

Generative adversarial network를 이용한 3D to 4D 심실 영상 생성기법

하성민* · 장영걸** · 장혁재***

Method for 3D to 4D Image Generation of Left Ventricle with Conditional Generative Adversarial Networks

Seongmin Ha*, Yeonggul Jang**, Hyuk-Jae Chang***

Abstract : The method of evaluating myocardial infarction is based on the degree of contrast enhancement or movement of the ventricles using non-invasive equipment. Among the non-invasive devices, computed tomography (CT) is widely used, and there is a risk of radiation exposure in order to determine the motion of the ventricle. We investigated the generation of retrospective gating (4D) images from prospective gating (3D) ED and ES images with cGAN in CT. It seemed to have the characteristics of the matched real image, but the correlation was not shown for each cycle.

1. 서 론

혈전 등으로 동맥이 막혀 심근에 문제(myocardial infarction)가 발생한 경우 정확한 심장 질환 진단을 위해 비침습 검사인 컴퓨터 단층촬영(CT; computed tomography), 자기공명영상(MRI; magnetic resonance imaging)등을 이용하고 있다.

그 중 CT 촬영을 통해 심전도(ECG; electrocardiogram) 동조화 방식을 적용하여 심장의 주기 중 수축기(systole)와 이완기(diastole) 시점에서 촬영하는 방식으로 구출분획(ejection fraction)을 계산하고 심실의 기능을 평가한다.

이러한 심장의 수축기와 이완기를 판단하는 척도로써 심장 R-R 주기를 측정하는 심전도 동조화(ECG gating) 장비를 사용하는데, 이 심전도 동조화 장비를 이용하여 획득된 주기 정보를 이용하여 수축기 말기(end-systole) 및 이완기 말기(end-diastole)의 심장 촬영을 수행하는 방식이 전향적 동조화(prospectively

gating) 기법이다. 이 기법의 경우 후향적 동조화(retrospective gating)에 비해 환자의 방사선 피폭량이 적다는 장점이 있으나 촬영시 적절한 타이밍을 맞추지 못한다면 심장을 재촬영해야 한다는 문제점과 선택한 영상 이외의 심장주기 영상은 확인할 수 없는 문제점이 있다⁽¹⁾.

본 논문에서는 수축기 말기 및 이완기 말기의 심장 영상을 이용하여 심장 전체 주기의 영상을 최근 급속도로 발전중인 generative adversarial network (GAN) 중 특정 영상을 입력으로 지정할 수 있는 conditional GAN (cGAN)을 이용하여 생성하고자 한다⁽²⁾.

2. 본 론

2.1. cGAN

cGAN 모델은 기존의 GAN과 달리 입력으로 임의의 입력영상(observed image x)을 가우시안 분포의 잡음(noise vector z)과 함께 영상 생성기(G; generator)에 입력하여 실제 영상과 구분이 안가는 가상 영상(fake image y)을 생성한다. 생성된 가상 영상은 식별

* 연세대학교 의과대학 생체공학협동과정

** 연세대학교 의과대학 의과학과

*** 연세대학교 의과대학 내과학교실 심장내과




Fig. 1 The structure of conditional generative adversarial network (cGAN)

기(D; discriminator)를 통해 가상 영상과 입력영상 쌍이 실제 영상 쌍인지 가상 영상 쌍인지 구분한 결과를 만들어낸다(Fig. 1). 이때 G와 D의 손실함수(loss function)는 식 (1)과 같으며, G를 최소화, D를 최대화하는 손실함수인 식 (2)를 업데이트하여 학습한다.

$$L_{cGAN}(G, D) = E_{x, y \sim p_{\text{data}}(x, y)} [\log D(x, y)] + E_{x \sim p_{\text{data}}(x), z \sim p_z(z)} [\log(1 - D(x, G(x, z)))] \quad (1)$$

$$G^* = \arg \min_G \max_D L_{cGAN}(G, D) \quad (2)$$

2.2. 심장 전체주기 심실 영상 생성 기법

심장 전체주기의 심실 영상을 생성하기 위해 지역화(localization)된 심실 영상과 영역화(segmentation)된 마스크 영상의 쌍을 학습 데이터로 구축한다. 학습데이터는 the University Hospital of Dijon (Dijon, France)에서 임상시험 목적으로 구축되었고 Automated Cardiac Diagnosis Challenge (ACDC) in MICCAI challenge 2017에서 제공한 cardiac MRI 데이터를 이용하였다.

전처리 과정으로 영상을 단축 단면도를 기준으로 심실 영역을 지역화 작업을 진행하였고, 영상 크기 재조정(rescaling)을 통해 256 x 256 크기로 조정하였다. MRI 영상의 특성으로 일정하지 않은 강도(intensity)의 분포를 일정하게 만들기 위해 정규화(normalization)을 수행하였고, 학습속도 향상 및 지역 최적의 상태(local minima)에 빠질 가능성을 줄여주기 위해 표준화(standardization)를 수행하였다.

2.3. Experiments

총 100명의 환자 데이터 중 90명의 환자데이터는 학




Fig. 2 The data flow diagram for generation of images of the left ventricle based on ED/ES phase

습을 위한 데이터셋(data set), 10명의 환자 데이터는 테스트를 위한 데이터셋으로 구분하였다. 학습을 위한 장비로는 CPU I7-3770K와 RAM 32GB, Titan Xp (12GB)를 사용하였고, windows10 64bit기반에서 Tensorflow-1.2.0을 통해 프로그래밍하였다. 학습 파라미터는 adam optimizer를 사용하였고, beta1 0.5, 러닝레이트(learning rate) 0.0002, 배치크기(batch size) 1이며 총 300번의 epoch을 적용하였다. 또한 데이터 확대(data augmentation)를 위해 4번(0°, 90°, 180°, 270°)의 회전(rotation)을 적용하였다.


Fig. 3에 영상과 마스크를 쌍으로 학습시킨 결과를 심장 주기 순서로 나열을 하였다. GAN 모델의 특성상 정량적 평가가 어렵기 때문에 정성적으로 생성된 영상에 대해 비교를 하였고, 매칭된 실제 영상의 특징을 보유하고 있는 것으로 보였다. 하지만 주기와 주기 사이에 연관성이 크지 않으며, 모델을 통해 생성된 영상은 심근과 심실을 기준으로 학습이 되었기 때문에 주변 기관에 대해서는 무작위 값이 매핑된 것을 볼 수 있다.

다음 연구로는 각각의 심장 주기별로 시계열 데이터 처리를 위한 순환 신경망(RNN; recurrent neural network)을 이용하여 심장 주기별 특징의 가중치를 공유하여 적용해야 할 것이며, 영상을 입력하여 마스크를 생성하는 GAN기반 영역화(segmentation)를 적용해볼 수 있을 것이다. 또한 모델의 성능평가를 위해 MRI영상에서 실험을 진행하였으며, 추후 공간해상도(spatial resolution)가 더 높은 CT영상에 해당 모델을 적용한다면 결과가 더 의미있을 것으로 사료된다.

3. 결론

cGAN을 이용하여 전향적 심실 영상으로부터 후향적 심실 이미지를 생성하였으며, 실제 영상과 생성된 영상을 비교해보았다.

참고 문헌



- (1) Einstein, A. J., et al, 2007, "Radiation dose to patients from cardiac diagnostic imaging." *Circulation*, 116(11), 1290-1305.
- (2) Isola, P., et al, 2016, "Image-to-image translation with conditional adversarial networks." arXiv preprint arXiv:1611.07004.
- (3) Radford, A., et al, 2015, "Unsupervised representation learning with deep convolutional generative adversarial networks." arXiv preprint arXiv:1511.06434.
- (4) Kwak, H., et al, 2016, "Generating images part by part with composite generative adversarial networks." arXiv preprint arXiv:1607.05387.
- (5) Mathieu, M., et al, 2015, "Deep multi-scale video prediction beyond mean square error." arXiv preprint arXiv:1511.05440.

Fig. 3 The result of generated LV 4D images. (above) ground truth images. (below) generated images. end-diastole phase (green box) and end-systole phase (orange box)