

심층 신경망을 이용한 인간의 특정 행동에 따른 EEG 분석

강병준¹, 조현찬^{2*}

¹한국폴리텍대학 서울정수캠퍼스 인공지능소프트웨어과, ²한국기술교육대학교 전기전자통신공학부

Brainwaves(EEG) Analysis for Specific Human Behavior using Deep Neural Networks

Byung Jun Kang¹, Hyun Chan Cho^{2*}

¹Department of Artificial Intelligence and Software, Seoul Jungsu Campus of Korea Polytechnics

²Department of Electrical, Electronics and Communication Engineering,
Korea University of Technology and Education

요약 뇌-컴퓨터 인터페이스(Brain Computer Interface, BCI)를 활용하여 인간의 의도에 따른 뇌 신호를 분석하여 시스템을 제어하는 연구는 대표적으로 뇌의 운동 피질 중 가장 넓은 활성 영역을 차지하는 손의 동작을 대상으로 연구되고 있다. 본 논문에서는 오른팔을 올리거나 내릴 때 발생하는 뇌 신호를 심층 신경망을 이용하여 분류하기 위한 데이터 수집 및 전처리 방법, 근전도 신호를 활용한 심층 신경망의 학습 방법을 제안하였다. 데이터 수집 시 뇌 신호가 근육으로 전달되는 시간은 충분히 빠르고 지연 시간이 없다고 가정하였고, 훈련데이터로 사용될 뇌 신호와 실제 의도와 의 오차를 줄이기 위하여 근전도 신호 기반의 뇌 신호 라벨링 기법을 사용하였다. 그리고 EMG 신호 측정이 가능한 대상의 EEG 신호와 EMG 신호를 활용하여 EMG 신호를 손실 함수의 가중치로 적용하는 학습 방법을 제안하여 움직임에 의한 잡음이 학습에 반영하는 것을 억제하고, 움직이려는 의지가 약한 구간에 대하여 안정적인 학습을 유도하였다. 또한 후천적으로 근전도 신호를 측정할 수 없는 대상에 대하여 EEG 신호만을 활용할 가능성을 확인하였다. EMG 신호를 가중치로 사용했을 시의 성능을 비교하기 위하여 동일한 심층 신경망의 성능을 Binary cross-entropy 손실 함수 사용 시의 성능과 비교하였다.

Abstract The study of system control by EEG according to human will using a brain computer interface (BCI) is focusing on the motion of the hand, which occupies the widest active area of the brain. In this paper, a data collection method, a preprocessing method, and a deep neural network learning method using EMG signals are proposed for classifying EEG signals generated when the right arm is raised or lowered. It was assumed that there is no delay in the transmission of brain signals to the muscles during data collection, and an EMG-based EEG labeling technique was used to reduce the error between actual intentions and EEG. Additionally, a training method that utilizes both EEG signals and EMG signals from subjects capable of measuring EMG signals is proposed. This method applies EMG signals as weights in the loss function to suppress the influence of noise caused by movement in the learning process and promotes stable learning in segments where the intention to move is weak. We confirmed the possibility of using only EEG signals for subjects for whom measuring EMG signals retrospectively is not possible. The performance of the proposed method using EMG weights was compared to the performance of the same deep neural network using a binary cross-entropy loss function.

Keywords : EEG, EMG, Deep Neural Networks, Loss Function, Motion Classification

이 논문은 2022학년도 한국기술교육대학교 교수 교수교육연구진흥과제 연구비 지원에 의하여 연구되었음.

*Corresponding Author : Hyun Chan Cho(Korea University of Technology and Education)

email: cholab@koreatech.ac.kr

Received July 21, 2023

Revised August 31, 2023

Accepted October 6, 2023

Published October 31, 2023

1. 서론

뇌전도(Electroencephalography, EEG), 근전도(Electromyography, EMG), 심전도(Electrocardiogram, ECG) 등 생체신호를 이용한 연구는 신경정신의학 분야에서 질환을 예측하거나, 신경인지과정 등의 의학분야로써 환자의 상태에 대해 예측, 분석, 진단의 영역으로 연구되어 왔다. 최근에는 머신러닝 기법을 활용한 뇌졸중 예후 분석[1], 수면 단계 예측[2] 등의 연구가 진행되고 있다. 뇌-컴퓨터 인터페이스(Brain Computer Interface, BCI)를 이용하여 인간의 의도에 따른 EEG 신호를 분석하여 시스템을 제어하는 연구는 대표적으로 뇌의 운동 영역 중 가장 넓은 활성 영역을 차지하는 손의 동작을 대상으로 연구되고 있다. 손의 동작 분석은 뇌전도 측정장치를 이용하여 수집한 EEG의 신호를 주파수 영역으로 변환하였을 때 손동작을 분류하는 중요한 특징이 존재함이 밝혀졌다[3,4]. 비슷한 분야로 MI-Task(Motor-Imaginary Task)에 대한 연구는 실제 움직임이 아닌 뇌가 몸의 움직임을 상상할 때 발생하는 EEG 신호를 이용하여 의도를 파악하는 연구가 진행되었다[5]. 심층 신경망을 이용한 MI-Task 연구에서 CNN[6]과 CNN-SAE(Stacked Auto Encoder)[7]를 이용한 동작상상 분류기의 성능은 평균 88%, 78.6%의 연구성과를 보였다.

MI-Task 기반의 BCI는 상상을 통해 통신하거나 제어할 수 있다는 장점이 있다. 그러나 어떤 뇌 신호가 몸을 움직이는 신호인지는 아직 명확하게 밝혀지지 않았다. 이것을 밝히기 위하여 가상의 움직임과 실제 움직임을 비교한 연구가[8] 시도되었다. EEG 신호와 EMG 신호를 사용하여 손가락, 팔, 어깨 움직임을 추적하는 연구[9,10]는 뇌와 신체 움직임을 추적할 수 있었지만 EEG 신호와 EMG 신호를 함께 사용하기 때문에 피험자(근육 부족, 절단)의 EMG 신호를 시스템에 적용하기 어렵다. BCI 관련 연구에서 공통적인 실험적 방법이 이벤트(비프음)가 발생할 때 몸을 움직이거나 행동을 상상하는 것이다[11-13]. 이러한 실험적 방법은 의도의 분류를 이벤트의 고정된 시간을 기준으로 하기 때문에 실제 의도와 일치하지 않는 오차를 포함할 수 있다.

본 논문에서는 오른팔을 올리거나 내릴 때 발생하는 EEG 신호를 심층 신경망을 이용하여 분류하기 위한 데이터 수집 방법과 전처리, 심층 신경망의 학습 시 EMG 신호의 활용 방법을 제안하였다. 데이터 수집 시 뇌 신호가 근육으로 전달되는 시간이 충분히 빠르고 지연 시간이 없다고 가정하였고, 훈련데이터로 사용될 EEG 데이

터와 실제 의도와와의 오차를 줄이기 위하여 EMG 신호 기반의 EEG 신호의 라벨링 기법을 사용하였다. 또한 EMG 신호 측정이 가능한 대상의 EEG 신호와 EMG 신호를 활용하여 손실 함수에 EMG 신호를 가중치로 적용하는 학습 방법을 제안하여 후천적으로 근전도 신호를 측정할 수 없는 대상에 대하여 EEG 신호만을 활용할 가능성을 확인하였다. EMG 신호를 가중치로 사용했을 시의 성능을 비교하기 위하여 동일한 심층 신경망의 성능을 Binary cross-entropy 손실 함수 사용 시의 성능과 비교하였다.

본 논문의 2장에서는 뇌 신호 수집 시 사용한 장비와 전극 위치 그리고 데이터 수집 절차를 기술하였다. 3장에서는 2장에서 수집한 신호를 이용하여 EMG 신호를 기반으로 EEG 신호를 라벨링 하여 오차를 줄이는 방법과 학습 데이터 구조에 관하여 기술하였다. 4장에서는 EMG 신호의 특성을 손실 함수에 적용하여 학습하는 방법을 제안하여 5장에서는 동일한 심층 신경망 구조에서 제안하는 손실 함수를 사용했을 경우의 성능을 비교하였다. 6장에서는 실험 결과에 대한 분석과 향후 연구에 관하여 기술하였다.

2. 뇌전도 및 근전도 데이터 수집 조건 및 환경

팔을 올리거나 내릴 때 의도가 포함된 EEG 신호와 EMG 신호를 수집하기 위하여 Laxtha의 QEEG-32FX 장비를 사용하였으며, EEG 신호와 EMG 신호는 동일 장비에서 동기화하여 수집하였다.

움직임을 상상하거나 실제 움직일 때 μ 파(3-13Hz) 또는 β 파(13-30Hz) 또는 50Hz 이상에서 변화를 보인 연구[14]를 바탕으로 샘플링 속도 1kHz로 충분히 샘플링 가능한 속도를 수집하며 하드웨어 대역통과 필터로 0.5-200Hz를 적용하였다. 또한 전원의 노이즈를 차단하기 위해 60Hz 노치 필터를 적용하여 수집하였다.

뇌 활동에 의해 생성되는 전기 신호인 EEG 신호를 수집하기 위해 두피에 비침습적으로 전극을 부착하였다. F3, F4, C3, C4, P3, P4, T3, T4 영역에 배치된 전극에서 8채널의 EEG 신호를 수집하였다. C3, C4 영역은 운동 영역을 담당하는 영역으로써 좌우 주먹을 이용한 운동 실험에서 ERD(Event-related desynchronization)와 ERS(Event-related synchronization) 현상[15,16]을 보여 Fig. 1과 같이 운동영역의 EEG 신호를 측정하고자 하였다. 또한 1채널의 오른팔 이두박근의 EMG 신호를 수집하였다.




Fig. 1. Electrode attachment location for EEG and EMG.

실험 대상은 오른팔의 움직임에 불편함이 없는 남성이며 팔을 들어 올리려는 의도가 충분히 전달되도록 오른팔에 1kg의 덤벨을 들고 의자에 앉아 비프음에 따라 오른팔을 반복적으로 올리거나 내리도록 하였다.

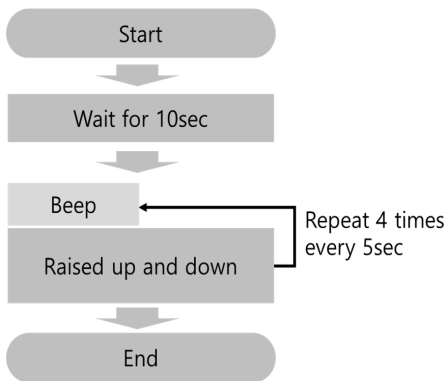




Fig. 2. Acquisition procedure for experimental data.

Fig. 2는 EEG 신호 및 EMG 신호에 대한 획득 절차로써 데이터 수집 시 위의 과정을 20회 반복하여 수집하였다.

Fig. 3은 위의 실험 방법에 따라 수집된 EEG 신호 및 EMG 신호를 나타낸다. Fig. 3-(a)에서 EMG 신호로써 10초간 휴식 후 근력이 일정한 간격으로 4번 변화하는 것을 확인할 수 있다. EMG 신호는 시간 축에서 의도를 구분할 수 있을 만큼 변화를 확인할 수 있지만, 동 시간의 Fig. 3-(b)의 EEG 신호에 대해서는 어떤 변화가 발생했는지 시각적으로 구분하기 힘들다. 따라서 EMG 신호를 이용하여 EEG 신호의 오른팔이 움직인 시간을 확인할 수 있다.



(a)



(b)

Fig. 3. Raw data of EMG and EEG.

(a) Raw Data of EMG; (b) Raw Data of EEG.

3. 수집된 데이터의 전처리

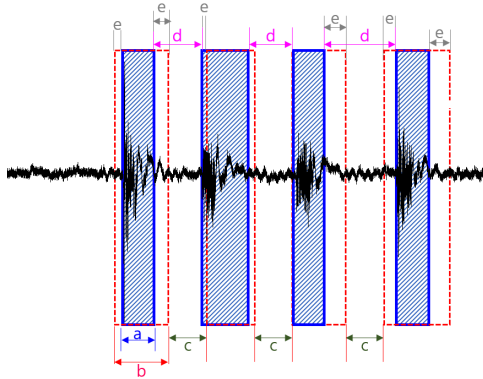
이벤트 기반 분류[17] 방법은 Fig. 4의 'b'와 'c'를 고정된 시간 간격으로 'b'는 팔을 움직이려는 의도가 있는 구간, 'c'를 팔을 움직일 의도가 없는 구간으로 분류한다.

실험 차수별 피실험자의 팔을 올리고 내리는 시간이 다르므로 Fig. 4의 'e'의 오차가 발생할 수 있다. 실시간 분류기의 성능을 향상하기 위해서는 'e'의 오차를 줄이고 팔을 올리는 의도가 있는 구간 'a'와 의도가 없는 구간 'd'로 분류하기 위한 EEG 신호와 EMG 신호의 전처리가 필요하다.

EMG 신호는 사람이 팔을 움직이고자 하는 의도의 결과물로 근육의 수축에 따라서 진폭이 크게 변하는 특성이 있다. 그리고 동 시간대에 팔이 실제로 움직이려는 의도가 EEG 신호에 포함되어 있다고 가정할 수 있다. EMG 신호는 EEG 신호를 입력으로 하는 심층 신경망 학습의 정답지로서 팔의 움직임 상태에 대하여 이전 연구의 라벨링 알고리즘[18]을 적용하였다.

Fig. 5-(a)는 EEG 신호에 대하여 시간 영역에서의 데이터 전처리를, Fig. 5-(b)는 주파수 영역에서 전처리를 나타낸다. EEG 원시 데이터에 대하여 512개 샘플의 윈도우를 적용하고, 시간 영역의 전처리는 윈도우 내 각 채널의 변화량($\Delta y_n = y_n - y_{n-1}$)을 평균으로 나누고 512

개 중 256개의 샘플을 시간 영역의 데이터를 얻는다. 동일 윈도우에 대하여 STFT를 적용한 256개 샘플을 주파수 영역의 입력데이터로 활용한다. 전처리를 마친 데이터는 심층 신경망의 훈련 및 평가데이터로 활용된다.



- a: The section with intention to move in proposed method
- b: The section with intention to move the arm in event-based method
- c: The section with no intention to move the arm in event-based method
- d: The section with no intention to move in proposed method
- e: The error with arm movements and rest

Fig. 4. Error in actual movement from previous research.

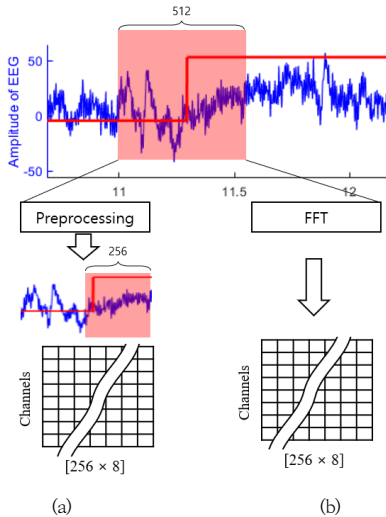


Fig. 5. Processed EEG data format.
(a) is preprocessing for time domain,
(b) is preprocessing for frequency domain.

4. 심층 신경망을 이용한 분류

4.1 심층 신경망의 구조

EEG 신호는 주파수, 주기 및 진폭에서 특정 행동에 대한 특성을 나타낼 수 있다. 전처리를 통해 얻은 샘플을 Fig. 6과 같이 시간 및 주파수 데이터에 대하여 변형하여 행의 개수를 증가하는 과정을 거친다. 이 입력 형식은 세로 및 가로 방향으로 컨볼루션의 연산 수를 증가시켜 다양한 방향의 특징을 추출할 수 있다.

수정된 주파수 및 시간 데이터 형식을 Fig. 7과 같이 네트워크를 구성하고 컨볼루션 연산을 통해 시간과 주파수 그리고 채널 간 특징점을 추출한 후 LSTM(Long Short-Term Memory) 및 Fully-Connected 레이어를 사용하여 특징점에 대한 팔을 올리는 작업 여부를 구분하기 위해 네트워크를 구성하였다.




Fig. 6. Input form of Networks.

(a) represents a process of modifying the input form of time-domain; (b) represents a process of modifying the input form of frequency-domain; (c) represents the combined form of (a) and (b).




Fig. 7. Deep Neural Networks Structure.

4.2 심층 신경망의 학습 방법

Eq. (1)은 이두박근 수축력의 크기와 팔을 움직이는 EEG 신호의 특성이 관련되어 있다는 가정을 적용하여 심층 신경망의 손실 함수로 적용한다. 팔을 올리고 내리는 분류에 대한 EMG 신호의 정보를 Binary cross-entropy [19]에 추가하여 분류의 정확도를 높이고자 하였다. y 는 EMG 신호를 통해 얻은 라벨로써 1은 팔을 올리려는 의도를 나타내고 0은 팔을 내리려는 의도를 나타낸다.

$$L = -y(1 - \lambda E^2) \log(\hat{y}) - (1 - y) \log(1 - \hat{y}) \quad (1)$$

Where, L denotes loss, E denotes amplitude of EMG, y denotes ground truth, \hat{y} denotes predict result.

\hat{y} 는 심층 신경망의 출력값으로 모델의 예측값이 0~1의 값을 갖는다. EEG 신호의 수축 의도는 이두박근의 수축력에 비례한다고 가정하였다. 의도가 강한 EEG 신호는 편향된 학습 결과를 보일 수 있다. y 가 0인 팔을 올릴 의도가 없는 경우 EMG 신호와 상관없이 손실 값을 학습하고, y 가 1인 팔을 들어 올리려는 의도가 있는 경우 EMG 신호의 크기에 따라 $(1 - \lambda E^2)$ 의 가중치를 적용한 손실을 학습한다.

5. 실험 결과

Table 1은 제안한 방법과 Binary cross-entropy의 총 20회의 실험데이터 중 3개의 검증 데이터에 대한 정확도 비교를 나타낸다.

Test Set2와 Test Set3에서 팔을 올린 상태의 정확도가 향상되었으며, 이는 제안된 손실 함수의 EMG 항이 작용했음을 유추할 수 있다.

Table 1. Compare the accuracy of the proposed loss function and the binary cross-entropy(%).

Loss Function	State	Set1	Set2	Set3
Proposed Loss Function	Raised	49.5	28.7	42.6
	Rest	69.8	89.1	88.2
	Total	61.6	64.8	70.2
Binary Cross-Entropy	Raised	55.9	26.2	33.6
	Rest	63.7	88.9	86.4
	Total	60.5	63.7	65.6

Fig. 8-(a)는 26초에서 30초까지의 Test Set1의 라벨을 나타내며, Fig. 8-(b)는 제안한 손실 함수를 사용한 결과이고, Fig. 8-(c)는 Binary cross-entropy를 사용한 결과이다. Fig. 10에서 28.5초 후의 결과를 비교하면 제안하는 손실 함수를 적용하였을 때 Binary cross-entropy를 적용한 경우보다 오검출이 더 억제됨을 알 수 있다.

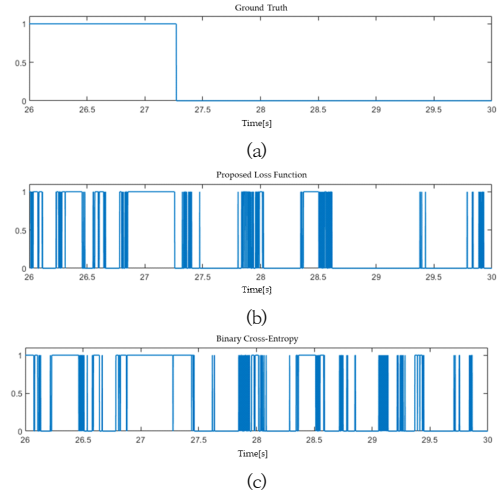


Fig. 8. Comparison of output by loss functions.

제안된 손실 함수는 기존의 Binary cross-entropy를 사용할 때보다 학습 반복 횟수가 더 필요했지만, 조금 더 높은 정확도를 확인할 수 있었다.




Fig. 9. History of Test Accuracy during Training for each Epoch.

Fig. 9에서 보는 바와 같이 Binary cross-entropy를 적용한 모델의 경우 560회차에서 Test Set의 평균 최댓값을 얻었고, 제안된 손실 함수를 적용한 모델의 경우 1,160회차에서 평균 최댓값을 얻을 수 있었다. Fig. 9의 학습 곡선에서는 Binary cross-entropy에서 560회차 이후에 정확도가 감소하고 제안된 손실 함수의 경우 1,160회차 이후에 정확도가 감소하는 경향을 보였다.

정확도에 의한 분석 외 Threshold 변화에 의한 분석으로 AUROC(the Area Under a Receiver Operating Characteristic Curve)[20]를 이용하면 Table 2와 같이 나타낼 수 있다. ROC는 Positive True Rate와 False Positive Rate에 대한 곡선으로써 왼쪽 상단이 급격한 볼록한 곡선의 형태를 할수록, 그래프의 아래 면적이 1에 가까울수록 좋은 성능이라고 할 수 있다.

Table 2. Compare the AUROC of the proposed loss function and the binary cross-entropy.

Loss Function	Set1	Set2	Set3
Proposed Loss Function	0.6126	0.5905	0.6252
Binary Cross-Entropy	0.6160	0.5843	0.6323

Fig. 10의 경우 낮은 False Positive Rate에서 True Positive Rate의 값은 제안하는 손실 함수를 사용한 모델이 Binary Cross-entropy를 적용한 모델보다 다소 높은 것을 확인할 수 있다.

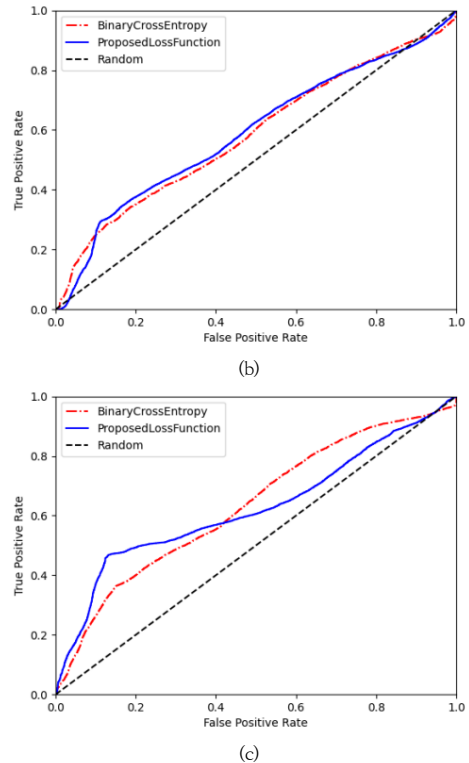
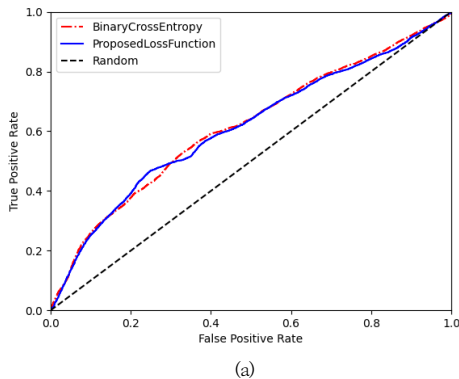


Fig. 10. Compare the ROC curve of the proposed loss function and the binary cross-entropy. (a) represents a curve of test set1, (b) represents a curve of test set2, (c) represents a curve of test set3.

6. 결론 및 향후 연구

본 논문의 실험은 시간과 주파수 범위에 대한 입력 형식을 변경하고 손실 함수에 가중치를 반영하여 정확도를 향상하고자 하였다. 손실 함수에 가중치를 부여하는 방식은 객체 탐지 및 이미지 분류 문제에서 클래스 불균형 문제를 해결하거나 어려운 샘플에 대하여 학습을 안정화 [21]하기 위하여 고정된 상수값을 사용한다. 본 논문의 실험에서는 팔의 움직임에 따라 변화하는 가중치를 적용하여, 움직임에 의한 잡음이 학습에 반영되는 것을 억제하며, 움직이려는 의지가 약한 구간인 EMG 신호의 크기가 작거나 관성에 의해 움직이는 구간에 대하여 안정적인 학습을 위해 움직임에 따른 가중치를 적용하였다.

실험 결과는 실시간 팔 움직임을 동일한 심층 신경망 구조와 초깃값이 같은 하이퍼파라미터에서 서로 다른 손실 함수로 분류했다. 또한 동작 의도의 결과인 EMG 신호를 손실 함수에 반영하였을 때 조금 더 좋은 결과를 얻

을 수 있었다. 제안한 모델의 정확도가 평균 65%인 점과 AUROC의 면적이 0.7이상 되지 않는 것으로 판단했을 때 모델의 절대적인 성능은 좋지 않으나, EMG 신호값을 손실 함수에 적용했을 때 성능향상을 유추해 볼 수 있었다. 향후 더 나은 정확도를 위해 네트워크 구조와 입력의 형태를 개선하여 안정된 성능의 모델에서 제안하는 손실 함수의 방법을 비교하면 본 논문에서 비교한 향상된 성능 결과보다 유의미한 결과를 얻을 수 있을 것으로 생각 된다.

References

- [1] Iqram Hussain, Se-Jin Park, "Prediction of Myoelectric Biomarkers in Post-Stroke Gait", *Sensors*, 21(16), 5334, 2021.
DOI: <https://doi.org/10.3390/s21165334>
- [2] Iqram Hussain, Md Azam Hossain, Rafasan Jany, MD Abdul Bari, Musfik Uddin, Abu Raihan Mostafa Kamal, Yunseo Ku and Jik-Soo Kim, "Quantitative Evaluation of EEG-Biomarkers for Prediction of Sleep Stages", *Sensors*, 22(8), 3079, 2022.
DOI: <https://doi.org/10.3390/s22083079>
- [3] G. Roy, A.K. Bhoi and S. Bhaumik, "A Comparative Approach for MI-Based EEG Signals Classification Using Energy, Power and Entropy", *IRBM*, 43(5), 2022.
DOI: <https://doi.org/10.1016/i.irbm.2021.02.008>
- [4] Said Abenna, Mohammed Nahid, Hamid Bouyghf and Brahim Ouacha, "An enhanced motor imagery EEG signals prediction system in real-time based on delta rhythm", *Biomedical Signal Processing and Control*, 79(2), 2023.
DOI: <https://doi.org/10.1016/i.bspc.2022.104210>
- [5] Padfield, N., Zabalza, J., Zhao, H., Masero, V. and Ren, J. "EEG-Based Brain-Computer Interfaces Using Motor-Imagery: Techniques and Challenges". *Sensors* 19, 1423, 2019.
DOI: <https://doi.org/10.3390/s19061423>
- [6] Wang, Z., Cao, L., Zhang, Z., Gong, X., Sun, Y. and Wang, H. "Short time Fourier transformation and deep neural networks for motor imagery brain computer interface recognition", *Concurrency and Computation: Practice and Experience*, 47, 2018.
DOI: <https://doi.org/10.1002/cpe.4413>
- [7] Yousef Rezaei Tabar, Ugur Halici, "A novel deep learning approach for classification of EEG motor imagery signals". *Journal of neural engineering*, 14, 1, 016003, 2016.
DOI: <https://doi.org/10.1088/1741-2560/14/1/016003>
- [8] Piotr Szczuko, "Rough set-based classification of EEG signals related to real and imagery motion", *Signal Processing: Algorithms, Architectures, Arrangements, and Applications (SPA)*, pp. 34-39, 2016.
DOI: <https://doi.org/10.1109/SPA.2016.7763583>
- [9] K. Bakshi, R. Pramanik, M. Manjunatha and C. S. Kumar, "Upper Limb Prosthesis Control: A Hybrid EEG-EMG Scheme for Motion Estimation in Transhumeral Subjects", *2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, pp. 2024-2027, 2018.
DOI: <https://doi.org/10.1109/EMBC.2018.8512678>
- [10] Fernandez-Vargas, J., Kita, K. and Yu, W. "Real-time hand motion reconstruction system for trans-humeral amputees using EEG and EMG", *Frontiers in Robotics and AI*, 3, 50, 2016.
DOI: <https://doi.org/10.3389/frobt.2016.00050>
- [11] Eun, H. J, "Basics of electroencephalography for neuropsychiatrist", *Journal of Korean Neuropsychiatric Association*, 58(2), pp. 76-104, 2019.
DOI: <https://doi.org/10.4306/jknpa.2019.58.2.76>
- [12] Neuper, C., Wörtz, M. and Pfurtscheller, G., "ERD/ERS patterns reflecting sensorimotor activation and deactivation", *Progress in brain research*, 159, pp. 211-222, 2006.
DOI: [https://doi.org/10.1016/S0079-6123\(06\)59014-4](https://doi.org/10.1016/S0079-6123(06)59014-4)
- [13] Whang, M. C., Kim, K. T., Goh, S. T. and Jeong, B. Y. "A Research on EEG Synchronization of Movement Cognition for Brain Computer Interface", *Journal of the Ergonomics Society of Korea*, 26(2), pp. 167-171, 2007.
DOI: <https://doi.org/10.5143/JESK.2007.26.2.167>
- [14] Zhang, G., Davoodnia, V., Sepas-Moghaddam, A., Zhang, Y. and Etemad, A., "Classification of hand movements from EEG using a deep attention-based LSTM network", *IEEE Sensors Journal*, 20(6), 3113-3122, 2019.
DOI: <https://doi.org/10.1109/JSEN.2019.2956998>
- [15] Robinson, N., Vinod, A. P., Ang, K. K., Tee, K. P. and Guan, C. T. "EEG-based classification of fast and slow hand movements using wavelet-CSP algorithm", *IEEE Transactions on Biomedical Engineering*, 60(8), 2123-2132, 2013.
DOI: <https://doi.org/10.1109/TBME.2013.2248153>
- [16] Alomari, M. H., Samaha, A. and AlKamha, K. "Automated classification of L/R hand movement EEG signals using advanced feature extraction and machine learning", *International Journal of Advanced Computer Science and Applications*, 4(6), pp. 207-212, 2013.
DOI: <https://doi.org/10.48550/arXiv.1312.2877>
- [17] Jeon, B.I., Kang, B.J., Cho, H.C. and Kim, J. , "Motion Recognition and an Accuracy Comparison of Left and Right Arms by EEG Signal Analysis", *Applied Science*, 9, 4885, 2019.
DOI: <https://doi.org/10.3390/app9224885>
- [18] Byung Jun Kang, Hyun Chan Cho. ".Classification of the Human Actions by Analysis of Electrical Signals in the Brain", *Journal of Korean Institute of Intelligent Systems*, 31(4), pp. 293-298, 2021.

DOI: <https://doi.org/10.5391/JKIS.2021.31.4.293>

- [19] Rubinstein, R. "The cross-entropy method for combinatorial and continuous optimization", *Methodology and computing in applied probability*, 1(2), pp. 127-190, 1999.
DOI: <https://doi.org/10.1023/A:1010091220143>
- [20] Greiner, Markus, Dirk Pfeiffer, and Rebecca D. Smith. "Principles and practical application of the receiver-operating characteristic analysis for diagnostic tests", *Preventive veterinary medicine*, 45.1-2, pp. 23-41, 2000.
DOI: [https://doi.org/10.1016/s0167-5877\(00\)00115-x](https://doi.org/10.1016/s0167-5877(00)00115-x)
- [21] Lin, Tsung-Yi, et al. "Focal loss for dense object detection." *Proceedings of the IEEE international conference on computer vision*, pp.2980-2988, 2017.
DOI: <https://doi.org/10.1109/ICCV.2017.324>

강 병 준(Byung Jun Kang)

[정회원]



- 2018년 8월 : 한국기술교육대학교 일반대학원 전기전자통신공학과 (전자공학석사)
- 2023년 8월 : 한국기술교육대학교 일반대학원 전기전자통신공학과 (전자공학박사)

• 2022년 8월 ~ 현재 : 한국폴리텍대학 서울정수캠퍼스 인공지능소프트웨어과 조교수

<관심분야>

딥러닝, 머신러닝

조 현 찬(Hyun Chan Cho)

[정회원]



- 1992년 3월 ~ 현재 : 한국기술교육대학교 전기전자통신공학부 교수

<관심분야>

지능제어, 로보틱스