

# Cycle GAN 을 활용한 Brain CT - MRI 이미지 양방향 변환에 관한 연구

김성혁<sup>1</sup>, 권장호<sup>2</sup>, 최기환<sup>3\*</sup>

<sup>1</sup>서울과학기술대학교 인공지능응용학과 학부생

<sup>2</sup>한국과학기술연구원 박사과정

<sup>3\*</sup>서울과학기술대학교 인공지능응용학과 교수

Seonghyeokst21@gmail.com, kzzangho@gmail.com, kihwanc@seoultech.ac.kr

## CycleGAN-Based Bidirectional Conversion of Brain CT and MRI Scans

Seong-Hyeok Kim<sup>1</sup>, Jang-Ho Kwon<sup>2</sup>, Ki-Hwan Choi<sup>3\*</sup>

<sup>1</sup>Dept. of Applied Artificial Intelligence, Seoultech University

<sup>2</sup>Dept. Electronics Engineering, Korea Institute of Science and Technology (KIST)

<sup>3</sup>Dept. of Applied Artificial Intelligence, Seoultech University

### 요약

본 연구는 CycleGAN을 활용하여 CT 와 MRI 간의 이미지 도메인 변환을 수행하는 방법을 제안한다. 의료 영상 분야에서는 서로 다른 촬영 기법 간의 도메인 불일치 문제가 존재하며, 특히 짹지어진 CT-MRI 데이터셋을 구축하는 것이 어려운 경우가 많다. 본 논문에서는 CycleGAN 의 구조를 기반으로 하여 두 도메인 간의 양방향 변환 모델을 설계하였으며 실험을 통해 도메인 간 구조적 정보 보존과 시각적 품질 측면에서 안정적인 변환 결과를 확인하였다. 본 연구 결과를 통해 의료 영상의 데이터 증강이나 MRI 촬영이 어려운 환자의 치료에 도움이 될 것으로 기대된다.

### 1. 서론

Computational Tomography (CT)와 Magnetic Resonance Imaging (MRI)는 환자의 상태를 확인하기 위해 촬영하는 의료영상의 종류이다. CT 는 X 선을 사용하여 빠르게 촬영하며, MRI 는 전자기장을 활용해 비교적 긴 시간 천천히 촬영한다. 촬영 방식과 시간의 차이로, CT 는 움직이는 장기나 간단한 구조를 촬영하는데 장점이 있으며 MRI 는 고정된 장기의 디테일한 모습을 확인할 수 있다는 장점이 있다.

CT 와 MRI 이미지는 서로 다른 특성을 가지고 있어 촬영 가능한 환자가 나뉘기도 하며 때에 따라 한쪽에서만 질환이 더 잘 관측되기도 한다. 이로 인해 이미지 간의 변환에 대한 연구의 필요성이 부각되고 있다. 특히, 최근에는 딥러닝 모델을 활용한 이미지 변환 연구들이 수행되고 있다.

이미지 변환 딥러닝 모델을 훈련하기 위해서는 정확하게 짹지어진 (Paired) Source Domain 의 이미지와 Target Domain 의 이미지가 필요하다 그러나, CT 와 MRI 이미지의 경우 이러한 데이터를 만들기 어렵다는 문제가 있다. 그렇기 때문에 짹지어지지 않은 두 도메인의 데이터를 (Unpaired Dataset)를 활용하여 변환

모델을 훈련하는 방법이 필요하다.

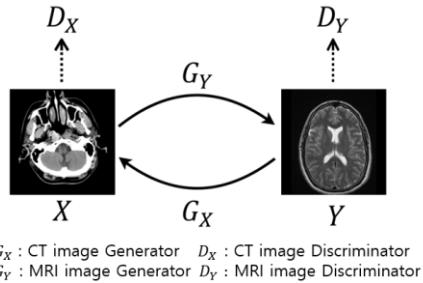
본 논문에서는 활용하는 모델인 CycleGAN [1]을 기반으로 서로 짹지어지지 않은(unpaired) 데이터를 활용해 이미지 변환을 가능하게 하는 모델을 개발하여, CT 에서 MRI 로의 변환 모델의 개발이 Unpaired Dataset 으로도 가능함을 보이고자 한다.

Unpaired Dataset 을 사용한 훈련 방법은 의료 영상과 같은 분야에서 짹지어진 데이터를 얻기 어렵다는 점을 해결해주기 때문에, 이러한 방식의 이미지 변환 연구를 통해 의료 영상의 활용성을 높여 최종적으로 환자의 진단을 도울 수 있을 것으로 기대된다.

### 2. 연구 방법

본 논문에서는 CT 와 MRI 사이의 변환 함수를 학습하는데 초점을 맞춘다. 학습 방법 정리를 위해  $X$ 를 CT 이미지,  $Y$ 를 MRI 이미지라고 하자. 학습에 사용되는 샘플은  $\{x_i\}_{i=1}^n$   $x_i \in X$  와  $\{y_i\}_{i=1}^n$   $y_i \in Y$  인 두 집합으로 나타낼 수 있으며, 샘플 원소의 데이터 분포는  $x \sim p_{data}(x)$ ,  $y \sim p_{data}(y)$  를 따른다.

Cycle GAN 에서는 두 개의 Generator 와 Discriminator 를 학습한다. 이를 각각  $G_X$  ( $Y \rightarrow X$  생성),  $G_Y$  ( $X \rightarrow Y$  생성)  $D_X$  ( $X$  인지 판별),  $D_Y$  ( $Y$  인지 판별)라고 하며 이는 그림 1 과 같다.



(그림 1) Cycle GAN 도식도.

Cycle GAN 에서는 크게 두가지 손실을 사용한다. 적대적 손실(Adversarial losses)은 적대적으로 Generator 와 Discriminator 를 학습한다. 이는 식 1 과 같으며, 수식에는  $G_Y$ ,  $D_Y$  대신  $G_X$ ,  $D_X$  를 대입할 수 있다.

$$\begin{aligned} \mathcal{L}_{GAN}(G_Y, D_Y, X, Y) = & \mathbb{E}_{y \sim p_{\text{data}}(y)} [\log D_Y(y)] \\ & + \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log(1 - D_Y(G_Y(x)))] \end{aligned} \quad (1)$$

사이클 일관성 손실(cycle consistency loss)은 G 를 통해 만들어낸 샘플이 특정 데이터 공간 안에서만 만들어지는 현상을 방지하기 위해 사용된다.

$$\begin{aligned} \mathcal{L}_{cyc}(G_X, G_Y) = & \mathbb{E}_{x \sim p_{\text{data}}(x)} [\|G_X(G_Y(x)) - x\|_1] \\ & + \mathbb{E}_{y \sim p_{\text{data}}(y)} [\|G_Y(G_X(y)) - y\|_1]. \end{aligned} \quad (2)$$

두 가지 손실을 조합해 전체 손실을 선정한다. Cycle loss 에  $\lambda$  를 적용해 어느정도 Cycle loss 를 적용할지 조정할 수 있다.

$$\begin{aligned} \mathcal{L}(G_X, G_Y, D_X, D_Y) = & \mathcal{L}_{GAN}(G_Y, D_Y, X, Y) \\ & + \mathcal{L}_{GAN}(G_X, D_X, Y, X) \\ & + \lambda \mathcal{L}_{cyc}(G_X, G_Y), \end{aligned} \quad (3)$$

### 3. 연구 결과

본 논문에서는 Cycle GAN 의 학습을 위해 kaggle 에서 제공하는 CT and MRI brain scans 데이터 셋을 활용하였다. 이 데이터 셋에서는 Unpaired 한 녀의 MRI 와 CT 이미지 2500 쌍이 학습 이미지 1756 쌍, 테스트 이미지 744 쌍으로 분할되어 제공된다. 이미지는 256\*256 size 로 center crop + padding 처리되어 사용하였다. 실험은 Ubuntu 20.04 LTS OS 에 CPU 는 i9 14900k, Memory 는 128G, GPU 는 RTX 4090 로 구성된 환경에서 진행됐다.

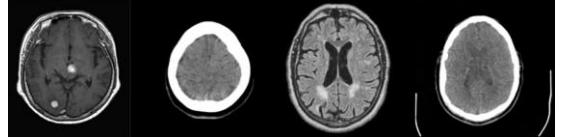
Cycle GAN 은 Resnet[2]과 U-net[3] 구조의 Generator 를 제공한다. 본 실험에서는 두 Generator 를 모두 200epoch 학습하여 더 적합한 모델을 선정하였다.

평가는 Generator 로 테스트 이미지를 생성하여 진행하였다. 본 논문에서는 Unpaired 데이터를 사용하기 때문에 평가를 위한 지표로서 FID[4]를 사용하였으며 그 결과는 표 1 과 같다. FID 는 데이터의 특징 분포의 가까운 정도를 평가하는 지표로, 작은 값을 가질수록 두 이미지의 특징 분포가 가까움을 의미한다.

Backbone	FID(CT → MRI)	FID(MRI → CT)	Params (M)
ResNet_9block	58.32	71.41	11.4
U-Net256	95.19	90.47	54.4

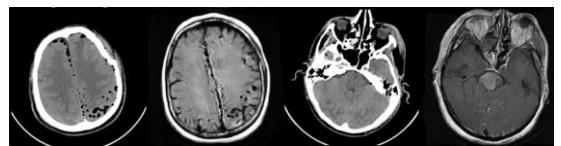
(표 2) 모델 평가.

실험 결과 Resnet 기반 Generator 가 더 우수한 성능을 보임을 확인하였다. 따라서 본 논문에서 제안하는 Cycle Gan 은 Resnet 기반 Generator 를 사용한다.



(그림 2) MRI → CT 변환

그림 2 에서는  $G_X$ 에 입력된 두 종류의 MRI 이미지와 생성된 CT 이미지 쌍을 볼 수 있다. 생성된 CT 이미지는 실제 CT 이미지와 유사하게 하얀 골격 구조를 포함하고 있다.



(그림 3) CT → MRI 변환

그림 3 에서는 앞서 본 것과 유사하게  $G_Y$ 에 입력된 두 종류의 MRI 이미지와 생성된 CT 이미지 쌍을 볼 수 있다. 생성된 MRI 이미지에 원래 CT 이미지에서는 보이지 않던 디테일한 구조를 확인할 수 있다. 이런 샘플들을 통하여 CT and MRI brain scans 데이터에 대한 양방향 이미지 변환이 가능함을 확인하였다.

### 4. 결론 및 제언

의료 분야에서는 CT 나 MRI 중 한가지만 촬영 가능한 상황이 종종 발생하며, 이에 대한 해법으로서 양방향 변환이 가능한 딥러닝 모델의 필요성이 제기되고 있다. 그러나 학습에 필요한 짹지어진 데이터가 확보되기 어렵다는 문제가 존재한다.

본 논문에서는 짹지어지지 않은 데이터를 활용할 수 있는 Cycle GAN 기반의 이미지 양방향 변환모델을 제안한다. 실험 결과, CT 와 MRI 이미지 간의 변환이 가능함을 입증하였으며, 의료 영상 분석에 활용할 수준의 이미지를 생성함을 확인하였다.

다만 도메인 변환의 특성 상 변환을 통해 생성되는 구조가 실제 구조와 동일한지 보장할 수 없고, 왜곡의 발생 가능성 또한 존재한다. 모델을 통해 생성되는 변환 이미지의 진위성과 해부학적 정합성에 대한 신뢰도를 확보하기 위한 연구가 추가적으로 요구된다.

### 참고문헌

- [1] J. Y. Zhu et al., *Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks*, ICCV, Venice, 2017, pp. 2223–2232.
- [2] K. He et al., *Deep Residual Learning for Image Recognition*, CVPR, Las Vegas, 2016, pp. 770–778.
- [3] O. Ronneberger et al., *U-Net: Convolutional Networks for Biomedical Image Segmentation*, MICCAI, Munich, 2015, pp. 234–241.
- [4] M. Heusel et al., *GANs Trained by a Two Time-Scale Update Rule Converge to a Local Nash Equilibrium*, NIPS, Long Beach, 2017, pp. 6626–6637.