

멀티모달 레이블 기반 심정지 후 뇌손상 환자의 신경학적 예후 예측 인공지능 모델 개발

황지원, 김영우*
*국립금오공과대학교

alalalek@kumoh.ac.kr, *ywkim09@kumoh.ac.kr

Development of an AI model of neurological prognosis prediction in patients with post-cardiac arrest brain injury using multi-modal labels

Jiwon Hwang, Youngwoo Kim*

*Kumoh National Institute of Technology

요약

본 연구는 심정지 후 소생한 환자의 뇌 CT 영상에서 회백질 대 백질 비율(gray/white matter ratio; GWR)을 계산하기 위한 corpus callosum, caudate nucleus, putamen, internal capsule 이라는 4 가지 랜드마크를 자동 분할할 수 있는 딥러닝 모델을 제안한다. 뇌부종이 심한 환자의 경우 응급 CT 촬영을 해야 하기 때문에, 영상만으로는 뇌 구조를 명확히 구분하기 어려운 문제가 있다. 따라서 제안하는 인공지능 모델은 기존에 촬영한 MR 영상에서 GWR 을 계산할 수 있는 4 개의 랜드마크를 분할한 레이블을 이용하여 CT 영상의 분류를 수행하는 멀티모달(multi-modal) 인공지능 모델을 제안한다. 3 차원 영상의 분할을 위한 딥러닝 아키텍처인 3D U-Net 구조를 백본으로 사용하여 GWR 을 구하기 위한 랜드마크를 효과적으로 분할하였으며, 본 연구는 향후 GWR 의 자동 측정을 통해 신경학적 예후를 보다 빠르고 정확하게 예측하는 데 기여할 수 있을 것이다.

I. 서론

심정지 후 소생한 환자의 신경학적 예후를 조기에 예측하는 것은 환자의 치료 계획을 세우는데 매우 중요한 역할을 한다. 따라서 이를 예측하기 위한 다양한 방법들이 연구되어 왔다. 심폐소생술로 자발 순환 회복 후 초기 단계에서 심정지의 원인을 평가하기 위해 뇌 전산화단층촬영(Computed Tomography; CT)이 수행된다. 이 검사는 두 개 내 출혈이나 뇌부종을 식별하는 데 도움을 주며, 특히 뇌부종은 심정지 환자에서 저산소성 뇌 손상을 나타내는 중요한 지표가 될 수 있다. 심정지 후 뇌 손상은 소생한 환자의 주요 사망 원인 중 하나이며, 심장마비 후 목표체온치료 등의 급성기 치료 이후에도 장기적인 장애를 초래할 수 있다 [1], [2]. 뇌 CT 영상에서 회백질과 백질의 밀도 차이는 뇌부종과 관련된 중요한 정보를 제공한다. 회백질의 밀도는 세포독성 부종으로 인해 감소하는 반면, 백질은 비교적 덜 영향을 받기 때문에, 두 조직 간의 밀도 비율인 회백질 대 백질 비율(gray/white matter ratio; GWR)이 감소하는 경향을 보인다. 이러한 이유로 GWR 과 신경학적 예후 간의 연관성을 조사하는 연구들이 활발히 이루어지고 있다 [3]. 최근 인공지능 기술이 의료 영상 처리 분야에서 큰 진전을 이루면서, 뇌 해부학 구조를 자동으로 분할하는 연구들이 이루어졌다 [4]. 그러나 기존 연구는 대부분 정상적인 뇌 CT 영상을 대상으로 진행되었으며, 이를 뇌부종이 있는 병적 상태의 환자에게 적용시 정확도가 떨어지는 문제가 있었다. 또한, 심정지 상태로 내원한 환자의 경우 응급 뇌 CT 만을 촬영할 수 있으므로 MRI (magnetic resonance imaging)와 같이 GWR 계산에 핵심적인 구조들(corpus

callosum, caudate nucleus, putamen, internal capsule)과 같은 해부학적 정보를 얻기 힘든 것이 현실이다. 따라서 본 연구는 이러한 문제를 해결하기 위해 영상의학과 전문의가 뇌 MRI 에서 분할한 4 가지의 랜드마크 레이블을 이용하여 심정지 후 소생한 환자의 뇌 CT 영상에서 동일한 4 가지의 랜드마크를 자동으로 분할할 수 있는 멀티모달 (multi-modal) 레이블 딥러닝 모델을 개발하고자 하며, 이는 향후 GWR 자동 측정을 통한 예후 예측 등의 임상시험에 활용될 수 있다.

II. 본론

뇌부종이 심한 환자의 경우, CT 영상만으로는 뇌의 해부학적인 세부 구조를 구분하는 것이 어렵다. 이를 해결하기 위해, 본 연구에서는 같은 환자의 MR 영상을 활용하여 영상의학과 전문의가 해부학적 구조가 명확히 구분된 수동 분할 작업을 먼저 시행한 후, 그 결과를 CT 영상에 적용하는 방식을 제안한다. 이를 위하여 우선 MR 영상에서 얻은 4 가지 랜드마크의 레이블을 동일 환자의 뇌 CT 영상에 정합(registration)하고, 이를 CT 영상에 반영함으로써, 뇌 CT 영상에서 각각 랜드마크의 경계를 보다 정확히 분할할 수 있었다. 총 55 명에게서 촬영한 심정지 후 소생 환자의 뇌 CT 영상 1824 개를 학습에 활용하였으며, 이 중 44 명은 학습(train) 데이터로, 11 명은 검증(validation) 데이터로 사용하였다. 뇌 구조 예측 작업은 슬라이스 간의 연관성을 파악하는 것이 중요하므로, 여러 2 차원 뇌 CT 영상을 스택(stack)하여 3 차원 데이터로 전처리한 후 학습을 진행하였다. 모델 학습에는 slice thickness, pixel spacing 등의 정보를

이용하여 입력 의료영상을 정규화하고 자동화된 하이퍼파라미터 최적화 기능을 제공하여 의료영상 분석에 효과적인 최적의 학습률과 배치 크기를 설정할 수 있는 nnUNet[5]을 백본으로 사용하였으며, 데이터 특성에 맞추어 3D Full Resolution U-Net 구조를 채택하였다.

III. 실험 결과

그림 1 은 Train Loss 와 Validation Loss 의 변화를 epoch 에 따라 나타낸 그래프이다. Train Loss 는 epoch 가 증가함에 따라 지속적으로 감소하여 모델이 훈련 데이터에 대해 잘 학습하고 있음을 보여준다. 그러나 Validation Loss 는 초기에는 감소세를 보였으나 이후 일정한 범위에서 변동하며 더 이상 유의미한 개선이 이루어지지 않고 있다.

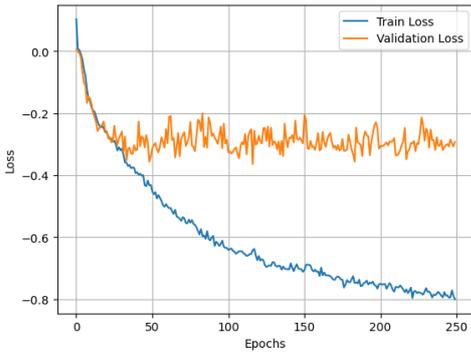


그림 1. 뇌 MRI 에서 얻은 4 가지 랜드마크 레이블을 활용한 뇌 CT 영상의 3D U-Net 학습 과정 (청색 실선: 학습 데이터 손실, 주황색 실선: 검증 데이터 손실)

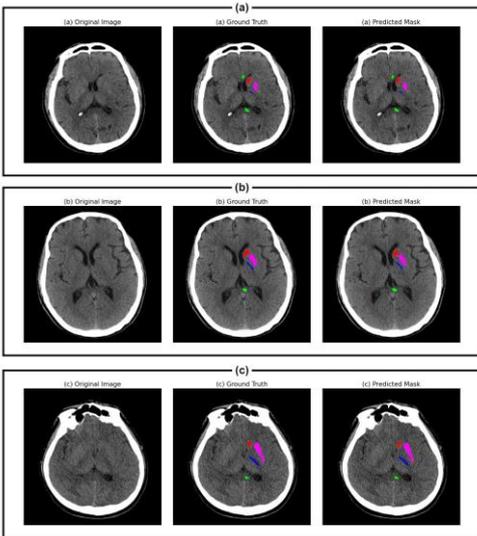


그림 2. 3 차원 U-Net 을 이용한 뇌 CT 랜드마크 자동 분할 결과 (a: 90.5%, b: 93.0%, c: 94.2%)

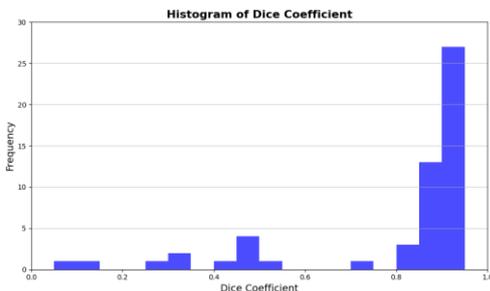


그림 3. 전체 데이터에 대한 Dice 계수 히스토그램

표 1. 학습 데이터와 검증 데이터의 성능 평가 지표

데이터셋	데이터 개수	평균 Dice Score	표준편차
학습 데이터	1466	0.901	0.037
검증 데이터	358	0.361	0.138
전체	1824	0.793	0.227

그림 2 는 제안하는 딥러닝 아키텍처를 이용하여 MRI 영상을 자동 분할한 예시이며, 그림 3 은 전체 데이터에 대한 Dice 계수의 분포를 나타낸다. 대부분의 데이터가 80% 이상의 일치도를 보이나, 일부 과적합된 데이터의 경우 비교적 낮은 일치도를 나타낸 것을 확인할 수 있다. 이러한 결과는 모델이 훈련 데이터에 비해 검증 데이터에 대한 일반화 성능이 부족할 수 있음을 의미하며 이는 학습에 사용되는 데이터의 수가 충분하지 않아 데이터에 과잉적합(Over-fitting)되어 모델이 다양한 패턴의 데이터를 학습하는 데 한계가 있다는 것이라고 예측된다. 따라서 향후 더 많은 유형의 데이터가 추가로 주어진다면 추가적인 모델의 성능 향상이 있을 것으로 기대된다.

IV. 결론

본 연구에서는 심정지 후 소생한 환자의 뇌 CT 영상을 이용하여 회백질과 백질을 자동으로 분할하는 모델을 제안하였다. 이를 통해 뇌 MRI 에서 생성된 랜드마크를 이용하여 뇌 CT 영상을 자동 분할할 수 있다는 가능성을 제시하였고, 향후 추가 데이터 확보를 통해 딥러닝 파라미터의 과잉적합 문제를 극복하여 성능 개선을 이룰 수 있을 것으로 기대된다. 또한, 이를 이용하여 GWR 을 효과적으로 계산하고 신경학적 예후를 예측하는 임상연구에 기여할 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

This work was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. RS-2024-00345567)

참 고 문 헌

- [1] V. Lemiale *et al.*, "Intensive care unit mortality after cardiac arrest: the relative contribution of shock and brain injury in a large cohort," *Intensive Care Med.*, vol. 39, no. 11, pp. 1972–1980, Nov. 2013.
- [2] "Standards for Studies of Neurological Prognostication in Comatose Survivors of Cardiac Arrest: A Scientific Statement From the American Heart Association."
- [3] B. K. Lee *et al.*, "Prognostic values of gray matter to white matter ratios on early brain computed tomography in adult comatose patients after out-of-hospital cardiac arrest of cardiac etiology," *Resuscitation*, vol. 96, pp. 46–52, Nov. 2015.
- [4] "Fully Automated Segmentation of Head CT Neuroanatomy Using Deep Learning." Accessed: Sep. 23, 2024.
- [5] F. Isensee *et al.*, "nnU-Net: Self-adapting Framework for U-Net-Based Medical Image Segmentation," Sep. 27, 2018, *arXiv: arXiv:1809.10486*. Accessed: Sep. 23, 2024.