

# 뇌-컴퓨터 인터페이스를 위한 딥러닝 기반 무릎 동작의 실제와 상상 동작 분류

이예지<sup>1</sup>, 허수진<sup>1</sup>, 이현주<sup>2</sup>, 태기식<sup>1\*</sup>

<sup>1</sup>건양대학교 의료공과대학 의공학부, <sup>2</sup>건양대학교 의과대학 물리치료학과

## Deep Learning Classification of EEG Signal between Real and Imagery of Knee Motion for Brain-Computer Interface

Yeji Lee<sup>1</sup>, Sujin Heo<sup>1</sup>, Hyunju Lee<sup>2</sup> and Kisik Tae<sup>1\*</sup>

<sup>1</sup>Department of Biomedical Engineering, Konyang University, Korea

<sup>2</sup>Department of Physical Therapy, Konyang University, Korea

\*tae@konyang.ac.kr

### Abstract

In general, non-invasive Brain-Computer Interface (BCI) uses neural activity information recorded through electroencephalogram (EEG). EEG have developed mainly into motor imagery (MI) with a low risk of contamination because they can be contaminated by various artifacts during the collection process. The purpose of this study was to find out which of the motor imagery and movement execution (ME) of knee is good classification performance. To this end, MI and ME data of four types of knee exercise were collected from 10 subjects. The data collected through deep learning were classified, and as a result, a study found that ME (98.90%) can be classified more accurately than MI (98.37%). These results are expected to be used for various controls such as mobility and robots through combination of MI and ME.

### 1. 연구 배경

뇌-컴퓨터 인터페이스(BCI: Brain-Computer Interface)는 사용자가 두뇌 활동을 통해 컴퓨터 또는 기타 외부 장치와 직접 상호작용할 수 있도록 하는 기술이다. 일반적으로 비침습적인 BCI는 휴대성과 저렴한 비용 및 높은 시간 분해능 등의 이유로 인해 주로 뇌파(electroencephalogram: EEG)를 통해 기록한 신경 활동 정보를 사용한다[1]. EEG는 뇌 활동을 모니터링하기 때문에 EEG를 사용하면 정신 상태, 감정 상태 및 동작 의도에 대한 추론을 가능하게 할 수 있다[2].

하지만 하드웨어의 한계로 인해 보다 큰 동작을 측정해야 하고 그 과정에서 동잡음(motion artifact)에 의해 오염될 수 있는 운동 실행(Movement Execution: ME)보다는 고정된 자세로 눈을 감고 실험할 수 있는 동작 상상(Motor Imagery: MI)이 BCI 연구에서 선호되었다. 하지만 MI는 실험과정에서 정확하게 제어하기 어렵기 때문에 정확한 데이터를 얻기 어렵다는 단점이 있다. 또한 최근 하드웨어 기술의 발달로 ME의 데이터 수집 과정에서 유발되는 잡음의 양이 감소했고, 다양한 인공물 제거 방법을 사용하여 잡음을 제거할 수 있게 됐다[3]. 따라서 최근 ME에 대한 연구도 활발히 진행되고 있는 추세이다.

대뇌 피질 호문쿨루스에 따르면 대뇌 일차 운동 피질에서 하지(lower limb) 움직임을 담당하는 영역이 상지(upper limb)에 비해 작고 매우 밀접하게 배열되어 있다. 때문에 유의미한 동작 분류에 어려움이 있어 상지에 비해 하지 운동의 동작 분류는 활발히 다루어지지 않았다[4]. 또한 대다수의 하지 동작 분류 연구는 MI를 다루거나, ME를 다루더라도 신체 일부를 고정한 채 운동을 진행하여 데이터를 수집했다[5, 6].

따라서 본 연구에서는 하지 중에서도 대뇌 일차 운동 피질에서 아주 좁은 영역을 담당하는 무릎의 MI와 ME의 동작을 딥러닝 모델을 통해 분류하고, 두 과제의 정확도를 비교하여 BCI에 활용 가능성을 검증하고 자 하였다.

### 2. 연구 방법

EEG(Q20r, CGX Ltd., USA) 기기를 사용하여 19채널(F<sub>7</sub>, Fp<sub>1</sub>, Fp<sub>2</sub>, F<sub>8</sub>, F<sub>3</sub>, F<sub>z</sub>, C<sub>3</sub>, C<sub>z</sub>, P<sub>8</sub>, P<sub>7</sub>, P<sub>z</sub>, P<sub>4</sub>, T<sub>3</sub>, P<sub>3</sub>, O<sub>1</sub>, O<sub>2</sub>, C<sub>4</sub>, T<sub>4</sub>)로 기록되었고, 일반적인 긴장상태에서 유효한 변화를 보이는 알파대역(8Hz-13Hz)에서의 데이터를 사용했다. EEG는 500Hz로 샘플링 되었다. 뇌파 수집 과정에서 피험자마다 집중도의 차이가 존재하기 때문에 이로 인한 오류를 해결하기 위해 이번 연구에서는 사전에 뇌파 측정값이 평균에서 크게 벗어나는 outlier의 제거를 진행하였다.

본 실험에서 사용된 MI와 ME 데이터는 건강한 20대 남녀 10명에게서 수집되었으며 오른 무릎, 왼 무릎, 양 무릎을 펴고 접은 채 5초 동안 유지하는 상태를 각각 20회씩 상상하고, 실제로 운동하도록 변칙적인 순서의 시각자극을 통해 지시하였다.



그림 1. 본 연구를 위한 실험 모습

이를 통해 수집한 그림 2와 같은 3차원 형식의 데이터를 HAR (Human Activity Recognition) 에 적합하도록 그림 3과 같이 2차원 형태로 펼쳐 Sliding Window Algorithm을 통해 다시 3차원으로 변환하여 사용하였다.




그림 2. 획득한 Data 형태

이를 통해 피험자 한 명 당 무릎 MI와 ME 데이터를 각각 1,200장씩 생성하였다. 그 후 Standard Scaler을 사용하여 적합한 범위와 형식으로 Data Scaling 과정을 거치고, 신호의 잡음 제거와 특징 추출을 목적으로 DWT (Discrete Wavelet Transform) 을 진행하였다.

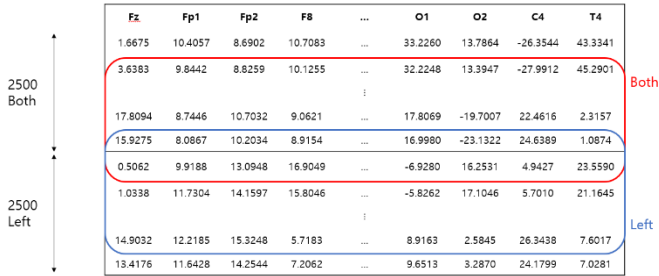


그림 3. Sliding Window Algorithm을 이용한 데이터 변환

본 연구의 인공지능 신경망 모델은 이미지 인식 및 분류에 최적화된 신경망 네트워크인 CNN 모델을 기초로 Lenet-5 모델을 표 1 과 같이 간략하게 변형하여 구성하였다. 데이터 크기로 인해 3x3 Filter를 학습 매개변수로 사용하는 3개의 Convolution(Conv)과 최소한의 크기로 구성된 Pooling(Pool)을 사용해 연산을 수행하며 출력계층에서 classification을 위해 Softmax 함수를 사용했다. 학습 속도를 빠르게 하고 모델의 성능을 높이기 위해 Batch Normalization을 사용했으며 Flatten 이전 단계에 과적합(overfitting)을 방지하기 위해 Dropout 층을 배치하여 모델을 구성하였다.

표 1. 딥러닝 모델 학습에 사용된 모델 구조

Model
Conv 32@3x3
Pool 2x2
Batch Normalization
Conv 64@3x3
Pool 2x2
Batch Normalization
Conv 128@3x3
Batch Normalization
Dropout 0.25
Flatten
Dense 100
Dense 4

실험의 결과는 3,000회 반복 학습시킨 결과에 대한 정확도를 10회 반복 학습하여 평균 결과를 도출하여 구해졌다. 실험 결과는 SPSS 12.0 (IBM Ltd, USA)를 이용하여 독립표본 T-test를 통해 시행하였으며 통계적 유의 수준은  $p < .05$ 로 정의되었다.

### 3. 연구 결과 및 결론

Train 데이터 셋과 Test 데이터 셋은 각각 전체 데이터의 80%, 20%로 구성하였다. Train 데이터 셋 중 20%는 Validation 데이터 셋으로 사용하였다. 실험 결과 표 2 와 같이 MI의 경우 98.37%, ME의 경우 98.90%의 평균 분류 정확도를 보여 주었으며 MI와 ME는 통계적으로 유의한 차이를 보였다( $p < .05$ ).

표 2. MI와 ME의 학습 결과

Data	Model	Accuracy	p-value
MI	CNN	98.37%	0.0001
ME		98.90%	

결론적으로 본 연구의 결과는 무릎 운동의 상상과 실행을 같은 환경에서 진행했을 때 수집되는 EEG가 MI보다 ME에서 더 정확히 분류될 수 있음을 시사한다. 이러한 연구 결과를 바탕으로 추후 다른 신체 움직임에 대한 연구가 동반된다면 ME 데이터를 BCI에 적용하여 보다 정확도 높은 BCI 기술의 발전이 가능할 것이라고 기대된다. 이를 통해 모빌리티, 로봇 등 다양한 제어분야에 활용할 수 있을 것으로 사료된다.

### 4. Acknowledgements

본 과제(결과물)는 2021년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신 사업의 결과입니다.(2021RIS-004)

### 5. 참고 문헌

- [1] Zou, Y., Zhao, X., Chu, Y., Zhao, Y., Xu, W. and Han, J., "An inter-subject model to reduce the calibration time for motion imagination-based brain-computer interface." *Med Biol Eng Comput*, Vol. 57, p939-952, 2019
- [2] P. Szczuko, "Rough set-based classification of EEG signals related to real and imagery motion." *2016 Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, p.34-39, 2016
- [3] C. Y. Sai, N. Mokhtar, H. Arof, P. Cumming and M. Iwahashi, "Automated Classification and Removal of EEG Artifacts With SVM and Wavelet-ICA." *in IEEE Journal of Biomedical and Health Informatics*, Vol. 22, No. 3, p.664-670, 2018
- [4] Robert M. Hardwick, Svenja Caspers, Simon B. Eickhoff and Stephan P. Swinnen, "Neural correlates of action: Comparing meta-analyses of imagery, observation, and execution." *Neuroscience & Biobehavioral Reviews*, Vol. 94, p.31-44, 2018
- [5] D. Liu., W. Chen., K. Lee., R. Chavarriaga., F. Iwane. And M. Bouri., "EEG-Based Lower-Limb Movement Onset Decoding: Continuous Classification and Asynchronous Detection." *in IEEE Transactions on Neural Systems and Rehabilitation Engineering*, Vol. 26, No. 8, p.1626-1635, 2018
- [6] Neha Hooda, Ratan Das and Neelesh Kumar, "Fusion of EEG and EMG signals for classification of unilateral foot movements." *Biomedical Signal Processing and Control*, Vol. 60, 2020