

운동 심상 기반 EEG 분류 기술의 발전 흐름

이현주, 이재호

덕성여자대학교

20221004@duksung.ac.kr, izeho@duksung.ac.kr

A Study on the Technological Evolution of EEG-Based Motor Imagery Classification

Lee Hyeon Joo, Jaeho Lee

Duksung Women's Univ.

요약

본 논문은 뇌파를 기반으로 한 운동 심상 분류 기술의 발전 과정을 체계적으로 정리한 것이다. EEG는 시간 해상도가 높고 센서 구조가 간단하여 다양한 뇌-컴퓨터 인터페이스 응용에 적합한 신호로 평가된다. 하지만 EEG는 비선형성 및 피험자 간 분포 차이로 인해 분석과 분류에 어려움이 존재한다. 초기에는 CSP와 같은 전통적인 특징 추출 기법이 주로 활용되었으나 시계열 정보를 반영하지 못하고 피험자 간 일반화 성능이 낮다는 한계가 있었다. 이러한 문제를 보완하기 위해 다양한 주파수 대역을 고려하는 Filter Bank CSP, 비선형 구조를 반영하는 Riemannian Geometry 기반 모델이 제안되었다. 이후 EEGNet, CNN-LSTM과 같은 딥러닝 모델을 통해 시공간 정보를 자동으로 학습하는 접근이 가능해졌으며 분류 정확도 향상에 기여했다. 그러나 피험자 간 신호 특성의 차이로 인해 여전히 cross-subject 상황에서는 성능 저하가 발생하는 문제가 남아있으며 이를 해결하기 위해 Domain-Adversarial Neural Network와 같은 도메인 적용 기반 모델이 도입되었다. 더 나아가 CNN-VAE, DMTL, GCN/GAT 등 복잡한 신경 구조나 연결성을 반영한 표현 학습 기반 모델이 개발되었으며 소수의 학습 샘플만으로도 빠른 적용을 가능하게 하는 Prototypical Network, MAML 등의 few-shot 및 meta-learning 기반 개인화 모델이 제안되고 있다. 본 논문은 각 모델이 직면한 기술적 한계와 그에 대한 대응 방식을 중심으로 MI 기반 EEG 분류 기술 발전 흐름을 정리하였다.

I. 서론

뇌파(EEG, Electroencephalography)는 뇌의 전기적 활동을 시간에 따라 연속적으로 측정할 수 있는 생체신호로 최근에는 건식 전극과 같은 간편한 센서를 통해 비교적 쉽게 수집할 수 있어 다양한 분야에서 활용되고 있다.[1] EEG는 외부 자극, 인지 활동, 운동 의도 등 다양한 뇌 상태를 반영할 수 있지만 신호의 복잡성과 잡음에 대한 민감도로 인해 분석에 어려움이 존재한다. 특히 피험자마다 집중력, 반응 양상, 전도 특성이 달라 동일한 자극에도 뇌파의 분포가 다르게 측정되는 경향이 있어 EEG 분석에는 높은 정밀도와 적응력이 요구되고 있다.

최근에는 EEG을 활용한 뇌-컴퓨터 인터페이스(BCI) 기술이 활발히 연구되고 있으며 그 중 운동 심상(Motor Imagery, MI)은 실제 움직임 없이 특정 동작을 상상한다.[2] MI 기반 BCI의 핵심은 유의미한 뇌파 패턴을 효과적으로 추출하고 이를 안정적으로 분류하는 데에 있다.

초기에는 전문가가 설정한 주파수 대역이나 공간 정보를 기반으로 수작업 특징 추출 방식이 주로 사용되었으나 표현력과 시공간 정보 통합, 일반화 성능, 개인 적응력 향상을 위한 다양한 신경망 기반의 자동화된 접근 방식이 제안되고 있다. 본 논문에서는 EEG 기반 MI 분류 모델의 발전 과정을 대표적인 구조별로 정리하고 각 모델이 해결하고자 한 기술적 한계와 향후 연구 방향을 고찰하고자 한다.

II. 본론

2.1 CSP 기반 모델

EEG 기반 운동 심상 분류 초기에는 Common Spatial Pattern 즉 CSP가 널리 사용되었다. CSP는 두 클래스 간 분산 비율을 최대화하는 공간 필터를 학습함으로써 뇌파 신호의 공간적 패턴을 효과적으로 추출할 수 있다. 계산이 간단하고 직관적이며 낮은 연산 자원으로도 일정 수준 이상의 분류 성능을 낼 수 있다는 점에서 실용성이 높았다.[3] 그러나 CSP는 시계열 구조를 반영하지 못하고 피험자 간 신호 분포 차이에 민감하다는 한계가 존재한다. 이를 보완하기 위해 Filter Bank CSP가 제안되었다. 이는 다양한 주파수 대역으로 신호를 분해하고 각 대역에 CSP를 적용하여 더 풍부하고 정교한 특징을 추출할 수 있도록 하였다.[4]

2.2 Riemannian Geometry 기반 모델

Filter Bank CSP는 주파수 정보를 확장하였으나 여전히 선형 공간에서의 처리를 기반으로 하기 때문에 EEG 신호의 비선형 구조를 충분히 반영하지 못했다. 이에 EEG 신호의 공분산 행렬을 대칭 양의 정부호 즉 Symmetric Positive Definite(SPD) 행렬로 해석하고 이를 리만 기하학 기반의 방법으로 분석하는 접근이 제안되었다. 이 방법은 SPD 행렬 간의 리만 거리 계산이나 Tangent Space 투영을 통해 분류에 활용할 수 있는 특징을 도출한다.[5] Tangent Space 기반 기법은 비선형 구조를 선형 모델에서도 활용할 수 있도록 변환해주며 피험자 간 신호 분포 차이가 존재하는 상황에서도 비교적 안정적인 성능을 보인다.[6] 이후 Riemannian Alignment(RA)를 통해 공분산 표현을 기준 피험자에 정렬함으로써 표현 공간을 통일하고 모델의 일반화 성능을 높이는 방식으로 확장되었다.[7]

다만 이러한 접근은 대부분 선형 분류기를 기반으로 하며 복잡한 분류

경계를 학습하거나 시공간 정보를 통합적으로 반영하는 데에는 구조적 한계가 존재한다.

2.3 EEGNet

딥러닝 기술이 EEG 분석에 적용되면서 원시 신호로부터 특징을 자동으로 학습하는 end-to-end 방식의 모델이 등장하였다. 이 중 EEGNet은 대표적인 경량 모델로 Depthwise Separable Convolution 구조를 활용하여 시공간 정보를 분리해 처리하고 전체 파라미터 수를 줄여 실시간 응용에도 활용할 수 있는 구조를 가진다.[8]

이 모델은 먼저 입력된 데이터에 공간 필터를 적용하여 EEG 채널 간 공간적 패턴을 추출하고 이후 시간 필터를 적용하여 시계열적 특징을 도출한다.[8] 또한 Dropout과 Batch Normalization 등의 기법을 활용하여 과적합을 방지한다. 이러한 구조는 다양한 EEG 분류 과제에서 효율성과 성능 간의 균형을 바탕으로 baseline 모델로 널리 활용되고 있다.

그러나 EEGNet은 주로 단일 피험자의 데이터를 기반으로 구성되어 있어 새로운 피험자에 대한 일반화 성능에는 한계가 있으며 장기 시계열 정보를 처리하는 데에도 구조적 제약이 따른다.

2.4 CNN-LSTM 구조

EEG는 시간 축을 따라 변화하는 시계열 데이터이기 때문에 이를 효과적으로 처리하기 위해 CNN과 LSTM을 결합한 구조가 제안되었다. CNN은 EEG 채널 간의 공간적 패턴을 학습하고 LSTM은 시간 축에서 순차적 의존성을 포착하여 시공간 정보를 통합적으로 반영할 수 있다.[9]

이러한 방식은 반복적이거나 장기적인 패턴이 포함된 운동 심상 과제에서 기존의 CNN 또는 RNN 같은 단독 구조보다 우수한 성능을 나타낸다. 그러나 모델의 복잡도가 증가할수록 연산 자원 요구량이 커져 데이터가 제한되었을 때 과적합이 발생한다.

2.5 DANN

딥러닝 기반 모델은 높은 표현력을 가지지만 피험자 간 뇌파 분포 차이로 인해 cross-subject 환경에서는 성능이 크게 저하되는 문제가 있다. 이를 해결하기 위해 Domain-Adversarial Neural Network 즉 DANN이 제안되었다. DANN은 feature extractor와 분류기 외에 도메인 분류기를 추가로 구성하고 feature extractor가 도메인 분류기를 구분하지 못하도록 학습하여 도메인 불변 특징을 학습을 유도한다.[10]

이러한 adversarial 학습 방식은 다양한 피험자의 데이터를 하나의 표현 공간으로 정렬하여 모델의 일반화 성능을 향상하는 데 효과적이다. 그러나 학습 안정성이 낮고 추출된 특징이 완전히 도메인 독립적이지 않을 수 있다.

2.6 CNN-VAE와 DMTL

EEG의 복잡한 특성을 효과적으로 표현하기 위해 CNN과 Variational Autoencoder(VAE)를 결합한 모델이 제안되었다. CNN-VAE는 EEG 신호의 잠재 표현을 추출한 후 이를 분류 뿐만 아니라 신호 재구성에도 활용함으로써 데이터의 구조적 특성에 대한 이해를 높혔다.[11]

한편 DMTL(Dual/Multi-Task Learning)은 분로와 함께 재구성 또는 예측 등의 보조 과제를 병행함으로써 다중 테스크 학습을 통해 모델의 일반화 성능을 향상하는 것을 목표로 한다. 이러한 접근은 라벨이 부족하거나 노이즈가 많은 환경에서도 비교적 안정적인 성능을 보이기 테스크 간

중요도 조정이나 손실 함수의 구성 방식에 따라 성능 변화가 크게 나타날 수 있다.

2.7 GCN과 GAT 기반 모델

EEG 신호는 채널 간 물리적 위치나 기능적 연결성을 기반으로 상호작용하므로 이러한 특성을 반영한 Graph Neural Network (GNN) 기반의 접근이 제안되었다. Graph Convolution Network(GCN)은 각 EEG 채널을 노드로 설정하고 인접 채널 간의 관계를 엣지로 정의함으로써 신호 간 상호작용을 그래프 형태로 모델링한다.[13]

Graph Attention Network(GAT)은 attention 매커니즘을 추가하여 채널 간 중요도의 차이를 반영했다. 이를 통해 중요한 연결에 더 높은 가중치를 부여한다. 이와 같은 방식은 기능적 연결성 분석이나 해석 가능성이 요구되는 상황에서 효과적으로 사용될 수 있다. 다만 그래프 구조의 정의 기준이 명확하지 않고 계산 자원 소모가 크다.

2.8 Prototypical Network와 MAML

BCI 응용 환경에서는 피험자 간 차이가 크고 개별 사용자로부터 충분한 데이터를 확보하기 어려운 경우가 많다. 이러한 문제를 해결하기 위해 최근에는 meta-learning 및 few-shot learning 기반 모델이 제안되고 있다.

Prototypical Network는 각 클래스의 중심값을 학습한 후 테스트 샘플이 어느 클래스 중심과 가까운지를 기준으로 분류를 수행한다. 이는 소수의 샘플만으로 빠르게 적용할 수 있다.[15]

MAML(Model-Agnostic Meta-Learning)은 다양한 테스크에서 일반화 할 수 있는 초기 가중치를 학습한 후 새로운 피험자 데이터에 대해 소량의 fine-tuning만으로 빠르게 성능을 향상할 수 있도록 설계된 구조이다. 이와 같은 접근은 개인화와 일반화 성능을 동시에 고려할 수 있다는 점에서 실제 응용 가능성이 크다. 그러나 사전 학습 데이터의 품질이나 하이퍼파라미터 설정에 따라 모델 성능이 크게 달라질 수 있다.[16]

III. 결론

EEG 기반 운동 심상 분류 기술은 전통적인 수동 특징 기반 모델에서 출발해 딥러닝 중심의 자동화 구조로 변환되었고 이어서 도메인 적용, 표현 학습, attention 및 그래프 기반 구조, meta-learning 기반 개인화 전략까지 점진적으로 진화했다. 각 기술은 이전 접근의 한계를 극복하고자 등장하였으며 특히 최근에는 실용적인 BCI 시스템을 위해 경량화, 실시간성, 개인 맞춤형 적용력 확보라는 핵심 요소를 동시에 고려한다. 앞으로는 이 다양한 기술들을 통합한 하이브리드 구조가 실현되어 높은 일반화와 해석 가능성을 갖춘 차세대 BCI 시스템의 기반이 되기를 기대한다.

ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 지원으로 한국연구재단의 지원 받아 수행된 연구임(과제번호- 2022R1A2C1009951).

참 고 문 헌

- [1] D. Kim, J. Lee, M. Park, Y. Park, and Y. Choi, "1.4킬로그램의 신비, 뇌! 뇌파 신호 응용기술," ETRI 웹진, no. 87, Jun. 2017. [Online].

Available: <https://www.etri.re.kr/webzine/20170630/sub04.html>

- [2] M. I. Razzak, F. Imtiaz, and T. T. Nguyen, "Motor Imagery EEG Signal Classification for Brain–Computer Interface: A Review," *Sensors*, vol. 23, no. 4, pp. 1–25, 2023. doi: 10.3390/s23042105
- [3] H. Ramoser, J. Muller–Gerking, and G. Pfurtscheller, "Optimal spatial filtering of single trial EEG during imagined hand movement," *IEEE Transactions on Rehabilitation Engineering*, vol. 8, no. 4, pp. 441–446, Dec. 2000.
- [4] K. K. Ang, Z. Y. Chin, H. Zhang, and C. Guan, "Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b," *Frontiers in Neuroscience*, vol. 6, no. 39, 2012.
- [5] P. Yang, Y. Gao, C. Xu, and D. Yao, "MLP with Riemannian covariance for motor imagery based EEG analysis," *IEEE Access*, vol. 8, pp. 139974–139982, 2020.
- [6] Z. Li, X. Tan, X. Li, and L. Yin, "Multiclass motor imagery classification with Riemannian geometry and temporal–spectral selection," *Medical & Biological Engineering & Computing*, vol. 62, pp. 2961–2973, May 2024.
- [7] X. Li, X. Tang, J. Liu, Q. Liu, H. Wang, and K. Liu, "Parameter transfer and Riemannian space coordinate alignment for EEG intention recognition," *Biomedical Signal Processing and Control*, vol. 92, p. 106044, 2024.
- [8] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. Lance, "EEGNet: A compact convolutional network for EEG-based brain–computer interfaces," *Journal of Neural Engineering*, vol. 15, no. 5, 2018
- [9] A. Raza and M. Z. Yusoff, "Development of a CNN–LSTM Deep Learning Model for Motor Imagery EEG Classification for BCI Applications," *Engineering, Technology & Applied Science Research*, vol. 15, no. 3, pp. 22705–22711, Jun. 2025.
- [10] D. Chen, Y. Zhang, Y. Wang, and X. Li, "An Intersubject Brain–Computer Interface Based on Domain–Adversarial Training of Convolutional Neural Network," *IEEE Transactions on Biomedical Engineering*, vol. 71, no. 10, pp. 2956–2967, Oct. 2024.
- [11] A. Zancanaro, G. Cisotto, I. Zoppis, and S. L. Manzoni, "vEEGNet: Learning latent representations to reconstruct EEG raw data via variational autoencoders," *arXiv preprint arXiv:2312.09449*, 2023.
- [12] Y. Song, D. Wang, K. Yue, N. Zheng, and Z.-J. M. Shen, "EEG–Based Motor Imagery Classification with Deep Multi–Task Learning," in *Proceedings of the 2019 International Joint Conference on Neural Networks (IJCNN)*, Budapest, Hungary, Jul. 2019, pp. 1–8.
- [13] Demir, A., Koike–Akino, T., Wang, Y., Haruna, M., & Erdoganmus, D. (2021). "EEG–GNN: Graph Neural Networks for Classification of Electroencephalogram (EEG) Signals." *arXiv preprint arXiv:2106.09135*.
- [14] A. Demir, T. Koike–Akino, Y. Wang, M. Haruna, and D. Erdoganmus, "EEG–GAT: Graph attention networks for classification of electroencephalogram (EEG) signals," in *Proc. 44th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, Glasgow, UK, Jul. 2022, pp. 2370–2374.
- [15] L. Qiu, J. Li, L. Zhong, W. Feng, C. Zhou, and J. Pan, "A Novel EEG–Based Parkinson’s Disease Detection Model Using Multiscale Convolutional Prototype Networks," *IEEE Transactions on Instrumentation and Measurement*, vol. 73, pp. 1–14, Jan. 2024, doi: 10.1109/TIM.2024.3351248
- [16] Z. Li, X. Tan, X. Li, and L. Yin, "Multiclass motor imagery classification with Riemannian geometry and temporal–spectral selection," *Medical & Biological Engineering & Computing*, vol. 62, pp. 2961–2973, May 2024.