

Prediction of the Following BCI Performance by Means of Spectral EEG Characteristics in the Prior Resting State

Jae-Hwan Kang[†] · Sung-Hee Kim^{††} · Joosang Youn^{†††} · Junsuk Kim^{††}

ABSTRACT

In the research of brain computer interface (BCI) technology, one of the big problems encountered is how to deal with some people as called the BCI-illiteracy group who could not control the BCI system. To approach this problem efficiently, we investigated a kind of spectral EEG characteristics in the prior resting state in association with BCI performance in the following BCI tasks. First, spectral powers of EEG signals in the resting state with both eyes-open and eyes-closed conditions were respectively extracted. Second, a convolution neural network (CNN) based binary classifier discriminated the binary motor imagery intention in the BCI task. Both the linear correlation and binary prediction methods confirmed that the spectral EEG characteristics in the prior resting state were highly related to the BCI performance in the following BCI task. Linear regression analysis demonstrated that the relative ratio of the 13 Hz below and above the spectral power in the resting state with only eyes-open, not eyes-closed condition, were significantly correlated with the quantified metrics of the BCI performance ($r=0.544$). A binary classifier based on the linear regression with L1 regularization method was able to discriminate the high-performance group and low-performance group in the following BCI task by using the spectral-based EEG features in the precedent resting state ($AUC=0.817$). These results strongly support that the spectral EEG characteristics in the frontal regions during the resting state with eyes-open condition should be used as a good predictor of the following BCI task performance.

Keywords : Electroencephalography, Brain Computer Interface, Convolution Neural Network, Lasso

뇌신호 주파수 특성을 이용한 CNN 기반 BCI 성능 예측

강재환[†] · 김성희^{††} · 윤주상^{†††} · 김준석^{††}

요약

뇌파를 이용한 Brain-computer interface (BCI) 연구에서는 다른 그룹보다 그 성능을 발휘하지 못하는 소위 BCI-illiteracy 그룹이라고 알려진 사용자 집단에 대한 이해와 처리가 중요하다. 본 연구는 사용자로부터 사전 휴지 상태의 뇌파 신호를 미리 측정하고 그 신호로부터 주파수 기반의 특징 변수를 생성하여 이를 피험자 개인의 특성 변수로 사용하고, 추정된 개인 특성 변수를 이용하여 이후 움직임 상상 패러다임이 적용된 BCI 시행의 성과와 어느 정도의 정량적 연관성을 가지며 이를 정확하게 예측할 수 있는지를 밝히고자 하였다. 결과에 대한 신뢰성을 높이기 위해서 검증된 공개 뇌파 데이터베이스를 활용하고 Convolution neural network 기반의 딥러닝 기법을 활용하여 이전 BCI 성능 계산을 실시하였으며 Lasso 정규화가 적용된 선형 회귀 분석을 통해서 각 특징 변수와의 예측 관련성을 조사하였다. 첫 번째로 휴지 상태 뇌파 모든 특징 변수들과 BCI 성능 간의 연관성을 파악하기 위해서 전통적인 통계 방법들을 적용하였고 이를 통해서 전두엽에서 측정된 뇌파 신호들의 13 Hz를 기준으로 이보다 낮은 주파수와 높은 주파수 파워 간의 비율이 BCI 성능 사이와 통계적 유의미한 높은 상관성이 가지고 있다는 사실을 확인할 수 있었다. 이를 근거로 상대 주파수 비율 값이 BCI 성능을 예측해볼 수 있는 좋은 지표 후보군으로 지정하였다. 두 번째로 Lasso를 이용한 회귀 분석을 통해서 휴식 상태의 상대 주파수 비율 변수를 이용하여 BCI 성능 사이에 최대 선형 계수 0.544 수준의 선형 관계를 찾을 수 있었으며, BCI 과제를 잘 시행할 수 있는 그룹과 못할 그룹을 AUC 0.817 수준으로 예측할 수 있었다. 본 연구에서는 각 사용자마다 측정된 휴지 상태의 뇌파로부터 앞으로 있을 BCI 성능을 예측할 수 있는 방법론 제시함으로써 일반인을 대상으로 좀 더 신뢰성 있고 응용 가능한 BCI 시스템 개발에 기여하고자 한다.

키워드 : Electroencephalography, Brain Computer Interface, Convolution Neural Network, Lasso

1. 서론

인간의 뇌파(EEG, electroencephalography) 신호는 대뇌 피질 내에서 발견되는 여러 기능적, 인지적 작용에 관한 다양한 정보를 포함하고 있다. Brain-Computer Interface (BCI) 기술은 다양한 신호 처리 및 해독 방법을 측정된 뇌파 신호에

※ 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 GrandICT 연구지원센터 지원사업의 연구결과로 수행되었음(IITP-2020-0-01791).

† 비회원 : 동의대학교 인공지능 그랜드ICT 연구센터 연구원

†† 정회원 : 동의대학교 산업ICT기술공학과 조교수

††† 종신회원 : 동의대학교 산업ICT기술공학과 교수

Manuscript Received : September 21, 2020

Accepted : October 22, 2020

* Corresponding Author : Junsuk Kim(junsuk.kim@deu.ac.kr)

적용하여 사용자의 실제 사지 및 말단 운동 없이, 운동에 대한 생각과 의지 정보를 뇌파로부터 정확하게 추출하여 이를 통해 외부 장비나 시스템을 안정적으로 조정하는 것을 목표로 한다. 그동안 BCI 기술은 뇌졸중, 치매 등과 같이 뇌 손상 환자들의 운동 혹은 인지 재활 훈련 활용에 주로 연구 초점이 맞춰져 있었지만 최근에는 일반 사람들을 대상으로 TV나 키보드 작동과 같이 실생활에 필요한 조작도 BCI 기술이 가능하도록 하는 많은 연구들이 진행 중이다[1]. 하지만, 정량적인 BCI 성능을 평가 기준으로 보면 비교적 간단한 BCI 기술 방법론으로도 그 성능이 잘 얻어지는 피험자가 있는 반면 두 피에서 측정되는 뇌파 신호 자체가 BCI 조절을 위한 정보가 매우 부족하거나 혹은 과도하게 왜곡된 상태로 기록이 되는 등 다양한 이유로 BCI 성능이 거의 나오지 않는 그룹도 전체 15~30% 정도가 존재한다고 알려졌다[2, 3]. 최근에 이 용어 사용에 대한 윤리적 논란이 있지만[4], 보편적으로 이렇게 BCI 성능이 현저히 낮은 사용자를 'BCI-illiteracy', 'BCI-inefficiency', 또는 'BCI-deficient' 그룹 등으로 일컫는다 [3, 4]. BCI-illiteracy를 문제를 적절하게 다루기 위해서 BCI 연구에서는 일반적으로 다음과 같은 두 가지 정도의 접근법을 활용한다. 첫 번째는 BCI-illiteracy에 해당하는 사용자 수를 최소화하기 위하여 BCI 시행의 페러다임 자체를 최적화하여 이를 해결하고자 하는 연구가 있으며[4, 5], 두 번째는 BCI 시행 전, 사전 조건을 통해서 전체 그룹에서 BCI-illiteracy 그룹을 우선 구분하여 이 두 종류 그룹에 대한 처리를 따로 행하는 연구들이 있다[3, 6, 7]. 보통 최종 응용 방법과 상관없이 개발 단계에서는 BCI-illiteracy 그룹과 아닌 그룹을 나누어 진행할 필요성이 있기에 사전에 측정된 뇌파를 이용하여 이후 해당 피험자가 본 BCI 시행 성능을 어느 정도 얻을 것인가 예측해보고자 하는 연구가 많은 관심을 받아 왔다. 이러한 이유로 대부분의 과거 연구는 본 BCI 시행 전에 움직임 없이 가만히 앉아서 휴지 상태에서 눈을 뜨고 있거나 (REO, Resting state with eyes-open condition) 혹은 눈을 감고 있는 (REC, Resting state with eyes-closed condition) 상태에서 간단히 측정된 뇌파를 주로 활용하였다.

예를 들어, Blankertz 등은 REO 상태에서 2분간 좌우측 두정엽 두 지점(C3, C4)에서 측정된 뇌파를 활용하여 차후 BCI 성능의 정도를 정량적으로 추정하고자 한 연구를 시도하였다. 우선 측정 뇌파 신호로부터 아래에 기술된 Equation (1)과 같은 주파수 파워 밀도 (PSD, power spectral density) 함수를 추정하고 이후, 움직임 상상을 통한 좌우 이진 BCI 시행을 실시하여 이에 해당하는 BCI 성능을 정량적으로 측정하였다. 추정된 PSD 함수는 Equation (1)과 같이 두 가지 요소로 구성되는데, 첫 번째는 뇌파의 1/f 잡음을 모델링 한 g_1 과 두 번째는 sensorimotor rhythm에 해당하는 두 개의 파워 진폭 피크를 표현하기 위해 정규 함수를 이용하여 모델화 한 g_2 함수가 이에 해당된다. PSD 함수의 하이퍼파라미터를 이용한 예측 지수와 이후 계산된 이진 분류 BCI 성능과의 선형 회귀 분석을 실시하여 이 둘 사이에 선형 계수 0.53

정도의 연관성이 있음을 밝혀, 이를 근거로 휴지 상태 뇌파의 PSD 함수의 계수가 본 BCI 시행의 성능을 추정할 수 있는 하나의 좋은 예측 계수로 활용될 수 있음을 보여주었다[3].

$$\begin{aligned} g(f; \lambda, \mu, \sigma, k) &= g_1(f; \lambda, k) + g_2(f; \lambda, \sigma, k) \\ g_1(f; \lambda, k) &= k_1 + \frac{k_2}{f^\lambda} \\ g_2(f; \mu, \sigma, k) &= k_3 N(f; \mu_1, \sigma_1) + k_4 N(f; \mu_2, \sigma_2) \end{aligned} \quad (1)$$

또 다른 그룹 연구에서는 REO 상태의 뇌파에서 Equation (2)에 기술된 것과 같이 쉐타 (θ , 4~8 Hz) 대역의 파워를 가중치 (λ , $1-\lambda$)가 각각 알파 (α , 8~13 Hz)와 베타 (β , 13~20 Hz) 대역 파워 값에 보정된 합으로 정량화 한 계수를 예측 지수로 제시하였다. BCI 시행 분류를 위해서 filter-bank common spatial pattern (FBCSP)를 이용한 전처리 기법과 선형 분류기인 support vector machine (SVM) 사용하여 BCI 성능과 제시한 예측 지수 간에 역시 선형계수 0.53 정도의 선형적 관계가 있음을 밝히고 있다[6]. Equation (2)에서 c 는 선택된 뇌파 채널을 의미하며 쉐타 대역에서 c_θ 는 전두엽 (Frontal)에 해당되는 F3, Fz, F4, 알파 대역에서 c_α 는 두정엽 (Parietal)에 해당하는 P7, P3, Pz, P4, P8, 베타 대역에서 c_β 는 중앙 가운데 (Central midline)에 해당하는 Cz, CPz 채널을 의미한다.

$$F_{\neq w} = \frac{\sum_{c \in c_\theta} P_c^\theta}{\lambda \sum_{c \in c_\alpha} P_c^\alpha + (1-\lambda) \sum_{c \in c_\beta} P_c^\beta} \quad (2)$$

Ahn 등은 Equation (3)과 같이 performance potential factor (PPfactor)라는 BCI 성능 예측 지수를 발표하였는데 이는 REO 상태의 뇌파에서 각각의 가중치가 적용된 알파 (α , 8~13 Hz)와 베타 (β , 13~30 Hz) 대역 파워와 쉐타 (θ , 4~8 Hz)와 감마 (γ , 30~70 Hz) 대역 파워의 비로 구성되어 있다. 이 PPfactor가 왼손과 오른손 움직임 상상을 구분하는 이진 BCI 시행 성능과 0.59 정도 수준의 선형 관계식을 가지고 있음을 밝혔고[8], 이 연구의 최근 후속 연구에서는 REO 상태뿐만 아니라 REC 상태의 뇌파 특징을 추가하여 선형 계수 0.71의 높은 수준의 선형적 관계를 보이는 BCI 성능 예측 지수를 개발하였다는 주장을 발표하였다[9].

$$PPfactor = \frac{w_1 \alpha + w_2 \beta}{w_3 \theta + w_4 \gamma} \quad (3)$$

주파수 밴드 파워를 이용한 예측 지수 이외에 Zhang 등은 REO, REC 상태의 뇌파로부터 Welch 방법을 이용한 PSD 함수를 구해 0.5~14 Hz 대역 파워 분포에 대한 엔트로피를 계산하여 이를 예측 지수로 활용하였다. 그 결과 REO 상태에서 C3 지점에서의 엔트로피가 선형 계수 0.65 수준으로

높은 연관성이 존재함과 이를 통해서 동일한 두 번의 BCI 세션 간의 분류를 통해서 BCI 성능이 높은 그룹과 낮은 그룹을 89% 정도 정확성으로 예측할 수 있다고 보고하였다[10].

앞서 기술한 바와 같이, 지금까지 개인별로 REO, REC 상태에서 측정된 뇌파와 BCI 성능과의 관계를 밝히고자 하는 다양한 연구가 있었고, 이러한 연구를 통하여 BCI 성능 예측에 대한 여러 중요한 정량적 증거들이 발표되었다. 하지만, 기존의 연구들은 아래와 같은 몇 가지 문제점을 여전히 가지고 있었다. 첫 번째로, 대부분의 연구가 신속한 BCI 응용 시스템을 개발하기 위해서 common spatial pattern (CSP)와 같은 비교적 간단한 선형 기반의 공간 필터와 linear discriminant analysis (LDA)나 SVM과 같은 선형 분류 방법을 기본으로 사용한다. 이러한 선형 기반의 방법론은 효율적이고 실용적이라는 장점이 있지만 사전 예측 지표 발굴이라는 관점에서 보면, 이보다는 더 고차원적인 기법을 통해 사전 뇌파 신호 특성과 BCI 성능과의 관계가 더 객관적으로 명확하게 밝혀질 필요가 있다. 두 번째로, 이 역시 자체 목적에 맞는 BCI 응용 시스템 개발에는 장점이 있지만, 범용성을 가진 일반적인 BCI 예측 계수 개발에 있어서는 수십 명의 피험자 수는 그 수가 적을 뿐 아니라 수집된 뇌파 데이터가 다른 연구 그룹이나 방법으로 검증되지 못했다는 문제점이 있을 수 있다.

이러한 기존 연구의 한계점을 고려하여 본 연구에서는 다음과 같은 두 가지 목표를 가지고 연구를 진행하였다. 첫 번째로 BCI 성능 측정을 위해서 단순한 선형 기반 분류기가 아닌 convolution neural network (CNN) 기반의 딥러닝 기술을 적용하였다. 이를 통해 좀 더 새롭고, 높은 BCI 성능을 추정해 그 결과를 다양한 특징 변수들과의 비교, 분석하였다. 두 번째로 자체 데이터베이스 활용이 아니라 100명 이상의 사용자가 참여하고 기존의 여러 연구에서도 활용된 공개된 데이터베이스를 활용해서 결과의 신뢰도를 높이고자 하였다.

2. 방 법

2.1 EEG Motor Movement/Imagery Dataset

본 연구에서는 2009년에 Physionet에서 공개되어 그동안 수많은 뇌파 신호 분석 및 BCI 알고리즘 연구에 활용되어 온 EEG Motor Movement/Imagery Dataset을 이용하였다 [11]. 이 데이터베이스는 109명의 사용자가 참가하여 움직임 상상을 기본 BCI 패러다임으로 한 실험을 수행하였는데, 이때 동시에 10-10 international 시스템을 따르는 64채널 뇌파 신호가 160 Hz 샘플링레이트로 수집된 데이터로 구성되어 있다. 모든 참여자의 뇌파 신호는 동일하게 총 14개의 시행에 맞춰 수집되었고, 처음 두 개 시행은 REO, REC 상태에 각각 1분간 측정된 데이터이며 나머지 12개 시행은 4개의 서로 다른 BCI 패러다임이 3번씩 반복된 상태이다. 4개의 BCI 패러다임은 다음과 같다. 1) 왼쪽 손 혹은 오른쪽 손 실제 움직임, 2) 왼쪽 손 혹은 오른쪽 손 상상 움직임, 3) 양손 혹은

양발 실제 움직임, 4) 양손 혹은 양발 상상 움직임, 이에 해당되는 약 4초간 구간의 뇌파가 시행 구간 사이는 2초간의 휴지 상태가 보장된 상태로 각 조건 별로 약 21회씩 기록되어 있다. Fig. 1은 움직임과 상상 시행을 할 때 진행되는 시간 순서를 보여주고 있다. 본 연구에서는 REO, REC 시행 조건과 움직임 상상에 해당되는 2), 4)번 BCI 패러다임이 적용된 데이터만을 사용하였다. 또한 109명의 피험자 뇌파 데이터 중에 과도한 잡음이 포함된 5명의 데이터를 뺀 104명의 뇌파 데이터를 사용하였으며 64채널 중에서 다음과 같은 8개의 채널 (AF7/8, FT7/8, T9/10, Oz, Iz)는 제외하고 56개 채널 뇌파만을 사용하였다.




Fig. 1. Timeline of a BCI Paradigm in the EEG Motor/Imagery Database

2.2 휴지 상태 뇌파 특성

사전 휴지 상태에 해당하는 REO, REC 시행에서 각각 1분간 측정된 뇌파 데이터는 다음과 같이 주파수 분석을 적용하여 주파수 파워 관련한 특징 변수를 추출하였다. 방법으로는 분석의 기본 구간을 2초로 설정하여 하나의 고정된 에폭으로 설정하고 이를 무작위로 30개의 에폭으로 분할한 후, 각 에폭별로 Hamming 윈도우가 적용된 FFT(Fast Fourier transform) 방법으로 채널별 주파수 분석을 실시하였다.

이후 본 연구에서 관심이 있는 5개의 주요 뇌파 주파수 대역, 즉 세타 (θ , 4~8 Hz), 알파 (α , 8~13 Hz), 낮은 베타 (β , 13~20 Hz), 높은 베타 ($h\beta$, 20~30 Hz), 감마 (γ , 30~50 Hz) 대역에 해당하는 파워를 각 구간의 주파수 진폭을 평균하여 대푯값으로 정하고 5개의 전체 파워에 각 파워를 나누는 정량화된 파워 값들을 특징 변수로 사용한다. 다음으로, 얻어진 개별 5개의 파워 값들로부터 10개의 가능한 쌍으로 묶어서 이들의 상대 파워 비율 계산 후 특징 변수로 사용한다. 추가로 Fig. 2와 같이 각 에폭별로 FFT로 얻은 전체 주




Fig. 2. An Example of Power Spectral Density of a 2-sec EEG Epoch during the Resting State with Eyes-closed Condition

파수 분포에 대해서 이 분포에 대한 Shannon 엔트로피와 중간값(Median)에 해당되는 주파수를 구해 역시 특징 변수로 활용한다. 결국, 우리는 각 채널당 총 17가지 특징 벡터를 계산할 수 있었고 최종적으로 REO, REC 상태를 표현하는 특징 변수로 이렇게 계산된 17가지 특징 벡터들의 30개 예폭에 대한 평균값 혹은 표준편차값을 활용하였다.

2.3 BCI 시행 성능

EEG Motor Movement/Imagery Dataset의 두 가지 BCI 패러다임 시행에 대한 뇌파 해독은 CNN 기반의 EEGNet 모델을 이용한 이진 분류 방식으로 실시하였다[12]. 우선, EEGNet에 입력값으로 들어온 다중 뇌파 신호는 다음과 같이 각기 다른 기능을 담당하는 세 단계 모듈을 거치면서 최종적인 이진 분류를 출력한다. 첫 번째 단계로 하나의 2D-CNN 모델이 각 채널 별로 다양한 주파수 성분 정보를 걸러내는 시간적(Temporal) 필터 역할을 담당한다. 두 번째 단계에서는 depthwise 2D-CNN 모델이 첫 단계에서 거친 정보에 대해 동일 시간당 전체 다중 채널 데이터에 적용하는 공간적(Spatial) 필터 역할을 담당한다. 마지막 단계는 depthwise 2D-CNN 모델의 조합으로 구성되어 있는데 이는 각 특징 맵마다 독립적으로 시간적 정보를 학습하고 이를 pointwise convolution 작용으로 결국 특징 맵을 최적화시키는 역할을 담당한다.

Table 1. Layout of EEGNet Network

Layer	Output shape
InputLayer	(56, 480, 1)
Conv2D	(56, 480, 8)
BatchNormalization	(56, 480, 8)
DepthwiseConv2D	(1, 480, 16)
BatchNormalization	(1, 480, 16)
Activation	(1, 480, 16)
AveragePooling2D	(1, 120, 16)
Dropout	(1, 120, 16)
SeparableConv2D	(1, 120, 16)
BatchNormalization	(1, 120, 16)
Activation	(1, 120, 16)
AveragePooling2D	(1, 15, 16)
Dropout	(1, 15, 16)
Flatten	(240)
Dense	(2)
Softmax Activation	(2)

저자는 개발된 EEGNet 알고리즘의 성능을 잘 알려진 네 가지 대표 BCI 데이터베이스에 적용하여 FBCSP를 포함한 기존의 여러 알고리즘 결과들과 비교 분석한 후, 이 모델이 해석 가능한 특징 변수 추출과 뇌파 해독 작업에 뛰어난 성능을 보여주고 있다고 발표하였다[12]. 본 연구에서의 BCI 이진 분류

는 각 사용자마다 독립적으로 실시하였으며, 이때 EEGNet 각 모듈의 CNN 연산은 배치크기가 15인 배치정규화 방식, 드롭아웃비는 0.2, 활성화 함수는 exponential linear units (ELU) 함수를 사용하였다. 손실 함수는 이진 크로스 엔트로피 함수를 사용하였으며 최적화는 adaptive movement estimation (ADAM) 방식을 사용하였다. Table 1은 본 연구에서 사용한 EEGNet 모델 구성과 사용된 파라미터를 보여준다.

분류에 대한 성능은 5-fold 교차 검증방식으로 학습 데이터와 테스트 데이터를 나누어 5번의 테스트 데이터 시행 결과로 얻은 전체 데이터의 정확률을 생성 후 두 가지 BCI 시행 성능의 평균값 중에 더 높은 값을 해당 참가자의 최종 BCI 정확률로 설정하였다. 이러한 이유는 본 연구 목적이 개별 참가자들이 내재적으로 가지고 있는 최대 유효 정보가 어느 정도 인지 즉, 개인별 최대 정량화에 초점을 맞추었기 때문이다. 계산된 BCI 정확률은 다음과 같이 독립된 두 가지 방법으로 가공되어 활용하였다. 첫 번째로 계산된 정확률은 이진 분류에 대한 결과 값이기 때문에 이 값이 통계적으로 어느 정도 정량적 의미를 가지는지 확인하여 전체 참가자를 BCI 성능에 따라 상/중/하 그룹으로 나누었다. 이를 위해서 전체 참가자 수와 몇 개의 클래스로 분류되는지가 정해지면 이에 맞는 유의미한 통계 신뢰 구간을 계산해주는 Muller-Putz 연구의 주장을 따랐다[13]. 본 연구에서는 총 104명의 참가자에 이진 균형 분류이기에 무작위 정확률은 0.5가 되며, 이보다 0.05 유의 수준으로 더 큰 범위는 0.594이며, 0.01 수준은 0.658이 된다. 이를 기준으로 정확률이 0.594 이하인 그룹을 '하' 그룹으로, 0.658 이상이 되는 그룹을 '상' 그룹, 그 중간에 있는 그룹을 '중' 그룹으로 나누었다. Equation (4)에서, n 는 전체 피험자 수, X_t 는 각 피험자 BCI 정확률, \bar{p} 는 표준정규함수, α 는 0.05 혹은 0.01 유의구간, C.I.는 신뢰구간 (Confidence interval)을 의미한다.

$$\begin{aligned} \bar{X} &= \frac{1}{n} \sum_{t=1}^n X_t \\ \tilde{p} &= \frac{n\bar{X} + 2}{n + 4} \\ \text{C.I.} &= \tilde{p} \pm \sqrt{\frac{\tilde{p}(1-\tilde{p})}{n+4}} \cdot z_{1-\frac{\alpha}{2}} \end{aligned} \quad (4)$$

두 번째로 추정된 REO, REC 상태의 특징 변수들 간의 상관성 조사를 위해서 계산된 정확률은 아래 Equation (5)와 같이 무작위 조건일 때 정확률이 0이며 최대치가 1이 될 수 있도록 정규화한 κ 값으로 변환한다. 이때 P_a 는 이진 분류 정확률을 의미하고, P_c 는 무작위 조건일 때의 이진 정확률인 0.5를 의미한다. 계산된 κ 를 최종 BCI 성능값으로 지정하고 이를 Lasso 회귀 분석에서의 종속 변수로 사용하였다.

$$\kappa = \frac{P_a - P_c}{1 - P_c} \quad (5)$$

2.4 Lasso regression

사전 휴식 상태의 뇌파 특성과 본 BCI 패러다임 성능 간의 연관성을 파악해보기 위해서 우선 REC, REO 조건에서의 모든 뇌파 특징 변수들과 BCI 성능 간의 관련성을 확인해보았다. 즉, 종속 변수는 계산된 각 피험자의 BCI 성능을 나타내는 κ 이며 독립 변수는 REO 혹은 REC 상태에서 추출한 56 채널의 각 17개 특징 변수들의 총 30개 에폭 평균 혹은 표준편차 값이 이에 해당된다. 첫 번째로 총 17 가지 개별 특징 변수들과 BCI 성능 값 간의 선형 분석을 실시하였고, BCI 성능에 따른 3가지 피험자 그룹(상/중/하)간 통계적으로 유의미한 차이가 있는지를 비모수 one-way analysis of variance (ANOVA) 방법인 Kruskal-Wallis H-test를 실시하였다. 두 번째로, REO, REC 조건의 각 특징 변수를 그 특성에 따라 다음과 같이 4개의 조합으로 묶어서, 이러한 그룹 특징 변수들이 각각 어느 정도 실질적인 BCI 성능을 예측할 수 있는지를 Lasso 정규화가 적용된 선형 회귀 방법을 통해서 확인하였다. 4가지 그룹 특징 변수는 1) 5개 밴드 파워 ($\theta, \alpha, \beta, h\beta, \gamma$), 2) 10개 상대 밴드 파워 비율 (eg, $\theta/\alpha, \beta/\gamma, \dots$), 3) Shannon 엔트로피와 중간 주파수 값, 4) 1), 2), 3)을 모두 합한 총 17가지 특징 변수 조건으로 이루어졌다. 역시 각 그룹 특징 변수를 하나의 다중 독립 변수로 측정된 BCI 성능 값을 하나의 종속 변수로 각각 설정하고 이들의 관계를 Lasso 정규성이 적용된 선형 관계로 정의하였다. Lasso 정규성은 Equation (6)과 같이 Lasso 파라미터인 λ 를 조정함으로써 유효한 선형 계수들의 개수를 최적화 할 수 있다.

$$W_{\text{lasso}} = \operatorname{argmin}_W \sum_{n=1}^N (y_n - W \cdot X_n)^2 + \lambda \|W\|_1$$

$$\hat{y}_n = W_{\text{lasso}} * X_n \tag{6}$$

$$\text{MSE} = \sum_{n=1}^N (y_n - \hat{y}_n)^2$$

성능 평가는 실제로 EEGNet이 계산한 정확률과 선형 분석의 출력값인 각 특징 변수 조건에 따른 예측치 간의 오차인 mean square error (MSE)를 이용하였다. 마지막으로, 최적화된 Lasso 계수들이 실질적으로 얼마나 정확히 BCI 성능 그룹을 구분할 수 있는지를 성능 예측 값에 대해 단순 임계치를 적용하여 '상' 그룹과 '하' 그룹 간의 이진 분류를 실시하였다. 사용되는 독립 변수 조합은 두 번째 방법에 기술된 4가지 그룹 특징 변수 조건을 따르며 이들에 대한 정량적 결과는 receiver operating characteristic (ROC) 커브의 area under curve (AUC)값으로 최종 확인하였다. 참고로 전반적인 확인을 위한 첫 번째 선형 분석에서는 전체 데이터를 모두 사용하였고, 두 번째 Lasso 회귀분석과 마지막 이진 분류 테스트는 5-fold 교차 검증 방식으로 학습 데이터와 테스트 데이터를 분리하여 학습 데이터를 이용해 Lasso 계수를 선정할 이후 이에 대한 결과는 테스트 데이터 실험으로 검증하였다.

3. 결 과

3.1 뇌파 특징 변수와 BCI 성능 상관관계

REO, REC 조건에서 추출한 17개의 각 특징 변수와 BCI 성능에 대한 선형 분석과 Kruskal-Wallis H-test를 실시해 본 결과 REC 조건의 평균값, 표준편차와 REO 조건의 표준편차 특징 변수에서는 3가지 BCI 성능 그룹간의 어떠한 통계적 유의미성이 발견되지 않았다 ($p > 0.05$). 하지만 REO 조건의 평균값에서는 몇몇 조건에서 뚜렷한 통계적 유의미성 차이를 보이고 있었다. 아래에 기술될 모든 내용은 REO 조건의 평균값을 특징 변수로 설정한 경우에 해당된다.

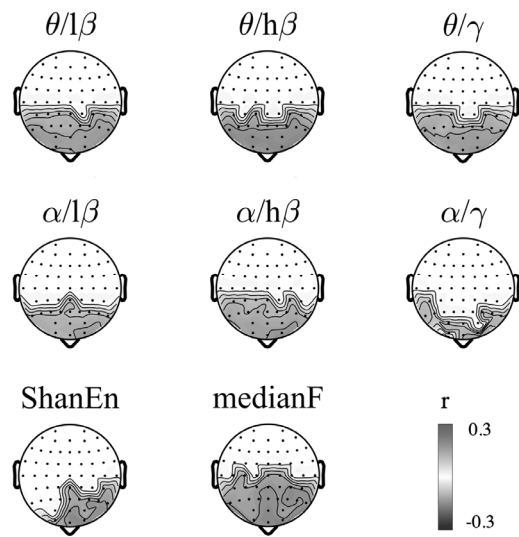


Fig. 3. Eight Topographies for the Individual Spectral EEG Characteristics with Significant Statistical Results ($P < 0.05$ and $|r| < 0.3$) during the REO Condition

Fig. 3은 REO 조건에서 유의미한 통계적 차이를 보이고 있는 8개의 특징 변수의 결과를 보여주고 있다. 이를 확인해 보면 전두엽 부위에서 세타, 알파와 같은 저주파수 대역과 베타, 감마와 같은 고주파 대역 간 상대 비율에서는 BCI 성능과의 선형 연관성과 BCI 세 가지 성능 그룹 간 차이에 뚜렷한 통계적 의미가 있음을 확인할 수 있었다. 이러한 근거는 Shannon 엔트로피, 중간 주파수 경우에도 역의 관계로 동일하게 표현되는데 결국 BCI를 상대적으로 잘하는 그룹에서는 높은 세타, 알파 파워 증가가 일어나 Shannon 엔트로피와 중간 주파수 값이 낮아짐을 확인할 수 있다.

3.2 Lasso Regression

Fig. 4는 특징 벡터 4가지 그룹 조건에 대해 BCI 성능과 Lasso 정규성이 적용된 선형 관계 결과에 대한 MSE 값을 학습 데이터와 테스트 데이터로 구분하여 보여주고 있다. 그림에서 가로축은 Lasso weight (λ)값을 의미하며 왼쪽이 높은 λ 값 (낮은 $-\log(\lambda)$ 값) 설정으로 특징 변수 개수가 최소로 선택한 경우에 해당하며, 반대로 오른쪽으로 갈수록

사용되는 특징 변수 갯수가 늘어나는 경우를 나타낸다. 사용되는 수가 늘어나면 날수록 MSE가 낮아지다가 과적합 발생으로 인한 테스트 데이터에서 MSE 값이 증가하는 전형적인 패턴을 보인다. 특징 변수 간의 성능을 보면 모든 계수를 사용했을 때가 MSE 값이 최소가 되는 가장 좋은 성능을 보이고 있으며 개별 특징 변수로는 상대 파워 비율과 Shannon 엔트로피 중간값 조합이 단순한 절대 밴드 파워 보다 더 좋은 성능을 보이고 있다. 이는 앞서 기술한 선형 분석을 통해 알게 된 전두엽 영역의 낮은 주파수 상대 파워 값 증가가 BCI 성능과 비례관계를 보인다는 동일한 결과를 보인다.

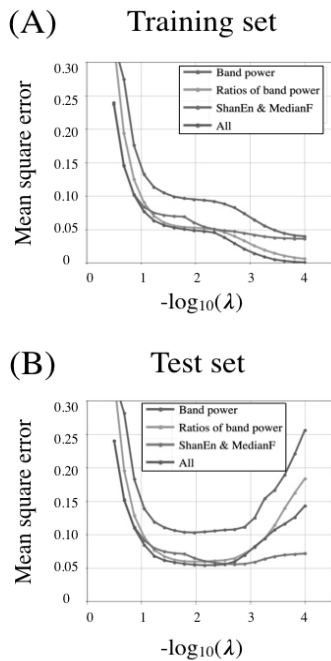


Fig. 4. Mean Square Errors in the Training Set (A) and Test Set (B)

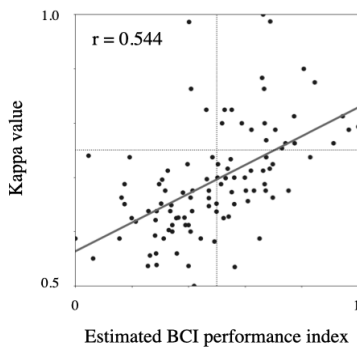


Fig. 5. Mean Square Errors in the Training Set

Fig. 5는 모든 특징 벡터를 사용하고, 최적의 Lasso 파라미터를 사용하였을 때 Lasso 결과값, 즉 BCI 성능 예측 지표와 실제 BCI 성능인 Kappa 값과의 관계를 보여주는 그림으로 이 둘 간에는 통계적으로 유의미한 수준으로 선형 계수 0.54 정도의 선형 관계성이 있음을 보여주고 있다($p < 0.01$).

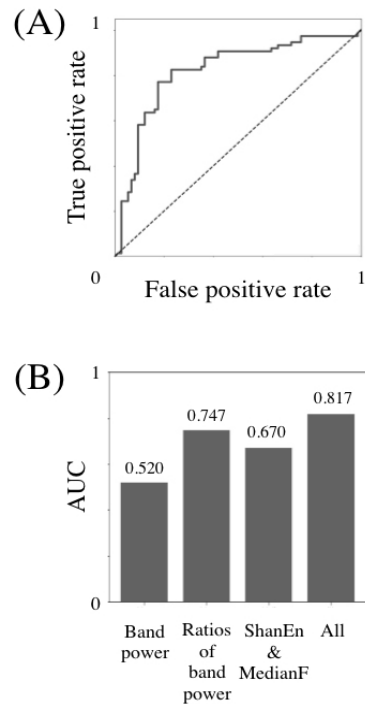


Fig. 6. (A) An Example of AUC in ROC at the 'All' Condition, (B) Four AUC Values Corresponding to all Individual Conditions, Respectively

Fig. 6은 선택 최적화된 계수를 이용하여 얻은 BCI 성능 예측 지표에서 높은 성능 그룹과 낮은 성능 그룹 간의 이진 분류 결과를 보여주고 있다. 왼쪽은 모든 특징 변수를 사용한 조건에서 임계치 변화에 따른 true positive rate (TPR)과 false positive rate (FPR)의 관계를 보여주는 ROC 커브의 예시를 보여준 것이고 오른쪽 바 그래프는 각 특징 변수 조합에 따른 이 ROC 커브의 AUC 값을 나타내고 있다. 이 결과로 확인 가능하듯이 모든 변수를 사용하였을 때가 AUC 값이 0.817로 가장 높았고 그 다음으로 상대 밴드 파워 비율 (0.747), Shannon 엔트로피와 중간 주파수 (0.670), 밴드 파워 (0.520) 순으로 확인되었다.

4. 토 의

본 연구에서는 사전 휴지 상태 동안 측정된 뇌파 신호로부터 주파수 기반의 특징 변수를 생성하고 이를 CNN 이진 분류 기반의 BCI 시행 성과 비교를 통해 BCI 성능 예측 정도를 정량적으로 조사하였다. 주요 결과로는 단일 절대 주파수 대역 파워 값들 자체로는 좋은 예측 지표를 제시하지는 못하였지만 이들 사이의 각 상대 밴드 파워의 비율 값으로는 차후 BCI 성능을 잘 예측함을 확인하였다. 특히, 4~13 Hz 범위에 속한 세타와 알파 대역과 13~30 Hz 범위에 속한 베타 파워 간의 상대 비율은 앞으로 진행될 해당 피험자의 BCI 성능을 예측할 수 있는 매우 중요한 인자로 밝혀졌다. 이러한 결과는 과거 연구 결과들과 상당한 부분 일치한다. 즉, 파워

스펙트럼의 추정식의 하이퍼파라미터를 예측 지수로 사용했던 Blankertz et al. 연구에서도 결국 지표에 가장 큰 영향력을 미치는 인자는 눈을 뜬 상태의 4~30 Hz 대역 중에 존재하는 최대 파워값이었다[3]. 또 다른 연구에서도 훈련 구간 동안에 12~15 Hz SMR 대역 파워를 자발적으로 올릴 수 있는 ‘responder’ 그룹이 그렇지 못한 ‘non-responder’ 그룹보다 휴식 상태의 SMR 파워가 더 높음을 기술하였다[14]. 그 외 예측 지수를 생성하는 방법이나 식은 다르지만 여러 연구들에서 휴식 상태의 4~30 Hz 대역의 파워가 BCI 성능 예측과 밀접한 관계가 있음을 일관적으로 보고하고 있다[6, 8-10]. 눈을 뜬 조건과 눈을 감은 조건에 대해서도 두 조건을 다 사용한 Kwon 연구[9]나 눈을 감은 조건에서 더 좋은 결과를 얻었다는 Zhang 연구[10]를 제외하고는 대부분이 본 연구 결과와 동일한 눈 뜬 상태에서 측정된 뇌파가 더 좋은 예측 인자로 표현되었다. 이는 눈을 감으면서 크게 발생하는 후두엽 알파파가 중요 SMR 대역의 파워에 대한 잡음으로 작용하기에 이를 이용한 예측 성능이 낮아지는 것으로 생각된다.

이번 연구를 통해서 눈을 뜬 상태 휴식 상태의 시험 전 뇌파로 차후의 BCI 시행 성능을 예측해볼 수 있었다. 특히 단순한 선형 분류기 임의 시행 데이터베이스를 벗어나 CNN 기반의 딥러닝 분류 기법과 공개 데이터베이스를 사용하고 교차 검증 방법을 택하여 결과에 대한 신뢰성을 높였다. 그럼에도 불구하고, 기존의 주파수 대역 파워 기반의 특징 변수를 벗어나 SMR-BCI가 아닌 보편적인 뇌파 실험에 대한 성능 예측을 위해서도 비선형 지수 활용 등 다양한 특징 변수 연구가 필요할 것으로 보인다.

5. 결 론

사전에 실시한 눈 뜬 상태의 휴식 구간에 전두엽에서 측정된 뇌파의 4~13 Hz 대역 파워와 13~30 Hz 대역 파워의 비율을 얻어내면 CNN 기반의 분류 알고리즘으로 확인한 차후 움직임 상상 기반의 BCI 시행 성과와 높은 선형 상관성이 존재하고 있을 뿐 아니라 이를 이용하여 성능이 높을 그룹과 낮을 그룹을 성공적으로 이진 분류가 가능하였다.

References

[1] P. Stegman, C. S. Crawford, M. Andujar, A. Nijholt, and J. E. Gilbert, “Brain-Computer Interface Software: A Review and Discussion,” *IEEE Transactions on Human-Machine Systems*, Vol.50, No.2, pp.101-115, Feb. 2020.

[2] C. Vidaurre and B. Blankertz, “Towards a Cure for BCI Illiteracy,” *Brain Topography*, Vol.23, No.2, pp.194-198, Nov. 2009.

[3] B. Blankertz, C. Sannelli, S. Halder, E. M. Hammer, A. Kübler, K.-R. Müller, G. Curio, and T. Dickhaus, “Neurophysiological Predictor of SMR-based BCI Performance,” *NeuroImage*, Vol.51, No.4, pp.1303-1309, Jul. 2010.

[4] M. C. Thompson, “Critiquing the Concept of BCI Illiteracy,” *Science and Engineering Ethics*, Vol.25, No.4, pp.1217-1233, Aug. 2018.

[5] C. Jeunet, E. Jahanpour and F. Lotte, “Why Standard Brain-computer Interface (BCI) Training Protocols Should be Changed: an Experimental Study,” *Journal of Neural Engineering*, Vol. 13, No.3, pp.036024, Jun. 2016.

[6] A. Bamdadian, C. Guan, K. K. Ang and J. Xu, “The Predictive Role of Pre-cue EEG Rhythms on MI-based BCI Classification Performance,” *Journal of Neuroscience Methods*, Vol.235, pp.138-144, Sep. 2014.

[7] E. M. Hammer, S. Halder, B. Blankertz, C. Sannelli, T. Dickhaus, S. Kleih, K.-R. Müller, and A. Kübler, “Psychological Predictors of SMR-BCI Performance,” *Biological Psychology*, Vol.89, No.1, pp.80-86, Jan. 2012.

[8] M. Ahn, H. Cho, S. Ahn, and S. C. Jun, “High Theta and Low Alpha Powers May Be Indicative of BCI-Illiteracy in Motor Imagery,” *PLoS ONE*, Vol.8, No.11, pp.e80886-11, Nov. 2013.

[9] M. Kwon, H. Cho, K. Won, M. Ahn, and S. C. Jun, “Use of Both Eyes-Open and Eyes-Closed Resting States May Yield a More Robust Predictor of Motor Imagery BCI Performance,” *Electronics*, Vol.9, No.4, pp.690-14, Apr. 2020.

[10] R. Zhang, P. Xu, R. Chen, F. Li, L. Guo, P. Li, T. Zhang, and D. Yao, “Predicting Inter-session Performance of SMR-Based Brain-Computer Interface Using the Spectral Entropy of Resting-State EEG,” *Brain Topography*, Vol.28, No.5, pp.1-11, Apr. 2015.

[11] G. Schalk, D. J. McFarland, T. Hinterberger, N. Birbaumer, and J. R. Wolpaw, “BCI2000: A General-Purpose Brain-Computer Interface (BCI) System,” *IEEE Transactions on Biomedical Engineering*, Vol.51, No.6, pp.1034-1043, Jun. 2004.

[12] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. Lance, “EEGNet: A Compact Convolutional Neural Network for EEG-based Brain-computer Interfaces,” *Journal of Neural Engineering*, Vol.15, No.5, pp.056013, Oct. 2018.

[13] G. Müller-Putz, R. Scherer, and C. B. I. Journal, 2008, “Better than Random: A Closer Look on BCI Results,” *International Journal of Bioelectromagnetism*, Vol.10, No.1, pp.52-55, Jan. 2008.

[14] J. L. Reichert, S. E. Kober, C. Neuper, and G. Wood, “Resting-state Sensorimotor Rhythm (SMR) Power Predicts the Ability to Up-regulate SMR in an EEG-instrumental Conditioning Paradigm,” *Clinical Neurophysiology*, Vol. 126, No.11, pp.2068-2077, Nov. 2015.



강재환

<https://orcid.org/0000-0002-9425-847X>
e-mail : jh.kang@deu.ac.kr
1999년 고려대학교 응용전자공학과(학사)
2001년 충북대학교 의용전자공학(석사)
2015년 고려대학교 뇌공학과(박사)
2020년~현 재 동의대학교 인공지능
그랜드ICT 연구센터 연구원

관심분야: Biomedical analysis, Deep-learning



윤주상

<https://orcid.org/0000-0001-9952-9649>
e-mail : jsyoun@deu.ac.kr
2001년 고려대학교 전기전자전파공학과(학사)
2003년 고려대학교 전기전자전파공학과(석사)
2008년 고려대학교 전기전자전파공학과(박사)
2008년~현 재 동의대학교
산업ICT기술공학과 교수

관심분야: AI, IoT, Mobile network



김성희

<https://orcid.org/0000-0002-9716-8349>
e-mail : sh.kim@deu.ac.kr
2006년 이화여자대학교 컴퓨터공학과(학사)
2008년 이화여자대학교 컴퓨터공학과(석사)
2014년 퍼듀대학교 산업공학과(박사)
2017년~현 재 동의대학교
산업ICT기술공학과 조교수

관심분야: Data visualization, Machine learning



김준석

<https://orcid.org/0000-0002-7252-3420>
e-mail : junsuk.kim@deu.ac.kr
2010년 고려대학교 전기전자전파공학과(학사)
2012년 고려대학교 뇌공학과(석사)
2016년 고려대학교 뇌공학과(박사)
2020년~현 재 동의대학교
산업ICT기술공학과 조교수

관심분야: Machine learning, Biosignal processing