [5] Karras, Tero, Laine, Samuli; Aila, Timo (2020). "A Style-Based Generator Architecture for Generative Adversarial Networks". IEEE Transactions on Pattern Analysis and Machine Intelligence.