

딥 뉴럴 네트워크의 적절한 구조 및 자가-지도 학습 방법에 따른 뇌신호 데이터 표현 기술 분석 및 고찰

고원준*

Analysis and Study for Appropriate Deep Neural Network Structures and Self-Supervised Learning-based Brain Signal Data Representation Methods

Won-Jun Ko*

요약

최근, 의료 데이터 표현 분야에서 딥러닝 방법들이 사실상의 표준으로 자리잡고 있다. 하지만, 딥러닝 기술은 내재적으로 많은 양의 학습 데이터를 필요로 하므로 대규모의 데이터를 확보하기 쉽지 않은 의료 분야에서는 직접적인 적용이 어려운 실정이다. 특히 뇌신호 모달리티의 경우, 변동성이 크기 때문에 여전히 데이터 부족 문제를 가진다. 이에, 최근 연구에서는 뇌신호의 시간-공간-주파수 특징을 적절하게 추출할 수 있는 딥 뉴럴 네트워크 구조를 설계하거나, 혹은 자가-지도 학습 방법을 도입하여 뇌신호의 신경생리학적 특징을 미리 학습하도록 한다. 본 논문에서는, 최근 각광받는 기술인 뇌-컴퓨터 인터페이스 및 피험자 상태 예측 등의 관점에서 소규모 데이터를 다루기 위해 적용되는 방법론에 대한 분석 및 향후 기술 방향성을 제시한다. 먼저 현재 제안되고 있는 뇌신호 표현을 위한 딥 뉴럴 네트워크 구조에 대해 분석한다. 또한 뇌신호의 특성을 잘 학습하기 위한 자가-지도 학습 방법론을 분석한다. 끝으로, 딥러닝 기반 뇌신호 분석을 위한 중요 시사점 및 방향성에 관하여 논한다.

ABSTRACT

Recently, deep learning technology has become those methods as de facto standards in the area of medical data representation. But, deep learning inherently requires a large amount of training data, which poses a challenge for its direct application in the medical field where acquiring large-scale data is not straightforward. Additionally, brain signal modalities also suffer from these problems owing to the high variability. Research has focused on designing deep neural network structures capable of effectively extracting spectro-spatio-temporal characteristics of brain signals, or employing self-supervised learning methods to pre-learn the neurophysiological features of brain signals. This paper analyzes methodologies used to handle small-scale data in emerging fields such as brain-computer interfaces and brain signal-based state prediction, presenting future directions for these technologies. At first, this paper examines deep neural network structures for representing brain signals, then analyzes self-supervised learning methodologies aimed at efficiently learning the characteristics of brain signals. Finally, the paper discusses key insights and future directions for deep learning-based brain signal analysis.

키워드

Deep Neural Network, Self-Supervised Learning, Brain Signal Analysis, Deep Representation Learning
딥 뉴럴 네트워크, 자가-지도 학습, 뇌신호 분석, 심층 표현 학습

* 교신저자 : 성신여자대학교 AI융합학부
• 접수일 : 2023. 12. 28
• 수정완료일 : 2024. 01. 20
• 게재확정일 : 2024. 02. 17

• Received : Dec. 28, 2023, Revised : Jan. 20, 2024, Accepted : Feb. 17, 2024
• Corresponding Author : Won-Jun Ko
School of AI Convergence, Sungshin Women's University
Email : wjko@sungshin.ac.kr

1. 서 론

뇌전도(Electroencephalogram: EEG) 신호는 뇌 안의 뉴런들의 신경 활동으로 인해 발생된다[1]. 뇌전도 신호는 비침습적으로 실용적이기 때문에 수면 단계(Sleep staging)[2], 질병 진단(Pathology detection)[3], 동작 상상(Motor imagery)[4] 등 사용자의 임상적 상태 혹은 건강 상태를 관찰하기 위해 빈번하게 채택된다. 일반적으로, 뇌전도 신호는 미리 정의된 전극 센서들의 배열을 머리 위에 씌워, 각 전극들에 기록되는 전위차를 계산하여 획득된다[1].

전극으로부터 획득된 뇌전도 신호는, 그것이 획득되는 과정에서 내재적으로 다수의 전기 발생 근원(Source), 즉 뉴런에서 발생한 전기장들의 간섭이 이루어진다. 그러므로, 이미 많은 수의 선도적인 연구들이 뇌 영역 및 기능에 대한 분석을 진행했음에도 불구하고, 일반적으로 전극 배열을 뇌 기능과 직접적으로 연관짓는 것은 불가능하다[1]. 즉, 뇌전도 신호의 복잡한 주파수-시간 혹은 공간-시간 패턴을 해석하는 것은 여전히 대단히 어려운 일이다[5]. 게다가, 뇌전도 신호가 복잡한 뇌 내부의 인지적 과정에서 생성되기 때문에 외부 환경은 물론 피험자 개인적인 상태에 따라서도 많은 영향을 받게 된다. 결국, 높은 피험자내(Intra-subject) 혹은 피험자간(Inter-subject) 변동성이 일반적으로 관찰되며, 이러한 변동성을 감축시키는 것은 용이하지 않게 된다[1]. 마지막으로, 뇌전도 신호의 특성이 그것을 획득하는 실험적 프로토콜, 즉 뇌전도 신호 패러다임에 따라 달라질 수 있다[1]. 이러한 어려움이 각 뇌전도 신호 패러다임에 특화된 분석 알고리즘을 개발하도록 하는 요인이다.

위에 서술된 뇌전도 신호 표현(Representation)의 어려움 때문에, 사전 지식에 기반하여 클래스-분리적 특징(Class-discriminative feature)을 추출하는 것은 대단히 어렵다. 그렇기 때문에, 최근 연구들은 기계학습(Machine learning) 기반의 특징 추출 및 분리 방법론에 대단히 주목하고 있다[6-8]. 예를 들어, 공간적 필터링(Spatial filtering) 기반 방법론들은 동작 상상 패러다임을 사용하는 뇌-컴퓨터 인터페이스(Brain-computer interface: BCI)기술에 많이 사용된다[4, 9]. 하지만, 이러한 선형적 기계학습 기반 방법론들은 뇌전도 신호 표현에 관련해서 위에 서술된 중

요한 문제들을 완벽하게 해결하지는 못하였다. 그러는 와중에, 딥러닝 프레임워크들이 데이터로부터 학습하는 자동적인 특징 표현에서 그 능력을 입증하였다. 그러므로, 많은 성공적인 연구들은 뇌전도 신호 분석을 위해 딥러닝 방식을 사용하였다[1, 2, 4, 10].

다양한 딥러닝 기술들 중, 컨볼루션 뉴럴 네트워크(Convolution neural network: CNN)는 입력 데이터의 구조적(Structural), 구성적(Configurational) 특성을 유지할 수 있기 때문에, 뇌전도 신호 분석에서 놀라운 결과를 보여주었다. 뇌-컴퓨터 인터페이스에 쓰이는 컨볼루션 뉴럴 네트워크는 일반적으로 세 타입의 컨볼루션을 사용한다[1, 4]. 공간 컨볼루션은 입력 뇌전도 신호의 전극 배열들로부터 얻어지는 공간적 관계를 표현한다. 시간적 컨볼루션은 입력 신호의 시간적 다이내믹스(Dynamics) 특징을 표현한다. 또한, 최근 들어 주목받는 주파수 컨볼루션은 뇌전도 신호의 주파수적 특성을 분석하여 그 효과를 입증하였다. 일반적으로 뇌-컴퓨터 인터페이스를 위한 컨볼루션 뉴럴 네트워크의 구조는 이러한 세 가지 종류의 컨볼루션을 조합하여 얻어지며, 시간-공간-주파수 특성을 표현하여 이들의 상호 보완적인 정보를 획득하는데 집중한다.

또한, 자가-지도적 학습(Self-supervised learning) 방법은 레이블이 없는 샘플들을 이용하여 딥 뉴럴 네트워크를 최적화할 수 있으므로 주목받고 있다. 자가-지도적 전략을 사용하여 다양한 학습 임무(Learning task)들이 딥 뉴럴 네트워크를 학습하는데 사용될 수 있으며, 범용(General-purpose) 표현을 얻을 수 있게 한다[3]. 일반적으로 컨볼루션 뉴럴 네트워크가 학습 파라미터가 많은 반면, 레이블이 있는 뇌전도 신호 데이터의 양은 그 획득이 제한적이다. 그렇기 때문에, 몇몇 선도적인 연구들은 자가-지도적 접근 방법을 채택하였으며, 특히 대조 학습(Contrastive learning)에 주목하였다[2, 11-12].

본 논문의 구성은 다음과 같다. 제 2장에서는 소규모 뇌전도 신호 표현을 위해 사용된 딥 뉴럴 네트워크 구조들을 분석한다. 제 3장에서는 뇌전도 신호를 표현하기 위해 사용되는 자가-지도적 학습 방법들에 대한 동향을 분석한다. 제 4장에서는 소규모 데이터 기반 뇌신호 표현 딥러닝 알고리즘 개발의 향후 방향성을 제시하고 제 5장에서 결론을 기술한다.

II. 뇌전도 신호 표현을 위한 컨볼루션 뉴럴 네트워크 구조

해당 장에서는 다양한 뇌전도 신호 패러다임의 시간-공간-주파수 특징을 추출하기 위해 고안된 딥 뉴럴 네트워크들의 구조를 분석한다. 표 1에 해당 방법론들에 대해 정리하였다.

2.1 뇌전도 신호 분석을 위한 컨볼루션 연산

일반적인 다층 퍼셉트론(Multi-layer perceptron: MLP)이 입력 데이터를 벡터화(Vectorization)하면서 구조적, 구성적 정보를 붕괴시키기 때문에, 그렇지 않은 컨볼루션 뉴럴 네트워크가 많은 주목을 받아왔다. 일반적으로, 컨볼루션 뉴럴 네트워크는 비선형 활성화 함수(Nonlinear activation function)을 포함한 컨볼루션 레이어들, 조건에 따라 선택되거나 하는 서브샘플링(Subsampling) 레이어들(예: 최대치 풀링(Max pooling), 전역 평균 풀링(Global average pooling) 등), 역시 조건에 따라 입력 사이즈를 유지하기 위해 사용되는 제로-패딩(Zero-padding)으로 구성된다.

일반적으로 컨볼루션 레이어의 역할은 학습 가능한 커널을 이용하여 입력 데이터의 각기 다른 위치에 존재하는 지역적 패턴을 인식하는 것이다. $v^{(i,j)}$ 가 행렬 V 의 i 번째 행, j 번째 열의 원소를 의미한다고 하자. 형식적으로, 전극 개수 N_c , 시간에 따른 데이터 포인트(Timepoint) 개수 N_t 를 가지는 입력 데이터 행렬 $X \in R^{N_c \times N_t}$ 에 대해 제로-패딩이 없는 이차원 컨볼루션의 출력 행렬 Y 는 수식 (1)과 같이 표현된다.

$$y^{(i,j)} = \sigma\left(\sum_{i,j} h^{(i,j)} + b^{(i,j)}\right) \quad \dots (1)$$

$$H := W \otimes X_{[K_w^{(i)} : K_w^{(i)}]}^{(i+S \cdot i - S, j+S \cdot j - S)} \quad \dots (2)$$

이 때 σ , \otimes , $W \in R^{K_o \times K_i}$, $B \in R^{K_o \times K_i}$, $S \in N^+$ 는 각각 비선형 활성화 함수, 하다마르드곱(Hadamard multiplication), 가중치(Weight) 행렬, 바이어스(Bias) 행렬, 스트라이드(Stride)를 의미한다. 또한 $V_{[m:n]}^{(i,j)}$ 는 행렬 V 의 i 번째부터 $i+m$ 번째 행, j 번째부터 $j+n$ 번째의 열을 의미하는 부분행렬(Submatrix)이다.

F_s 의 샘플링 주파수를 갖는 뇌전도 신호 샘플 X 를 위해 주파수 컨볼루션은 전극-차원의 방향으로 $1 \times (F_s/2)$ 크기의 커널을 가진다. Nyquist-Shannon 샘플링 정리에 따라 이러한 주파수 컨볼루션은 입력 신호의 2 Hz 이상의 주파수 정보를 탐지할 수 있다 [1]. 또한, 시간 컨볼루션은 비슷하게 입력 신호를 시간적으로 임베딩(Embedding)하며 같은 시간축 커널을 가지지만 그 크기는 $F_s/2$ 보다 훨씬 작게 설정하여, 지역적인 시간적 정보를 학습하는 데에 주목한다. 마지막으로 공간 컨볼루션은 $N_c \times 1$ 크기의 커널을 사용하여 뇌전도 신호를 획득하는 데에 사용되는 전극의 공간적 관계를 추출할 수 있도록 한다.

2.2 뇌전도 분석을 위한 컨볼루션 뉴럴 네트워크

Schirmmeister 등은 다양한 뇌전도 신호 패러다임 표현을 위해 효율적인 컨볼루션 뉴럴 네트워크 구조를 제안하였다[4]. 예를 들어, Shallow ConvNet 및 Deep ConvNet 구조는 뇌전도 신호를 우선 공간 컨볼루션을 이용하여 공간적으로 필터링한 후 후속 특징을 시간 컨볼루션을 이용하여 시간적으로 임베딩하였다. 또한, Hybrid ConvNet은 Shallow ConvNet과 Deep ConvNet의 특징 추출 과정을 모두 사용하여 좀 더 특징 표현의 품질을 더 향상하였다.

Lawhern 등은 깊이축(Depthwise) 컨볼루션 및 분리가능(Separable) 컨볼루션 연산을 적절히 사용하여 EEGNet 구조를 설계하였으며, 이를 통해 학습 파라미터를 효과적으로 줄였다[6]. 또한, 주파수 컨볼루션을 제안하여, 다양한 뇌전도 신호 패러다임에서 좋은 성능을 획득하였다.

Ko 등은 다중 스케일에서 중간적 특징을 추출하여 표현하는 데에 함께 사용하는 Multi-Scale Neural Network(: MSNN)를 제안하였다[1]. 제안 구조는 다양한 패러다임에서 뇌전도 신호의 시간-공간-주파수 특성을 효율적으로 추출하여, 뇌전도 신호 해석에서 최고 수준의 성능을 획득하여 우수성을 입증하였다.

Santamaria-Vazques 등은 뇌전도 신호 표현을 위해 인셉션(inception) 구조를 채택하여 입력 데이터의 중간적 특징을 추출하였다[7]. 이를 통해 뇌전도 패러다임 중 하나인 사건-관련 전위(Event-related potential)을 효과적으로 분류하였다.

Kwon 등은 신호 필터링 방법론을 컨볼루션 뉴럴 네트워크와 조합하여 Spatio-Spectral Feature Representation(: SSFR) 방법을 제안하였다[9].

Jeon 등은 딥러닝 방법을 이용하여 학습된 뇌전도 신호의 표현의 상호 정보량(Mutual information)을 계산한 후 뇌전도 신호의 높은 변동성을 줄이는 데에 집중하여 동작 상상 패러다임에서 높은 성능을 획득 하였다[8].

Perez-Velasco 등은 인셉션 구조 및 잔차 연결(Residual connection)을 조합하고, 데이터 증대(Data augmentation)방법을 이용하여 학습시킨 EEGSym을 제안하여 역시 동작 상상 패러다임의 변동성을 줄이는 데에 집중하였다[13].

표 1. 뇌전도 신호 표현을 위한 컨볼루션 뉴럴 네트워크 구조

Table 1. Convolution neural network structures for electroencephalogram signal representation

Methods	Structures
Shallow/Deep ConvNet[4]	CNN
Hybrid ConvNet[4]	CNN + Hybrid
EEGNet[6]	CNN
MSNN[1]	CNN + Multi-Scale
Santamaria-Vazquez[7]	CNN + Inception
SSFR[9]	CNN + Spatial filtering
Jeon[8]	CNN + Mutual information
EEGSym[13]	CNN + Inception + Residual connection

III. 뇌전도 신호 표현을 위한 자가-지도 학습 방법

해당 장에서는 다양한 뇌전도 신호 패러다임의 클래스-분리적 특징을 추출하기 위해 제안된 자가-지도 학습 방법론을 분석한다. 표 2에 해당 방법론들에 대해 정리하였다.

3.1 자가-지도 학습 방법론

자가-지도 학습은 레이블이 없는 데이터를 이용하여 새로운 데이터셋을 생성하고 이를 딥 뉴럴 네트워크의 사전학습(Pretraining)에 사용하는 방식이다[10]. 일반적으로 레이블이 있는 데이터를 확보하기 어려운 경우에 사용되며, 사전학습된 네트워크는 추후 본래 목적을 위해 학습될 경우 더 우수한 성능을 보인다.

널리 쓰이는 자가-지도 방법 중 하나인 관계적 위치(Relative positioning) 기반 방법은 데이터가 가지고 있는 공간적 정보를 학습하는데 주로 쓰인다[10]. 더 자세히는, 뇌전도 전극의 국소 부분들이 주어지면, 이들 사이의 상대적인 관계를 토대로 공간 특징을 학습한다. 이와 비슷하게, 시간 셔플링(Temporal shuffling) 방법은 뇌전도 신호의 시간적 위치를 예측 하도록 하는 자가-지도 학습 방법이다[10].

뿐만 아니라, 뇌전도 신호를 마스크(Masking), 잡음(Noise) 더하기 등의 다양한 방식으로 변동시킨 후 비교적 학습(Constastive learning)을 통해 복잡한 특징을 학습할 수 있도록 하는 자가-지도 방법도 존재 한다[11].

최근에는 뇌전도 신호의 신경생리학적 특성에 기반 하여 사전 임무(Pretext task)를 설계하는 연구도 제안되었으며, 다양한 패러다임의 뇌전도 신호에서 유의 미한 성능을 획득하였다[14].

3.2 뇌전도 분석을 위한 자가-지도 학습

최근의 자가-지도 학습 기반 뇌전도 신호 표현 연구는 보통 피험자간 임상적, 자발적(Spontaneous) 뇌전도 신호 해석에 집중되어 있다. Banville 등은 트리플렛-순서(Triplet-order) 기반 학습 전략을 적용하여 임의의 앵커(Anchor) 샘플에서 미리 정의된 길이 내부에 존재하는 샘플을 양적(Positive) 샘플, 그렇지 않은 샘플을 음적(Negative) 샘플로 설정하여 관계적 위치 학습을 진행하였다[10]. 이 방법론을 이용하여, 수면 상태 예측 및 질병 진단에서 그 우수성을 입증 하였다.

Jiang 등은 몇 가지 신호 변환 방법론과 함께 비교적 자가-지도 학습 프레임워크를 제안하였다[11]. 시간 워핑(Time warping), 가우시안 잡음 추가(Adding Gaussian noise), 수평 뒤집기(Horizontal flipping), 부분 신호 자르기(Cutout), 신호 사이즈 변환(Resizing)을 이용하여 수면 상태 예측을 실험하였다.

Mohsenvand 등은 마스크(Masking), 스케일링(Scaling), 직류값 이동(DC value shifting)과 같은 새로운 신호 변환 방식을 제안하여 자가-지도 학습 프레임워크를 설계하였으며, 수면 상태 예측, 질병 진단, 감정 예측 등 다양한 패러다임의 뇌전도 신호 분석에서 제안 방법론의 우수성을 확인하였다[3].

Yang 등은 비교적 학습 기반의 자가-지도 방법을 제안하였다. 이 연구는 데이터셋의 전역적 통계치를 사용하여 수면 상태를 예측하였다[2].

Ou 등은 Temporal Rearrangement Motor Imagery Network(TRIMNet)이라는 새로운 사전 임무를 설계하였는데, 뇌전도 신호를 시간적으로 재배열(Rearrangement)하여 그러한 샘플들을 구분하는 자가-지도 학습 방법이다. TRIMNet은 동작 상상 뇌신호 패러다임에 사용되었으며 피험자간 변동성을 줄여 높은 성능을 획득할 수 있음을 입증하였다[15].

Xiao 등은 수면 상태 분류를 위해 분류 및 예측적 비교 코딩(Coding)을 사용한 SleepDPC를 제안하여 우수한 성능을 획득하였다[12].

Tang 등은 다음에 이어질 뇌전도 신호의 주기(Next period)를 예측하는 자가-지도 학습 방법을 설계하여 뇌전증 환자의 발작을 예측하는 임무에서 그 우수성을 입증하였다[16].

Ko 등은 뇌전도 신호의 신경생리학적 특성을 고려한 새로운 사전 임무를 제안하였다[14]. 이 연구에서는 감쇄 밴드 예측(Stopped band prediction) 임무를 통해 뇌전도 신호 샘플에서 감쇄된 주파수 영역을 예측하는 자가-지도 학습을 통해 딥 뉴럴 네트워크가 주파수 특성을 잘 학습하도록 하였다. 뿐만 아니라, 시간적 경향성 예측(Temporal trend identification) 임무를 이용하여 뇌전도 신호에 추가된 직류값이 가지는 경향성을 예측하도록 하여 딥 뉴럴 네트워크가 국소적, 전역적 시간 특징을 잘 학습할 수 있도록 설계하였으며, 다양한 뇌전도 신호 패러다임에서 그 우수성을 입증하였다.

표 2. 뇌전도 신호 표현을 위한 자가-지도 학습
Table 2. Self-supervised learning methods for electroencephalogram signal representation

Methods	Self-supervised learning
Banville[10]	Relative positioning, Time shuffling
Jiang[11]	Contrastive learning
Mohsenvand[3]	Contrastive learning
Yang[2]	Contrastive learning
TRIMNet[15]	Temporal rearrangement
SleepDPC[12]	Contrastive learning
Tang[16]	Next period prediction
Ko[14]	Stopped band prediction, Temporal trend identification

IV. 방향성 분석

지금까지 제안된 방법론들은 크게 뇌신호의 신경생리학적 특징을 잘 추출하기 위한 컨볼루션 뉴럴 네트워크 설계 혹은 클래스-분류적 특징을 추출하기 위한 자가-지도적 학습이었다. 두 가지 방향성 모두 독립적으로 우수한 성능을 입증하였으나 이를 적절히 융합한다면 더욱 풍부한 표현이 가능할 것이다. Hybrid ConvNet, MSNN처럼 시간-공간-주파수 정보를 추출하기 위한 경로를 분리[1, 4]하고, Ko 등의 방법처럼 뇌신호의 신경생리학적 특성을 고려한 자가-지도 학습을 각각의 경로에 적용하여 사전학습[14] 시킨 후, 각 경로에서 추출되는 중간 특성들을 통계치에 기반해서 조합하여 사용하는 방법을 고려할 수 있다. 이 경우, 다양한 뇌신호 패러다임에 적용 가능하고, 피험자내/피험자간 변동성을 줄여 적은 양의 뇌전도 신호 데이터만 사용해도 실용적으로 사용 가능한 수준의 딥러닝 방법론을 설계할 수 있을 것으로 예상된다. 또한, 각 경로에서 학습되는 정보가 분리되어 있는 만큼 설명성 알고리즘을 적용하기에도 유리할 것이다.

V. 결론

본 논문에서는 많은 샘플의 확보가 어려운 뇌전도 분석에 딥러닝을 적용하기 위해 고안된 방법을 조사하였다. 시간-공간-주파수 특징 추출을 위한 컨볼루션 뉴럴 네트워크 구조 및 적은 양의 데이터로도 클래스-분류적 특징을 학습할 수 있는 자가-지도 학습에 대해 다루었으며 뇌신호의 신경생리학적 관점에 집중해서 향후 연구되어야 할 방향성을 제시하였다. 추후, 제시한 방향성을 검증하고, 다른 신호로 확장 시 발생할 문제에 대한 고찰이 필요할 것이다[17].

References

[1] W. Ko, E. Jeon, S. Jeong, and H. Suk, "Multi-scale neural network for EEG representation learning in BCI," *IEEE Comput. Intell. Mag.*, vol. 16, no. 2, 2021, pp. 31-45.
[2] C. Yang, D. Xiao, M. B. Westover, and J. Sun,

- "Self-supervised EEG representation learning for automatic sleep staging," *arXiv*, vol. 1, 2021.
- [3] M. N. Mohsenvand, M. R. Izadi, and P. Maes, "Contrastive representation learning for electroencephalogram classification," in *Proc. Mach. Learn. Health. Virtual Meeting*, 2020.
- [4] R. T. Schirrneister, J. T. Springenberg, L. D. J. Fiederer, M. Glasstetter, K. Eggensperger, M. Tangermann, F. Hutter, W. Burgard, and T. Ball, "Deep learning with convolutional neural networks for EEG decoding and visualization," *Hum. Brain Mapp.*, vol. 38, no. 11, 2017, pp. 5391-5420.
- [5] D. Kim, S. Park, and D. Kim, "The classification scheme of ADHD for children based on the CNN model," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 17, no. 5, 2022, pp. 809-814.
- [6] 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 interface," *J. Neural Eng.*, vol. 15, no. 5, 2018, pp. 056013.
- [7] E. Santamaria-Vazquez, V. Martinez-Cagigal, F. Vaquerizo-Villar, and R. Hornero, "EEG-inception: a novel deep convolutional neural network for assistive ERP-based brain-computer interfaces," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 28, no. 12, 2020, pp. 2773-2782.
- [8] E. Jeon, W. Ko, J. Yoon, and H. Suk, "Mutual information-driven subject-invariant and class-relevant deep representation learning in BCI," *IEEE Trans. Neural Net. Learn. Syst.*, vol. 34, no. 2, 2021, pp. 739-749.
- [9] O. Kwon, M. Lee, C. Guan, and S. Lee, "Subject-independent brain-computer interfaces based on deep convolutional neural networks," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 31, no. 10, 2019, pp. 3839-3852.
- [10] H. Banville, O. Chehab, A. Hyvarinen, D.-A. Engemann, and A. Gramfort, "Uncovering the structure of clinical EEG signals with self-supervised learning," *J. Neural Eng.*, vol. 18, no. 4, 2021, p. 046020.
- [11] X. Jaing, J. Zhao, B. Du, and Z. Yuan, "Self-supervised contrastive learning for EEG-based sleep staging," in *Proc. Int. Joint Conf. Neural Netw.*, Virtual Meeting, 2021.
- [12] Q. Xiao, J. Wang, J. Ye, H. Zhang, Y. Bu, Y. Zhang, and H. Wu, "Self-supervised learning for sleep stage classification with predictive and discriminative contrastive coding," in *Proc. IEEE Int. Conf. Acoust., Speech, Signal Process*, Toronto, Canada, 2021.
- [13] S. Perez-Velasco, E. Santamaria-Vazquez, V. Martinez-Cagigal, D. Marcos-Martinez, and R. Hornero, "EEGSym: overcoming inter-subject variability in motor imagery based BCIs with deep learning," *IEEE Trans. Neural Syst. Rehabil. Eng.*, vol. 30, 2022, pp. 1766-1775.
- [14] W. Ko and H. Suk, "EEG-oriented self-supervised learning and cluster-aware adaptation," in *Proc. Int. ACM Conf. Inf. Knowl. Manag.*, Atlanta, USA, 2022.
- [15] Y. ou, S. Sun, H. Gan, R. Zhou, and Z. Yang, "An improved self-supervised learning for EEG classification," *Math. Biosci. Eng.*, vol. 19, no. 7, 2022, pp. 6907-6922.
- [16] S. Tang, J. A. Dunmon, K. Saab, X. Zhang, Q. Huang, E. Dubost, D. L. Rubin, and C. Lee-Messer, "Self-supervised graph neural networks for improved electroencephalographic seizure analysis," *arXiv*, vol. 1, 2021.
- [17] J. Moon and Y. Lee, "Artificial Intelligence Computing Platform Design for Underwater Localization," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 17, no. 1, 2022, pp. 119-124.

저자 소개

고원준(Won-Jun Ko)



2022년 고려대학교 대학원 뇌공학과 졸업(공학박사)
2023년 ~ 현재 성신여자대학교 AI융합학부 조교수
※ 관심분야 : 의료인공지능