

휴식상태 EEG-to-MRI 크로스 모달리티 변환을 위한 스펙트로그램 기반 딥러닝 기법에 관한 예비 연구

이규석¹⁺, 마히마 아리아²⁺, 유원상^{1,*}

¹선문대학교 스마트정보통신공학과, 인공지능 영상처리 연구실

²Center for Computational Engineering and Networking, Amrita Vishwa Vidyapeetham, Coimbatore, India

A Feasibility Study on Spectrogram-based Deep Learning Approach to Resting State EEG-to-MRI Cross-Modality Transfer

Gyu-Seok Lee¹⁺, Arya Mahima²⁺, Wonsang You^{1,*}

¹Dept. of Information Communication Engineering, Sun Moon University, Korea

²Center for Computational Engineering and Networking, Amrita Vishwa Vidyapeetham, Coimbatore, India

*wyou@kaist.ac.kr (corresponding author) +contributed equally

요 약

뇌의 전기적 신경활동을 측정하는 뇌전도(EEG)는 저렴하게 취득할 수 있고 높은 시간 해상도를 갖는 반면 공간적 정보를 제공하지는 않는다. 기능적 자기공명영상(fMRI)은 혈류변화를 감지하여 뇌 활동을 측정하는 방식으로 높은 공간 분해능을 갖지만 고가의 비용과 설비를 요구한다. 최근 저렴하게 취득할 수 있는 EEG 데이터로부터 딥러닝을 사용하여 fMRI 합성영상을 생성하는 기술이 제안되었지만, 저주파수 대역에서 EEG와 fMRI 간의 뇌과학적 상관관계를 반영하지는 않는다. 본 연구에서는 휴식상태에서 취득된 EEG 데이터를 스펙트로그램으로 변환한 후 저주파수 특성을 사용하여 fMRI 합성영상을 생성하는 U-net 기반의 크로스 모달리티 변환 모델의 실현가능성을 평가하였다.

1. 서론

뇌전도(EEG)는 뇌의 신경 활동을 직접적으로 측정하여 높은 시간 해상도를 가지며 기능적 자기공명영상(fMRI)은 뇌의 활동 부위를 작은 단위까지 파악할 수 있는 장점이 있어 높은 공간 분해능을 가지고 있다. 단일 양식의 한계를 극복하기 위해 EEG와 MRI를 동시에 획득하여 분석한 연구가 진행되어 왔지만, 동시 측정에는 고가의 장비와 측정 비용이 발생한다[1].

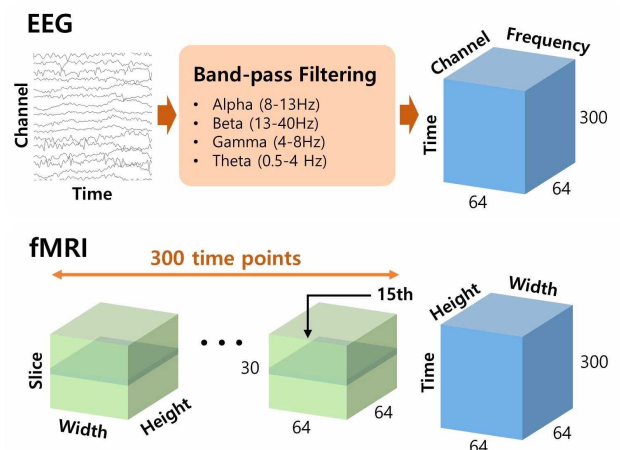
최근 저렴하게 취득할 수 있는 EEG 데이터로부터 딥러닝을 사용하여 fMRI 합성영상을 생성하는 기술이 제안되었다. Calhas et al.은 인코더-디코더 기반의 모델을 사용하였고[2], Cheng et al.은 생성적 적대 신경망(GAN)을 사용하였다[3]. 한편 휴식상태에서 취득된 EEG와 fMRI는 0.5~40Hz의 저주파수 대역(알파/베타/감마/세타)에서 밀접한 상관관계가 있다는 연구결과가 있지만[4], 기존 기술은 이러한 뇌과학적 상호연관성을 반영하지 않는다.

본 연구에서는 휴식상태에서 취득된 EEG 데이터로부터 fMRI 합성영상을 생성하는 크로스 모달리티 변환의 새로운 접근방법으로서 EEG 신호의 시간-주파수 특성을 사용하는 스펙트로그램(spectrogram) 기반의 딥러닝 접근방법을 제안하고, 제안된 방법의 실현가능성을 평가하였다. 본 연구의 독창성은 휴식상태 EEG와 fMRI 간의 뇌과학적 상관관계를 반영하기 위해 EEG 스펙트로그램의 저주파수 특성을 사용한 딥러닝 기법이라는 점에 있다.

2. 방법

2.1. 스펙트로그램 기반 데이터 전처리

모델의 학습 및 평가를 위한 데이터로서 총 16명의 환자를 대상으로 휴식상태에서 동시에 획득한 EEG와 fMRI 쌍으로 구성된 NODDI 데이터셋을 사용하였다. 휴식상태 데이터는 환자들이 활동이 없는 정지 상태일 때 측정된 것을 말하며 EEG는 1kHz의 기본 주파수에 64개의 채널 MR 호환 전극 캡을 사용하여 MRI 스캔 중에 기록되었다. fMRI 데이터는 300 볼륨, TR/TE=2,160/30ms, 두께 3.0 mm의 30개 슬라이스로 수집되었다[4].

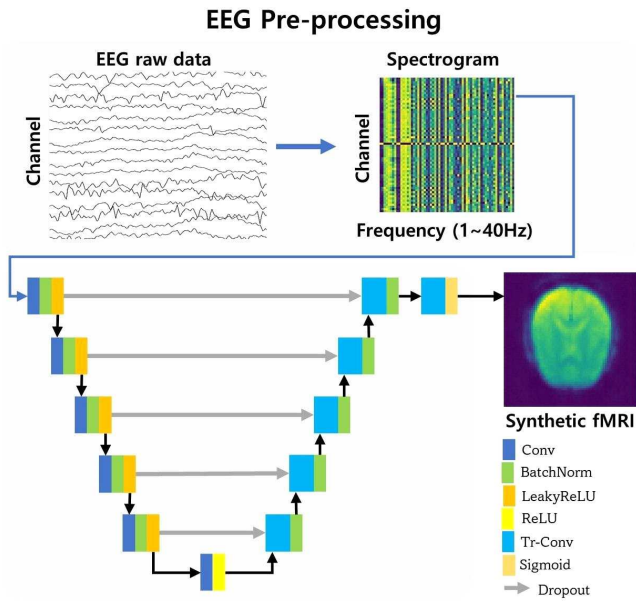


(그림 1) 데이터 전처리 과정

데이터 전처리는 그림 1에 표현하였다. fMRI는 15번째 슬라이스만을 사용하여 환자당 300 볼륨으로 총 4,800장 (=300x16명)의 이미지를 사용한다. EEG는 fMRI와 뇌과학적 상관관계가 있는 알파파(8-13Hz), 베타파(13-40 Hz), 감마파(4-8Hz) 세타파(0.5-4Hz)의 4개 주파수 대역으로 필터링되었고[4], 각 주파수 대역의 신호는 푸리에 변환을 사용하여 16개 주파수 특성을 가진 정규화(normalization)된 스펙트로그램으로 변환되었다. 전처리된 EEG 데이터는 300 시간 포인트, 64개 주파수 영역, 64개 채널로 구성되어, fMRI와 동일한 크기를 가진다.

2.2. U-net 기반 크로스 모달리티 변환

학습모델은 그림 2의 U-net 네트워크의 구조를 사용하였다[5]. EEG 전처리 과정을 통해 생성된 주파수-채널의 64x64 크기의 이미지를 모델의 입력으로 한다. 인코더 부분에는 이미지를 다운샘플링을 하여 압축하는 6개의 블록으로 구성되어 있고, 디코더 부분은 압축된 이미지를 업샘플링을 통해 확장하여 fMRI 이미지로 변환한다. 디코더는 잔차 연결을 통해 인코더 블록의 출력값에 드롭아웃을 0.5의 비율로 적용하여 디코더 블록의 출력에 이어붙인다.



(그림 2) EEG-fMRI 크로스 모달리티 변환을 위한 U-Net

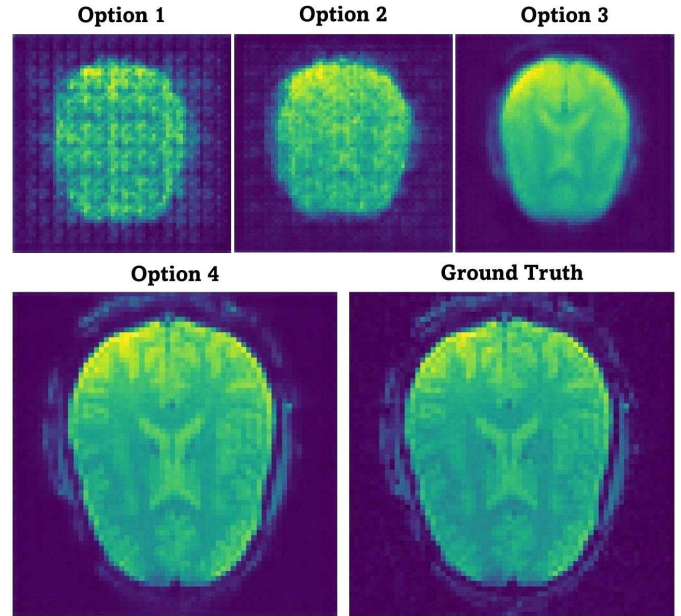
3. 실험 결과

데이터셋은 훈련, 검증, 테스트를 위해 6:2:2의 비율로 나누었다. 손실 함수로는 평균제곱오차(MSE), 평가지표로는 최대신호대잡음비(PSNR)와 구조적 유사도(SSIM) 지수를 사용하였다. 배치 사이즈는 64, 옵티마이저는 Adam, 학습율은 6×10^{-5} , 반복횟수(epochs)는 50으로 하였다.

정량적 실험결과가 표1에 요약되어 있다. 잔차연결의 드롭아웃을 디코더의 전체블록에 적용하는 경우(Whole)와 1~3번째 블록에만 적용한 경우(Partial)를 비교하였다. 또한 인코더의 활성화 함수로서 Leaky ReLU와 ReLU의 효과를 비교하였다. 그림3은 EEG를 fMRI로 변환한 결과와 실제 fMRI 영상을 비교하는 정성적 평가결과를 보여준다.

<표 1> 정량적 모델 성능 평가 결과

Option	Dropout	Activation	MSE ↓	PSNR ↑	SSIM ↑
1	Whole (p=0)	ReLU	0.012	19.2	0.41
2		LReLU	0.019	17.3	0.27
3	Partial (p=0.5)	ReLU	0.006	22.1	0.65
4		Norm+LReLU	0.001	28.4	0.92



(그림 3) EEG-fMRI 크로스 모달리티 변환 모델의 정성적 결과

4. 결론

본 연구에서는 휴식상태 EEG 데이터로부터 fMRI 합성 영상을 생성하는 크로스 모달리티 변환을 위한 스펙트로그램 기반 딥러닝 기법을 제안하고 이의 실현가능성을 평가하였다. U-net 모델을 사용하여 EEG로부터 fMRI 합성 영상 생성이 가능함을 실험을 통하여 확인하였다. 미세조정 실험을 통하여, 드롭아웃을 부분적으로 적용하고 인코더에 데이터 정규화 및 Leaky ReLU 활성화 함수를 적용함으로써 모델 성능을 최적화하였다.

그러나, 비교적 단순한 모델을 사용했기 때문에 성능은 받아들일만한 수준에 미치지 못하였고, 다른 기존 모델과의 성능 비교도 이루어지지 못하였다. 이러한 한계에도 불구하고, 본 연구는 EEG와 fMRI 간의 뇌과학적 상관관계를 스펙트로그램 특성에 반영하여 모델 학습에 반영하였다는 점에서 의의가 있다. 향후 전체 MRI 볼륨을 시간적으로 예측할 수 있도록 모델을 개량할 계획이다.

참고문헌

- [1] Mele G et al. "Simultaneous EEG-fMRI Functional Neurological Assessment", Front. Neurology, 1, 2019.
- [2] Calhas D, Henriques R, "EEG to fMRI Synthesis: Is Deep Learning a candidate?", arXiv:2009.14133, 2020.
- [3] Cheng D et al. "Research on the Modality Transfer Method of Brain Imaging Based on Generative Adversarial Network" Front. Neurosci. 15:655019, 2021.
- [4] Fail D et al. "Relating resting-state fMRI and EEG whole-brain connectomes across frequency bands", Front. Neurosci. 3, 2014.
- [5] Ronneberger O et al. "U-Net: Convolutional Networks for Biomedical Image Segmentation," MICCAI 2015.