

Residual Multi-dilated convolution U-Net을 이용한 다중 심장 영역 분할 알고리즘 연구

임상현*, 최한승*, 배희진*, 정서경*, 정진교**, 이명숙***

*계명대학교 의과대학 의용공학과

**한양대학교 공과대학 생체공학과

***계명대학교 타블라라사칼리지

e-mail:mslee@kmu.ac.kr

Multi-Class Whole Heart Segmentation using Residual Multi-dilated convolution U-Net

Sang-Heon Lim*, H.S. Choi*, S.K. Jung*, J.K. Jung**, Myung-Suk Lee***

*Department of Biomedical Engineering, Keimyung University

**Department of Biomedical Engineering, Hanyang University

***Tabula Rasa College, Keimyung University

요 약

본 연구에서는 딥 러닝을 이용하여 완전 자동화된 다중 클래스 전체 심장 분할 알고리즘을 제안하였다. 제안된 방법은 recurrent convolutional block과 residual multi-dilated block을 삽입하여 기존 U-Net을 개선한 인공신경망 모델을 사용하였다. 평가는 자동화 분석 결과와 수동 평가를 비교하였다. 그 결과 96.88%의 평균 DSC, 95.60%의 정확도, 97.00%의 recall을 얻었다. 이 실험 결과는 제안된 방법이 다양한 심장 구조에서 효과적으로 구분되어 수행되었음을 알 수 있다. 본 연구에서 제안된 알고리즘이 의사와 방사선 의사가 영상을 판독하거나 임상 결정을 내리는데 보조적 역할을 할 것을 기대한다.

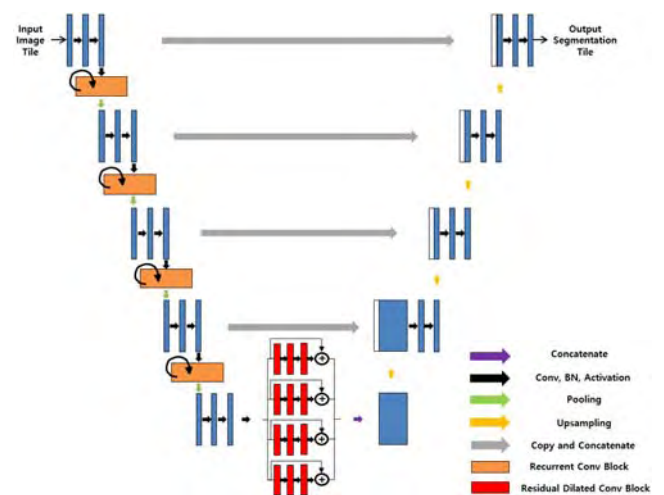
1. 서론

순환계통 질환 중 심장 질환으로 인한 사망률은 60.2%로 악성종양 다음으로 가장 높은 2위를 차지하고 있으며, 매년 증가하고 있는 추세이다[1]. 심장 질환의 진단은 주로 컴퓨터 단층촬영(Computed Tomography, CT)과 같이 비침습적 투시 검사를 통해 이루어진다. CT는 심장을 고화질의 영상으로 관찰할 수 있으며, 심장의 해부학적 이상을 검출하기에 적합한 영상진단법이다. CT가 심질환의 해부학적 이상을 판독하기 위한 영상진단 장치로 꾸준히 이용됨에 따라, 심장의 하부 구조들을 정확히 분할하는 것은 심장의 기능을 정량적으로 평가하고 분석하는 것에 있어서 중요한 과정 중 하나가 되었다. 그러나 여전히 많은 임상적 연구는 심장의 구조를 분할함에 있어 영상의학 전문가 또는 방사선사의 수동 분할 방법에 의존하고 있다. 이 과정은 심장의 단면 영상을 하나씩 분석해야 하므로 과도한 노동과 시간이 소요된다. 또한, 심장의 하부구조들은 물리적인 조직으로 분리되어 있지 않기 때문에 정확한 분할을 위해서는 관찰자의 전문적인 해부학적 지식이 필요하며, 전문가에 따라서 분할 결과가 달라지는 경향이 있다 [2]. 기존의 전통적인 영상처리 방법 및 패턴인식 기반의 기계학습 방법[3]으로는 모든 case의 영상에 일반화하여 정확하게 분할하는 것에 한계가 존재한다. 따라서 본 연구에서는 딥 러닝(deep learning)을 기반으로 심장의 구조를 전-자동으로 분할하고 3차원으로 가시화하여 의사의

진단을 보조하는 인공지능 모델을 제안한다.

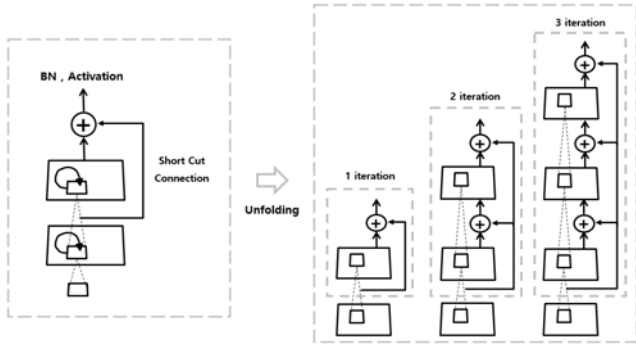
2. 다중 심장 분할 알고리즘

(그림 1)에서 심장의 구조를 분할하기 위해 기존 의료 영상 분할 문제에 탁월한 성능을 내는 것으로 알려진 U-Net[4]에 recurrent convolutional block과 residual multi-dilated block을 삽입하여 기존 U-Net을 개선한 인공신경망 모델을 사용하였다.



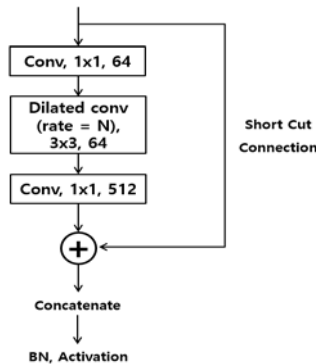
(그림 1) U-Net을 개선한 인공신경망 모델

(그림 2)에서는 recurrent convolutional block을 보여주고 있다. 이는 각 convolution layer 간의 weight를 공유함으로써 convolution layer가 물체 특징의 통계적 정규성을 포착할 수 있는 능력을 향상시켜준다[5].



(그림 2) Recurrent convolutional block

(그림 3)은 Residual multi-dilated block에서 ResNet[6]의 short cut과 dilated convolution을 사용하여 CT의 연속적인 특징과 더 넓은 receptive field를 동시에 고려하여 학습하도록 하였다.



(그림 3) Residual multi-dilated convolutional block

두 block 모두 short cut connection을 사용하여 각 convolutional block에서 입력과 출력 간의 잔차를 학습함으로써 gradient vanishing 문제와 overfitting 문제를 완화하였다. 모델의 분할 성능을 평가하기 위해 예측된 분할 결과와 수동 분할 결과 사이의 Dice Similarity Coefficient (DSC), Precision, 그리고 Recall을 계산하여 비교 분석하였다. 심장 구조의 분할 결과는 3차원 볼륨 재구성을 통해 시각화하였다.

3. 실험 및 결과


본 연구에서는 Multi-Modality Whole Heart Segmentation Challenge2017[7]에서 제공받은 환자 20명의 CT 데이터를 사용하였다. 모든 환자의 영상 데이터는 각각의 slice로 나누어 Training, Validation, Test Set

(6:2:2)의 비율로 나누어 실험하였다.

Dilated convolution은 convolution layer에 dilated rate 파라미터를 추가한 것이다. 이 방법은 pooling을 수행하지 않고도 receptive field를 늘릴 수 있기 때문에 spatial dimension 손실이 적으며, dilated rate의 크기에 따라 필터링을 하는 영역이 커지므로 영상에서 특징을 추출하기 용이한 방법이다. 본 연구에서는 dilated rate 2, 4, 8, 16을 가지는 4개의 convolution을 병합하여 다양한 receptive field에서 추출된 특징을 모두 고려하도록 모델을 설계하였다.

환자 20명의 DICOM 영상을 data augmentation 방법을 이용하여 영상을 shifting하거나 rotating하여 training set과 validation set을 증식하였다. Data augmentation 방법을 통해 기존 training set으로부터 더 많은 training 데이터를 생성하여 새로운 데이터에 일반화할 수 있도록 과대적합(overfitting)을 방지하였다. 학습은 64개의 batch size로 진행하였으며, Adam optimizer[8]를 사용하였다. Adam의 초기 learning rate은 0.001로 시작하여 validation 정확도가 5번 saturation되면 현재 learning rate의 20%만큼 줄여 learning rate을 업데이트하였다. 모델이 학습하는 중 15번의 epochs 동안 학습의 진전이 없을 경우 학습을 중단하는 early stopping 기법을 이용하였으며, 일반적으로 100~120 epochs 사이에서 학습이 중단되었다. 모델의 손실 함수는 Tversky loss function[9]을 사용하였다.

인공신경망 모델의 성능을 평가하기 위해 심장구조 분할결과를 수동 분할한 결과와 DSC, Precision, Recall를 계산하여 비교하였다. (그림 4)와 같이 결과를 3차원 볼륨 재구성을 통해 시각화 하였다.



(그림 4) 심장 하부 구조의 3D 볼륨 렌더링

본 연구에서는 기존의 U-Net 모델, U-Net에 recurrent convolutional block을 삽입한 모델, residual multi-dilated block을 삽입한 모델, 두 block을 모두 삽입한 모델의 결과를 비교 분석하였다.

실험에 의하면 <표 1>과 같이 recurrent convolutional block과 residual multi-dilated block을 모두 삽입한 모델의 DSC가 96.88%로 가장 좋은 성능을 보였다. 특히 상행 대동맥의 분할 결과가 높은 정확도를 보였으며, 폐동맥의 분할 결과는 낮은 정확도를 <표 2>와 같이 보였다.

<표 2> 제안된 방법들의 성능 비교 실험 결과

Model	DSC	Precision	Recall
Simple U-Net	95.70%	94.90%	96.53%
U-Net+RC	96.44%	95.20%	96.63%
U-Net+RMDC	96.53%	94.80%	96.83%
U-Net+RC+RMDC	96.88%	95.60%	97.00%

RC, recurrent convolutional block;
RMDC, residual multi-dilated convolutional block

<표 3> 심장 하부 구조의 세그멘테이션 결과

Class	DSC	Precision	Recall
좌심실	97.30%	94.20%	97.50%
우심실	94.90%	95.07%	94.73%
좌심방	97.50%	96.34%	97.46%
우심방	95.10%	90.80%	96.90%
좌측 심근	96.04%	93.85%	96.14%
상행 대동맥	98.40%	96.73%	98.80%
폐동맥	93.36%	91.70%	93.36%

4. 결론

본 연구는 딥 러닝을 이용하여 심장 구조를 자동화된 다중 클래스로 분할하고 3차원으로 가시화하여 의사의 진단을 보조하는 인공지능 모델을 제안하였다. 심장 구조를 분할하는 방법으로 recurrent convolutional block과 residual multi-dilated block을 삽입하여 기존 U-Net을 개선한 인공지능 모델 사용하였다. Recurrent convolutional block은 각 convolution layer 간의 weight를 공유함으로써 convolution layer가 물체 특징의 통계적 정규성을 포착할 수 있는 능력을 향상시켜준다. Residual multi-dilated block에서는 ResNet의 short cut과 dilated convolution을 사용하여 더 넓은 receptive field를 고려하였다.

본 연구에서 제안한 딥 러닝 모델을 통해 실시간으로 심장의 구조를 자동으로 분할하고 3차원으로 가시화 된 모델을 제공함으로써 의료영상 전문의 또는 방사선사의 영상 판독과 의사결정을 보조할 수 있을 것으로 기대한다.

향후 자기공명영상(Magnetic Resonance Imaging, MRI) 전 처리 기법을 적용한 모델을 추가하여 CT뿐만 아니라 MRI를 3차원으로 가시화 할 수 있는 다중 모델을 개발하고자 한다.

참고문헌

- [1] 『2017년 사망원인 통계』, 통계청, 2018, pp. 10, 서울: 통계청.
- [2] Alejandro F. Frangi et al, "Three-Dimensional Modeling for Functional Analysis of Cardiac Images: A Review", IEEE Transactions on Medical Imaging, vol.20, no.1, 2001.
- [3] Zheng Y et al, "Four-Chamber Heart Modeling and Automatic Segmentation for 3D Cardiac CT Volumes Using Marginal Space Learning and Steerable Features", IEEE Transactions on Medical Imaging, vol.27, no.11, 2008.
- [4] Olaf Ronneberger, Philipp Fischer, Thomas Brox, "U-Net: Convolutional Networks for Biomedical Image Segmentation", International Conference on Medical Image Computing and Computer-Assisted Intervention - MICCAI, pp. 234-241, 2015.
- [5] Ming Liang, Xiaolin Hu, "Recurrent Convolutional Neural Network for Object Recognition", 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 3367-3375, 2015.
- [6] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, "Deep Residual Learning for Image Recognition", 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 770-778, 2016.
- [7] "MM-WHS: Multi-Modality Whole Heart Segmentation", Multi-Modality Whole Heart Segmentation Challenge, accessed Mar 28, 2019, <http://www.sdspeople.fudan.edu.cn/zhuangxiahai/0/mmwhs/>.
- [8] Diederik P. Kingma, Jimmy Ba, "Adam: A Method for Stochastic Optimization", arXiv:1412.6980v9, 2014.
- [9] Seyed Sadegh Mohseni Salehi, Deniz Erdogmus, Ali Gholipour, "Tversky Loss Function for Image Segmentation Using 3D Fully Convolutional Deep Networks", Machine Learning in Medical Imaging. LNCS, vol 10541, pp. 379-387, 2017