

의료 도메인에서 Spiking Neural Network 기반 3D U-Net 적용 가능성 평가

이수범¹, 정성민²

¹명지전문대학 컴퓨터보안공학과 학생

²명지전문대학 컴퓨터보안공학과 교수

tnqjae@mjc.ac.kr, smjung@mjc.ac.kr

Evaluating the Applicability of a Spiking Neural Network-Based 3D U-Net in the Medical Domain

Sooboom Lee¹, Sungmin Jung²

¹Dept. of Computer Security Engineering, Myongji College

²Dept. of Computer Security Engineering, Myongji College

요약

본 연구에서는 3D U-Net의 활성화 함수(ReLU)를 Spiking Neural Network(SNN)의 Leaky Integrate-and-Fire(LIF) 뉴런으로 대체한 Spiking 3D U-Net 모델을 구현하였다. 의료영상 데이터셋인 MICCAI 2017 ACDC를 활용하여 기존 모델과의 분할 성능 및 전력 효율을 비교하였다. 실험 결과, Spiking 3D U-Net은 기존 3D U-Net보다 낮은 IoU 성능을 보였으나, 약 20%의 전력 소비 절감을 확인하였다. 이는 Spiking 뉴런의 희소한 발화 특성에 따른 연산 효율 향상에 기인한 것으로 해석된다. 향후 연구에서는 데이터 증강을 통한 학습 데이터 확대와 SNN 구조의 개선을 통해 모델의 성능과 일반화 능력을 향상시키고자 한다.

적은 양의 주석 데이터로도 학습이 가능하다[3].

SNN(Spiking Neural Network)는 생물학적 뉴런의 작동 원리를 모사한 이벤트 기반 신경망으로, 입력신호가 특정 임계값을 초과할 때만 출력을 생성하여 연산의 희소성과 효율성을 확보할 수 있다. 대표적인 스파이크 뉴런에는 LIF, SRM, Izhikevich 모델 등이 있으며, 이 중 LIF는 입력 전류가 임계값에 도달하면 뉴런이 발화한 뒤 상태를 초기화되는 방식으로 가장 널리 사용되는 모델이다[4].

3. 실험

본 연구에서는 2017년 MICCAI에서 공개된 ACDC 데이터셋을 활용하였다[5]. 이 데이터는 프랑스 디종 대학병원에서 수집된 150명의 심장 cine-MRI 영상이며, 좌심실과 우심실의 구조를 포함한 이완기 및 수축기 시점의 영상과 정답 데이터(Ground Truth)를 제공한다.

훈련 데이터는 100명의 환자 폴더로 구성되어 있으며, 각 폴더에는 MRI 프레임 2개와 그에 대응하는 정답 데이터(Ground Truth)가 포함되어 있다. 본 연구에서는 200개의 데이터 중 160개를 학습용으로,

1. 서론

의료영상 분야에서는 질병 진단을 지원하기 위해 병이 있는 부위를 탐지하고 중증도를 분류하는 인공지능 기술이 활발히 연구되고 있다[1]. 기존에는 CNN 기반 모델이 주로 사용되었으나, 이들은 높은 연산량과 전력 소모로 인해 자원이 제한된 환경에서는 활용에 어려움이 있었다[2]. 본 연구에서는 기존 3D U-Net의 활성화 함수를 Spiking 뉴런으로 단순히 치환한 Spiking 3D U-Net을 snntorch 기반으로 구현하여 IoU 스코어와 전력 소비량에 대해 비교하였다. 기존 모델과 비교해 복잡한 구조 변경 없이 SNN이 3차원 영상 분할 모델에 적용할 수 있음을 확인하고, 향후 적용 가능성을 제시하고자 한다.

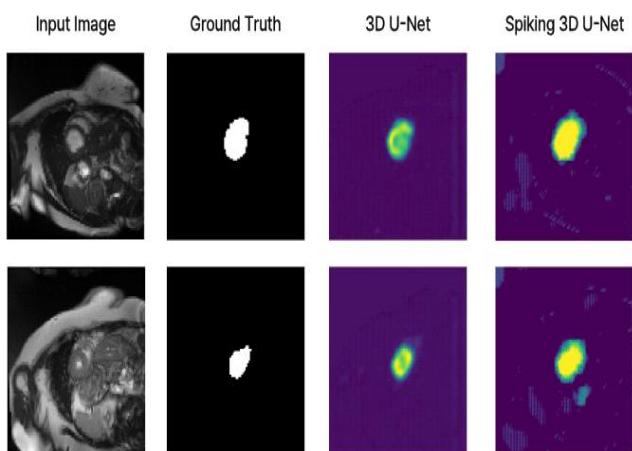
2. 관련 연구

3D U-Net은 2016년 MICCAI 학회에서 제안된 모델로, 기존 U-Net 구조를 3차원으로 확장하여 의료영상 분할에 적용한 것이다. 3D Convolution과 skip-connection을 활용해 공간적인 정보를 효과적으로 반영하며, weighted softmax loss를 사용하여

나머지 40개를 검증용으로 사용하였고, 테스트 데이터 100개에 대해 평균 IoU를 산출하였으며, 이 중 임의로 선택한 2개의 샘플에 대해서는 예측 결과를 시각화하고, 개별 IoU를 추가로 제시하였다.

3D U-Net의 DoubleConvBlock 내 활성화 함수를 SNN의 LIF(Leaky Integrate and Fire) 뉴런으로 대체하고, 이를 3D 의료영상의 분할에 적용하여 성능을 분석하였다. 두 모델은 동일한 데이터셋과 환경에서 비교 실험을 수행하였다. 실험 환경은 Ubuntu 22.04 LTS, Nvidia RTX 4090(24GB), Pytorch 2.6.0+cu124, snntorch 0.9.4 버전으로 구성하였다. 학습은 총 100 epoch 동안 수행되었고, 학습률을 $1e-4$ 로 설정하였다.

기존 3D U-Net 테스트 데이터 100개에 대해 평균 IoU가 0.7989로 측정되었고, 전력 사용량은 nvidia-smi를 통해 확인한 결과 평균 약 250W였다. 반면, Spiking 3D U-Net은 평균 0.5881로 상대적으로 낮았으며, 전력 사용량은 약 200W로 나타났다. 이는 약 20% 감소한 수치로, 이는 Spiking 뉴런의 희소한 발화 특성으로 인해 연산량이 줄어든 결과로 해석된다.



(그림 1) 3D U-Net과 Spiking 3D U-Net 예측 결과

그림 1은 테스트 데이터 중 임의로 선택한 2개의 샘플에 대한 예측 결과를 시각화한 것이며 각 모델의 IoU 점수는 표 1에 정리하였다.

<표 1> 모델별 IoU 점수

그림	3D U-Net	Spiking 3D U-Net
1번	0.8422	0.7228
2번	0.7836	0.5436

4. 결론

본 연구에서 3D U-Net의 활성화 함수(ReLU)를 SNN의 LIF 뉴런으로 대체하고, 임계치 기반 발화 메커니즘이 이미지 분할 성능에 미치는 영향을 분석하였다. 실험 결과, 분할 성능은 기존 모델보다 다소 낮았으며, 이는 Spiking 뉴런이 0 또는 1의 이산적인 값으로만 신호를 전달하기 때문에 세부적인 정보 표현이 어렵다는 점에서 기인한 것으로 보인다. 또한 Spiking 뉴런의 불연속적인 특성으로 인해 기존의 역전파 함수 적용이 어렵다는 구조적인 한계도 존재한다. 반면, 전력 효율 측면에서는 기존 3D U-Net보다 개선된 결과를 확인할 수 있었다. 이는 SNN이 뉴런의 발화를 최소화함으로써 불필요한 연산을 줄이는 구조적 특성에 기인한다.

본 연구에서는 200개의 데이터를 사용하여 학습을 진행하였으나, 데이터 규모가 제한적이어서 모델의 일반화 성능을 충분히 평가하기에는 어려움이 있었다. 따라서 향후 연구에서는 다양한 데이터 증강 기법을 활용해 학습 데이터를 확장하고, 모델의 안정성과 일반화 능력을 향상시키는 방향으로 추가 연구를 진행할 예정이다.

참고문헌

- [1] 공은정, 방창석, "인공지능을 이용한 의료영상 판독의 현재와 미래", 대한소화기학회지, 제82권, 제1호, pp.43-45, 2023.
- [2] Charles Edison Tripp, Jordan Perr-Sauer, et al., "Measuring the Energy Consumption and Efficiency of Deep Neural Networks: An Empirical Analysis and Design Recommendations", arXiv preprint, arXiv:2403.08151, 2024.
- [3] Ahmed Abdulkadir, Soeren S. Lienkamp, et al., "3D U-Net: Learning Dense Volumetric Segmentation from Sparse Annotation", MICCAI 2016, Athens, Greece, 2016, pp.424-432.
- [4] Amirhossein Tavanaei, Masoud Ghodrati, et al., "Deep Learning in Spiking Neural Networks", Neural Networks", Vol.111, pp.47-63, 2019.
- [5] O. Bernard, A. Lalande, C. Zotti, F. Cervenansky, et al., "Deep Learning Techniques for Automatic MRI Cardiac Multi-structures Segmentation and Diagnosis: Is the Problem Solved", IEEE Transactions on Medical Imaging, Vol.37, No.11, pp.2514-2525, 2018.