

뇌졸중 병변 분할을 위한 효율적인 U-Net

신현광, 최규상

영남대학교

shg3786@ynu.ac.kr, castchoi@ynu.ac.kr

e-UNet: Efficient U-Net for Brain Stroke Lesion Segmentation

Hyunkwang Shin, Gyu Sang Choi

Yeungnam Univ.

요약

뇌졸중은 전 세계적으로 가장 흔한 신경학적 질환이며, 일반적으로 방사선 전문의가 직접 뇌졸중 병변을 분할한다. 이는 많은 시간이 소요되며, 전문의의 주관적 인식에 의존하게 되기 때문에 뇌졸중 병변을 자동으로 분할하는 연구가 중요하다. 최근 딥 러닝 발전과 함께 컨볼루션 네트워크 기반의 이미지 분할 연구가 많이 진행되고 있지만, 많은 파라미터 수와 장기 의존성 문제가 존재한다. 이 문제를 해결하기 위해 기존의 U-Net 구조에 e-block과 Non-local block을 적용한 e-UNet(Efficient UNet)을 제안한다. e-UNet의 성능을 평가하기 위해 ATLAS(Anatomical Tracings of Lesions After Stroke) 데이터를 활용했으며, 기존의 SegNet, U-Net, 2D Dense-UNet 보다 더 나은 성능을 달성했다.

I. 서론

뇌졸중은 뇌의 혈관이 터지거나 막힘으로써 해당 부위가 손상되어 발병되며, 전 세계적으로 두 번째 사망원인이다[1]. 일반적으로 뇌졸중 병변은 방사선 전문의가 직접 MR 이미지에 포함된 병변을 분할한다. 이는 많은 시간이 소요되며, 전문의의 주관적 인식에 의존하게 되기 때문에 뇌 병변 분할을 위한 자동화 연구가 필요하다[2]. 뇌졸중 병변은 그림 1과 같이 모양과 경계가 명확하지 않으며, 다양한 위치에서 발생 된다.

최근 몇 년간 딥 러닝 발전과 함께 컨볼루션 네트워크 기반의 이미지 분할 연구가 진행되고 있으며, 대표적인 모델로 SegNet[3], U-Net[4], 2D Dense-UNet[5] 등이 있다. U-Net은 의료 영상 분할의 대표 모델로 인코더와 디코더 구조에 skip connection을 결합한 구조로 이루어져 있다. 하지만, 고정된 컨볼루션 크기와 다운 샘플링에 의해 로컬 수용 필드 및 특징 정보 재사용이 제한됨으로 크기 및 경계가 명확하지 않아 뇌 병변 분할 결과에 영향을 미친다. 또한, 기존의 이미지 분할 모델들은 많은 학습 파라미터들이 요구된다.

본 논문에서는 위에서 언급한 문제를 해결하기 위해 e-UNet 모델을 제안한다. e-UNet은 기존의 U-Net에 사용되는 컨볼루션을 깊이별 분리 컨볼루션(Depthwise Separable Convolution; DSC)[6] 기반의 e-block으로 대체함으로써, 학습 파라미터를 줄인다. 또한, Non-local block[7]을 통해 장기 의존성 문제 해결하며, 기존의 SegNet, U-Net, 2D Dense-UNet 모델과 성능을 비교한다.

II. e-UNet

본 논문에서는 뇌졸중 병변 분할을 위한 e-UNet을 제안하며, 구조는 그림 2와 같다. e-UNet은 기존 U-Net 구조에서 컨볼루션 연산과 브릿지(brige) 위치에 e-block 및 Non-local block이 적용된다. 기존 U-Net은 각 계층에서 두 번의 3×3 컨볼루션 연산을 수행하며, $2(K^2CM)$ 파라미터 수가 요구된다. K 는 필터의 크기, C 와 M 은 입력 채널 수, 필터의 개수를




그림 1. 뇌졸중 병변 분할의 예

의미한다.

제안하는 e-block은 1×1 컨볼루션을 사용하여 필터 수를 결정하고, 두 번의 깊이별 컨볼루션(Depth-wise Convolution)과 1×1 컨볼루션을 통해 나온 결과와 합치게 된다. 첫 번째 연산은 3×3 깊이별 컨볼루션을 통해 공간적 특징을 추출하고, 1×1 컨볼루션을 통해 출력 채널의 수를 2배 늘린다. 그 후, 다시 3×3 깊이별 컨볼루션과 1×1 컨볼루션을 통해 입력 채널 수와 동일하게 출력 채널을 맞춘다. 제안하는 e-block의 파라미터 수는 $CM + C(K^2 + 2M) + 2C(K^2 + M)$ 이며, 각 계층은 $C(3K^2 + 5M)$ 만큼의 파라미터 수를 가지게 된다. 따라서, 각 계층의 두 파라미터 수 차이는 e-block 파라미터 수/기존 컨볼루션 파라미터 수 = $3/2M + 5/2K^2$ 배 차이난다.

III. 실험 및 결과

3.1 데이터셋

뇌졸중 병변 분할에 대한 e-UNet의 성능을 평가하기 위해 ATLAS(Anatomical Tracings of Lesions After Stroke) 데이터[2]를 사




그림 2. e-UNet 구조

용했다. ATLAS는 다양한 병변이 포함된 229개의 정규화된 T1-가중치 (T1-weighted) 3D MRI로 구성된다. 각 3D 이미지는 189개의 슬라이스로 구성되며, 233×197 이미지에서 224×192영역만 네트워크의 입력으로 사용한다.

3.2 실험 결과

본 논문에는 5-교차 검증(5-fold cross validation)을 통해 제한하는 모델을 검증하며, 평가지표로 Dice score, 정밀도, 재현율을 사용한다. 표 1은 2D Dense-UNet, U-Net, SegNet 모델과 제한하는 e-UNet 간의 성능을 비교한 결과이며, 기존 모델에 비해 Dice score와 정밀도가 향상된 것을 확인할 수 있다. 또한, e-UNet의 파라미터 수는 11.5M로 기존 모델보다 적은 파라미터 수와 연산량으로 모델을 학습할 수 있다.

표 1. 성능 결과

	Dice	정밀도	재현율	파라미터 수
2D Dense-UNet	0.4741	0.5613	0.4875	41.3M
SegNet	0.277	0.394	0.2532	29.5M
U-Net	0.461	0.599	0.445	34.5M
e-UNet	0.480	0.624	0.451	11.5M

IV. 결론

본 논문에서는 뇌졸중 분할을 위해 e-UNet 모델을 제안했으며, e-block을 통해 학습 가능한 파라미터의 수를 효율적으로 줄였다. 또한, Non-local 블록을 통해 장기 의존성 문제를 해결했으며, ATLAS 데이터를 통해 제안 모델이 기존 모델보다 적은 파라미터 수와 뇌졸중 분할에 우수함을 검증했다.

ACKNOWLEDGMENT

이 논문은 2019년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구(2019R1A2C1006159)이며, 미래창조과학부 및 정보통신기술진흥센터의 대학ICT연구센터육성 지원사업의 연구결과로 수행되었으며 (IITP-2020-2016-0-00313), 2016년도 산업통상자원부 및 산업기술평가관리원(KEIT) 연구비 지원에 의한 연구임(No.10063130, 익스트림 트랜잭션 및 분산 확장성을 제공하는 대용량 비휘발성 메모리(SCM) 기반의 차세대 인메모리 빅 데이터베이스 시스템 상용 기술 개발)

참고 문헌

- [1] Johnson W., Onuma O., Owolabi M., et al.: Stroke a global response is needed. Bulletin of the World Health Organization 94(9), 634 (2016)
- [2] Liew, S. L., Anglin, J. M., Banks, N. W., et al.: A large, open-source dataset of stroke anatomical brain images and manual lesion segmentations. Scientific data (2018)
- [3] Badrinarayanan V., Kendall A., Cipolla R.: Segnet: A deep convolutional encoder-decoder architecture for image segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence 39(12), pp. 2481 - 2495 (2017)
- [4] Ronneberger O., Fischer P., Brox T.: U-net: Convolutional networks for biomedical image segmentation. In: International Conference on Medical Image Computing and Computer-Assisted Intervention. pp. 234 - 241 (2015)
- [5] Li X., Chen H., Qi X., et al.: H-denseunet: Hybrid densely connected unet for liver and tumor segmentation from ct volumes. IEEE Transactions on Medical Imaging 37(12), 2663 - 2674 (2018)
- [6] Chollet F.: Xception: Deep learning with depthwise separable convolutions. In: Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. pp. 1251 - 1258 (2017)
- [7] Cao, Y., Xu, J., Lin, S., Wei, F., & Hu, H. Gcnet: Non-local networks meet squeeze-excitation networks and beyond. In Proceedings of the IEEE International Conference on Computer Vision Workshops. pp. 0-0 (2019)