

딥러닝기반 심장 MRI에서의 심방, 심실 자동 분할 기법

장영걸* · 하성민* · 김세근* · 장혁재**

Automatic segmentation of LV and RV in Cardiac MRI

Yeonggul Jang*, Hyuk-Jae Chang**

Abstract : Automatic and accurate segmentation of Left Ventricle (LV) and Right Ventricle (RV) in cine-MRI is required to analyze cardiac function and viability. We pre-sent a fully convolutional neural network to efficiently segment LV and RV as well as myocardium. The network is trained end-to-end from scratch. Average dice scores from five-fold cross-validation on the ACDC training dataset were 0.94, 0.89, and 0.88 for LV, RV, and myocardium. Experimental results show the robustness of the proposed architecture.

1. 서 론

최근 초음파(Echo), 컴퓨터 단층촬영(CT), 자기공명 영상(MRI)과 같은 비침습 영상기술의 발전으로 영상으로 질환에 대한 정성적 및 정량적 분석이 가능해졌고, 심장구조 분할기술은 심장질환의 진단, 체적 분석, 영상 가이드 심혈관질환 중재시술[1] 등에 있어서 중요한 역할을 담당하고 있다. 심박출량과 같은 심장기능정보 추출을 위해 좌심실 및 우심실의 정확한 분할 기술은 특히 중요하다. 현재 임상현장에서 심장 기능을 평가하기 위한 표준검사방법으로 심장 MRI를 사용하고 있고, 심장 MR 영상에서 심근을 자동으로 영역화하는 다양한 접근법들이 제안되어왔다. [2, 3, 4]

최근 딥러닝 기술의 발전으로 물체 검출, 인식, 분할과 같은 다양한 자연영상처리 기술에서 비약적인 성능향상이 있었고, 의료영상에서도 관심구조를 분할하기 위하여 2차원/3차원 합성곱신경망(Convolutional neural network, CNN), 순환신경망(Recurrent neural network, RNN)과 같은 다양한 딥러닝 기법들이 적용되었다. [5, 6, 7, 8, 9]

최근 제안된 M-net은 3차원 정보를 이용하기 위하여 3D filter를 사용하는 3D-2D 변환층을 가진 U-net 기반의 네트워크 구조로 뇌 MR 영상에서 관심구조를

분할하는데 있어서 좋은 성능을 보였다. [10, 11]

본 논문에서 우리는 심장 MR 영상에서 좌심실, 좌심근 및 우심실을 완전 자동으로 분할하는 기법을 제안한다. 우리는 심장 MR 영상이 큰 슬라이드 두께(5~10mm)를 갖고 있으며 이런 문제가 분할 성능을 저하시킨다는 것을 관찰하였다. 이런 문제를 해결하기 위해 본 논문에서는 제안된 M-net 구조를 심장 MR 영상에 잘 작동될 수 있도록 변형하여 사용하였다. 기법에 대한 자세한 부분과 심혈 결과는 본문에서 기술할 것이며, 결론에서 기법에 대한 정리와 추가 연구에 대하여 기술할 것이다.

2. 본 론

2.1. 심장 MR 데이터셋

제공된 심장 MR 영상은 Dijon 대학병원에서 획득되었고 STACOM 주관 MICCAI 2017 workshop: Automated Cardiac Diagnosis Challenge(ACDC)을 목적으로 공개된 데이터셋이다. 총 100명의 환자에서 획득한 심장 cine MR 영상(3D + t)은 short-axis을 따라 만들어졌으며 확장말기, 수축말기 두 phase 영상만 좌심실, 좌심근, 우심실 3개의 심장구조에 대한 분할참값이 있다. 해당 데이터는 정상포함 각 질환별로 20명씩 총 5개의 카테고리로 분류된다. (normal case, heart failure with infarction, dilated cardiomyopathy, hypertrophic cardiomyopathy, and abnormal right

* 연세대학교 의과대학 의과학과

*** 연세대학교 의과대학 내과학교실 심장내과

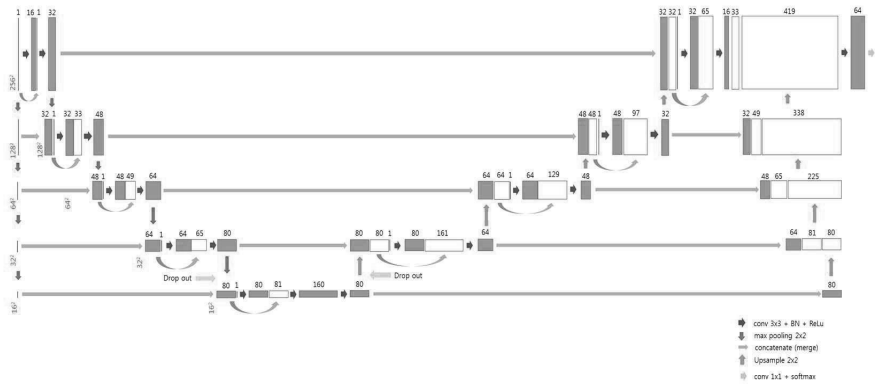


그림 1. 제안하는 네트워크 구조

ventricle)

2.2. 전처리과정

다양한 사이즈를 갖는 영상을 큰 축 크기가 256이 되도록 맞추고 후 나머지 영역에 대하여 zero-padding하여 256 x 256으로 모두 고정하였다. 또한, 16 bit MR 영상은 스캐너 혹은 획득 프로토콜에 따라 다른 값을 가지는데, 이것은 분할 모델의 성능에 영향을 미칠 수 있으므로 평균을 0, 표준편차를 1로 정규화를 수행하였다.

2.3 분할 네트워크 구조

제공된 데이터셋이 큰 슬라이스 두께(5~10mm)를 가지고 있어 인접한 슬라이스간 연속성이 충분하지 않다. 즉, 이 경우 3차원 정보를 고려할 필요가 없으며 오히려 모델의 일반화 성능을 저해할 수 있다. 본 논문의 네트워크는 M-net 구조에서 3차원 정보를 이용하기 위한 3D-2D 변환층을 제거하였으며 네트워크 층의 높이를 늘려 성능을 향상시켰다. 모델은 contraction, expanding 2가지 메인 pathway를 갖는다. 각 pathway는 5개의 cascade step으로 구성되는데, contraction의 각 step은 2개의 3x3 convolution과 2x2 max-pooling으로 구성되며, expanding은 max-pooling 대신 up-sampling을 사용한다. 또한, 정확한 분할 지역화를 위해 contraction의 각 step의 출력은 expanding의 해당하는 층으로 연결되어 정보를 전달하는데 이는 학습 시 gradient를 더 잘 전달시켜 학습을 잘되도록 하는 작용도 한다. 마지막 층은 4개(배경, 우심실, 좌심근, 좌심실) 1x1 filter와 함께한 convolution 층으로 구성되고 활성화함수로 pixel-wise softmax를 수행한다. pixel별 최종 분할 레이블은 4개의 클래스 중

가장 큰 값을 가지는 것으로 결정된다. 수렴속도를 증가시키기 위해 batch normalization은 convolution 후 relu 활성화함수 전에 수행되고 과적합 문제를 해결하기 위하여 dropout은 0.5의 확률로 2개의 메인 pathway에 각각 한번 씩 적용되었다. 또한, 클래스간 불균형 문제를 해결하기 위해 비용함수로 클래스 수 기반 weighted cross entropy를 사용하였다.

2.4. 실험 결과

2.4.1 구현 세부정보

각 질환별 수를 동일하게 맞춰 100명 환자 데이터 중 80명을 학습, 20명을 테스트 데이터로 분류하여 5-fold 교차검증을 수행하였다. 또한, 회전 및 랜덤블러를 통한 데이터 증강을 통해 데이터 수를 늘려 학습하였다. 후처리로 작은 볼륨 제거 또는 채우기 위해 형태학적 연산을 수행하였고 좌심실에 대해서는 오목한 형태를 제거하기 위해 convex hull을 적용하였다.

제안된 네트워크는 NVIDIA TITAN X에서 다음과 같은 하이퍼-파라미터를 사용하여 학습되었다. (batch size: 20, 150 epochs, RMSProp optimizer(lr: 10^{-3} , decay: 0.9, momentum: 0, epsilon: 10^{-10})

	DSC		
	RV	LV-Myo	LV
U-net	0.900	0.878	0.967
U-net with converter	0.878	0.829	0.959
The proposed FCN	0.908	0.883	0.962

표 1. 제안하는 기법과 다른 네트워크와의 비교.




그림 2. Base, Mid, Apex 3가지 다른 level에 대한 분할 참값과 제안된 기법의 분할 결과의 정성적 비교.

2.4.2 실험 결과 및 다른 방법과의 정량적 비교

체적일치도(Dice Similarity Coefficient, DSC)와 하우스도프 거리(Hausdorff distance, HD)를 사용하여 모델의 분할 성능을 평가하였다.

아래 표와 같이 제안된 네트워크는 분할 참값을 기준으로 다른 두 개의 네트워크 구조 U-net, 3D-2D 변환층 결합 U-net과 비교되었고 좌심실, 좌심근, 우심실을 분할하는데 있어서 보다 좋은 성능을 보였다. 특히 큰 슬라이스 두께를 가지는 영상에 3D 정보를 고려했을 경우 오히려 성능이 저하되는 것을 확인할 수 있었다. 또한, 5-fold 교차검증에서도 우수한 분할 결과를 확인하였고 데이터 증강을 통해 분할 성능이 더

향상될 수 있음을 보였다.

제안 네트워크의 좌심실, 좌심근, 우심실에 대한 평균 분할 계산시간은 CPU(i7-6770)에서 8.09초, GPU에서 0.62초로 매우 빠른 시간 내 3개의 심장 구조를 분할하였다.

3. 결론

본 논문에서 우리는 심장 MR 영상에서 좌심실, 좌심근, 우심실을 자동으로 분할하는 합성곱 신경망을 제안하였다. 제안된 방법은 더 많은 skip 연결과 깊은 네트워크 높이로 다른 네트워크보다 더 나은 특징을 학습할 수 있었고, 분할 참값과 비교하여 우수한 분할 성능을 보였다. 특히, 좌심실, 좌심근과 달리 회전에 따라 다르게 보일 수 있는 우심실의 경우 회전 변환을 통한 데이터 증강 후 분할 성능이 크게 향상됨을 확인하였다.

제안된 방법은 우수한 성능과 함께 심장기능 분석을 위해 사용될 수 있을 것이고 더 나아가 추가 분할 참값 초기 생성을 하는데도 적용되어 생성 시간을 줄이는데 크게 도움을 줄 것으로 예상된다.

향후 연구로 분할 성능 향상을 위해 계산된 심장구조에 대한 확률맵에 더 정교한 사후 처리 알고리즘을 적용할 것이며, basal, apical level에서의 추가적인 성능 향상을 위해 level 분류를 통한 level별 다른 접근 방법을 연구할 것이다.

		RV		LV-Myo		LV	
		ED	ES	ED	ES	ED	ES
DSC	CV#1	0.934±0.03	0.837±0.09	0.880±0.02	0.903±0.02	0.960±0.02	0.924±0.05
	CV#2	0.924±0.03	0.853±0.07	0.866±0.03	0.882±0.04	0.959±0.01	0.919±0.04
	CV#3	0.917±0.03	0.851±0.10	0.861±0.05	0.884±0.04	0.956±0.02	0.898±0.09
	CV#4	0.918±0.06	0.843±0.09	0.853±0.04	0.873±0.04	0.958±0.02	0.911±0.08
	CV#5	0.932±0.04	0.891±0.04	0.892±0.03	0.900±0.03	0.970±0.02	0.920±0.05
	Avg	0.925±0.04	0.855±0.08	0.870±0.04	0.888±0.04	0.961±0.02	0.915±0.06
Total		0.890±0.07		0.879±0.04		0.938±0.05	
HD (mm)	CV#1	12.49±5.87	15.54±5.05	9.23±5.93	8.68±3.91	7.29±4.36	7.15±4.27
	CV#2	14.63±5.55	16.20±5.89	10.88±9.02	11.86±6.78	6.94±4.50	9.52±4.10
	CV#3	15.61±7.62	15.34±5.57	9.52±5.27	10.49±3.80	8.73±5.66	8.78±4.69
	CV#4	15.30±7.60	16.98±8.80	9.68±6.21	11.83±6.28	7.49±8.29	9.33±5.94
	CV#5	11.82±4.91	14.64±7.49	7.84±6.50	9.22±5.36	3.99±2.83	8.90±6.55
	Avg	12.60±6.02	14.78±6.36	9.47±6.64	10.05±5.27	6.27±4.74	8.28±4.67
Total		13.69±6.30		9.76±6.02		7.27±4.83	

표 2. 5-fold 교차검증에서의 체적 일치도(DSC), 하우스도프 거리(HD) 결과

참고 문헌

- (1) Kang, D., et al., Heart chambers and whole heart segmentation techniques. *Journal of Electronic Imaging*, 2012, 21(1): p. 010901, 1-16, 2012.
- (2) Petitjean, C., et. al, A review of segmentation methods in short axis cardiac MR images, *Medical Image Analysis*, 15(2), pp. 169-184, 2011.
- (3) Bai, W., et. al, A Probabilistic Patch-Based Label Fusion Model for Multi-Atlas Segmentation With Registration Refinement: Application to Cardiac MR Images, 32 (7), pp. 1302-1315, 2013.
- (4) Bai, W., et. al, Multi-atlas segmentation with augmented features for cardiac MR images, *Medical Image Analysis*, 19 (1), pp. 98-109, 2015.
- (5) Avendi, M., et. al, A combined deep-learning and deformable-model approach to fully automatic segmentation of the left ventricle in cardiac MRI. *Medical image analysis*, 2016. 30: p. 108-119.
- (6) Wolterink, J.M., et al. Automatic coronary calcium scoring in cardiac CT angiography using convolutional neural networks. in *International Conference on Medical Image Computing and Computer-Assisted Intervention*. 2015. Springer.
- (7) Poudel, R.P., et. al, Recurrent fully convolutional neural networks for multi-slice mri cardiac segmentation. in *International Workshop on Reconstruction and Analysis of Moving Body Organs*. 2016. Springer.
- (8) Zhen, X., et. al, Multi-scale deep networks and regression forests for direct bi-ventricular volume estimation, *Medical Image Analysis*, 30, pp.120-129, 2016.
- (9) Litjens, G., et. al, A survey on deep learning in medical image analysis, arXiv:1702.05747.
- (10) Mehta, R., et. al, M-Net: A convolutional neural network for deep brain structure segmentation, *Int. Symp. Biomedical Imaging*, pp. 437-440, 2017.
- (11) Ronnenberger, O., et. al, U-Net: Convolutional networks for biomedical image segmentation. In *MICCAI*, pp. 234 - 241, 2015.