

## 딥러닝 네트워크를 이용한 조영증강 CT 영상 생성

우상근<sup>o</sup>

<sup>o</sup>한국원자력의학원 RI중개연구팀

e-mail: skwoo@kirams.re.kr<sup>o</sup>

## Synthesis of contrast CT image using deep learning network

Sang-Keun Woo<sup>o</sup>

<sup>o</sup>Devison of RI-convergence Research, Korea Institute of Radiology and Medical Sciences, Seoul, Korea

### ● 요약 ●

본 논문에서는 영상생성이 가능한 딥러닝 네트워크를 이용하여 조영증강 CT 영상을 획득하는 연구를 수행하였다. CT는 고해상도 영상을 바탕으로 환자의 질병 및 암 세포 진단에 사용되는 의료영상 기법 중 하나이다. 특히, 조영제를 투여한 다음 CT 영상을 획득되는 영상을 조영증강 CT 영상이라 한다. 조영증강된 CT 영상은 물질의 구성 성분의 영상대비를 강조하여 임상의로 하여금 진단 및 치료반응 평가의 정확성을 향상시켜준다. 하지만 많은 수의 환자들이 조영제 부작용을 갖기 때문에 이에 해당되는 환자의 경우 조영증강 CT 영상 획득이 불가능해진다. 따라서 본 연구에서는 조영증강 영상을 얻지 못하는 환자 및 일반 환자의 불필요한 방사선의 노출을 최소화 하기 위하여 영상생성 딥러닝 기법을 이용하여 CT 영상에서 조영증강 CT 영상을 생성하는 연구를 진행하였다. 영상생성 딥러닝 네트워크는 generative adversarial network (GAN) 모델을 사용하였다. 연구결과 아무런 전처리로 거치지 않은 CT 영상을 이용하여 영상을 생성하는 것 보다 히스토그램 균일화 과정을 거친 영상이 더 좋은 결과를 나타냈으며 생성영상이 기존의 실제 영상과 영상의 구조적 유사도가 높음을 확인할 수 있다. 본 연구결과 딥러닝 영상생성 모델을 이용하여 조영증강 CT 영상을 생성할 수 있었으며, 이를 통하여 환자의 불필요한 방사선 피폭을 최소화하며, 생성된 조영증강 CT 영상을 바탕으로 정확한 진단 및 치료반응 평가에 기여할 수 있을거라 기대된다.

**키워드:** 영상생성 딥러닝 네트워크 (Generative adversarial network, GAN),  
조영증강 CT (contrast enhanced computed tomography), 히스토그램 균일화 (histogram equalization)

### I. Introduction

Computed tomography (CT) 영상은 환자의 진단 및 치료반응을 평가하기에 유용한 의료영상 획득 방법이다. 의료영상 획득 및 분석 기술이 향상 되면서 높은 해상도의 CT 영상 획득이 가능해짐에 따라서 질병의 진단의 정확도 역시 향상되어왔다. CT 영상의 획득 원리는 외부에서 x-선을 체내에 기해주면 체내를 통과한 x-선이 CT 영상기기에 도달하는 정보를 바탕으로 영상을 재구성하여 체내 영상화를 진행한다. 체내 투과된 x-선은 물, 뼈, 공기, 연조직과 같은 구성성분이 다른 물질의 영상 대비도가 크기 때문에 체내 영상화가 가능해진다. 하지만 CT 영상은 연조직(soft tissue)부위 부위에서의 영상 대비도가 떨어져 연조직 부위의 미세한 물질 구성의 차이는 영상화가 매우 어렵다. 이러한 문제점을 해결하기 위한 CT 영상 획득 방법이 조영제를 투여한 후 영상을 획득하는 조영증강 CT (contrast enhanced CT) 영상이다. 그러나 많은 수의 사람들이 조영제-유발 신독성 (contrast-induced nephropathy)와 같은 조영제의 부작용을 나타낸다. 림프절전이 (lymph node metastasis) 환자의 경우 일반 CT

영상으로는 종양의 크기를 통한 진단이 어렵기 때문에 일반 CT 영상뿐만 아니라 조영증강 CT 영상을 함께 획득하여 진단의 정확성을 높이고 있다. 본 연구에서는 암 환자의 림프절 전이 진단을 위한 영상생성 딥러닝 네트워크를 이용하여 일반 CT 영상을 기반으로 조영증강 CT를 생성하는 연구를 수행하였다.

### II. Materials and Methods

#### 1. CT 및 조영증강 CT 영상 준비

영상생성 딥러닝 네트워크를 학습시키기 위하여 일반 CT 영상과 조영증강 CT 영상을 동일 환자에서 각각 획득한다. CT 및 조영증강 CT 영상은 각각 1560장으로 구성되어 있다.

Table 1. CT image information

Name	Info
Voxel size (mm)	1.367, 1.367, 2.5
Number of voxels	512, 512, 390

## 2. CT 및 조영증강 CT 영상 전처리

영상생성 딥러닝 네트워크의 성능 향상 및 생성된 영상의 정확도를 위하여 일반 CT 영상과 조영증강 CT 영상의 공간상 위치를 일치시켜 준다. 학습 정확도 향상을 위하여 CT 영상의 경우 히스토그램 평준화 (histogram equalization) 방법을 사용하였다.

## 3. 영상생성 딥러닝 네트워크

CT 영상을 기반으로 조영증강 CT 영상 생성을 위하여 본 연구에서는 영상생성 딥러닝 네트워크 (generative adversarial network, GAN) 방법을 사용하였다.

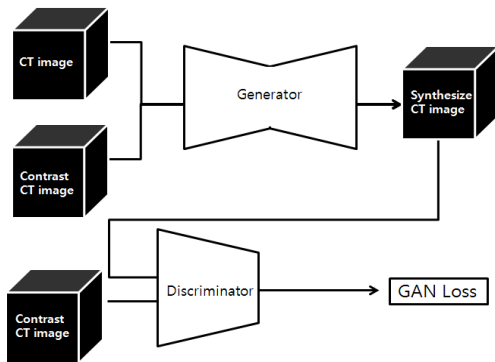


Fig. 1. 영상생성 딥러닝 네트워크 모식도

GAN의 구성은 생성부(generator)와 판별부(discriminator)로 구성되어 있으며 생성부는 입력된 영상(input data)를 표적 데이터(target data)에 가장 유사하게 생성하도록 하는 기능을 한다. 판별부는 입력된 실제영상(ground truth)을 합성곱 신경망(convolutional neural network) 기법을 이용하여 학습하여 실제영상의 패턴특징을 학습한다. 최종적으로 생성된 영상은 판별부로 입력이 되어 GAN 손실값(loss)을 바탕으로 영상이 실제영상에 가까운지 그렇지 않은지를 결정하게 된다.

## 4. 생성영상 정량평가

생성된 영상과 실제영상과의 차이를 확인하기 위하여 구조적 유사도(structure similarity, SSIM) 방법을 이용하였다. 또한 히스토그램 평준화 방법에 따른 생성영상의 차이를 확인하기 위하여 생성된 영상을 대응표본 t 검정(paired sample t-test) 통계분석 방법을 이용하여 유의미성을 판별하였다.

## III. Result

딥러닝 네트워크를 이용한 영상생성 결과 Fig 2에 제시하였다. Fig. 2에서 빨간색 화살표로 표시된 부위가 림프절 전이 영역을 나타내는데 일반 CT 영상에서는 해당 부위가 육안으로는 확인이 불가능 하지만 조영증강 CT 영상에서는 확인이 가능하다.




Fig. 2 일반 CT 영상, 조영증강 CT 영상, 히스토그램 평준화를 하지 않은 생성영상, 히스토그램 평준화를 진행한 영상생성 결과.

실제영상과 생성영상 사이에 SSIM 결과를 바탕으로 한 통계분석 결과는 Fig. 3과 같다. 대응표본 t 검증을 통하여 히스토그램 평준화를 진행한 영상과 그렇지 않은 생성영상을 각각 대응 비교한 결과 두 방법 간에 차이가 있음을 확인할 수 있었다 ( $p > 0.0001$ ).

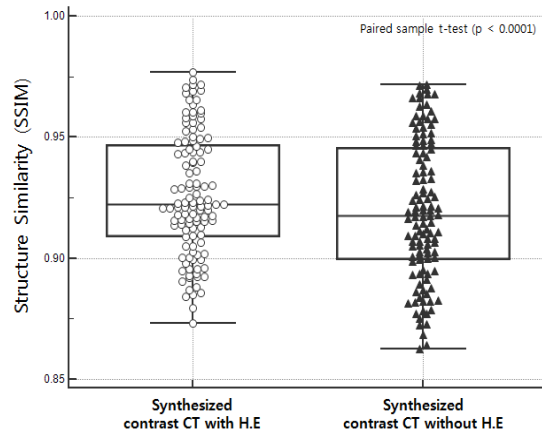


Fig. 3 히스토그램 표준화를 진행한 생성영상과 진행하지 않은 생성영상 SSIM 비교 결과

## IV. Conclusions

본 연구에서는 영상생성 딥러닝 네트워크를 이용하여 CT 영상에서 조영증강 CT 영상을 성공적으로 생성할 수 있었다. 또한 생성영상의 정확도를 위하여 히스토그램 평준화 방법으로 전 처리한 영상의 정확도가 그렇지 않은 영상보다 실제영상과 유사함을 확인할 수

있었다. 본 연구결과는 조영증강 CT 영상을 획득하지 못하는 암 환자의 정확한 진단 및 치료반응 평가에 큰 도움이 될 수 있을 거라 기대된다.

## REFERENCES

- [1] Dales RE, Stark RM, Raman S. Computed tomography to stage lung cancer. Approaching a controversy using meta-analysis. *Am Rev Respir Dis*. Vol. 141, No. 5, pp.1096-1101, June 1990.
- [2] Andreucci, Michele, Richard Solomon, and Adis Tasanarong. Side effects of radiographic contrast media: pathogenesis, risk factors, and prevention. *BioMed research international*, Vol. 2014, pp.20, May 2014.
- [3] Yi, Xin, Ekta Walia, and Paul Babyn. "Generative adversarial network in medical imaging: A review." *arXiv preprint arXiv:1809.07294*, 2018.
- [4] Nie, Dong, et al. Medical Image Synthesis with Deep Convolutional Adversarial Networks. *IEEE Transactions on Biomedical Engineering* Vol.65, No.12, pp.2720-2730, December 2018.
- [5] Isola, Phillip, Jun-Yan Zhu, Tinghui Zhou et al., Image-to-image translation with conditional adversarial networks, *arXiv preprint*, 2017.
- [6] Mirza, Mehdi, and Simon Osindero. "Conditional generative adversarial nets." *arXiv preprint arXiv:1411.1784* , 2014.
- [7] Zhu Y, Huang C. An adaptive histogram equalization algorithm on the image gray level mapping. *Physics Procedia*. Vol. 25, pp. 601-608, December 2012.