

동작 상상 뇌파 분류를 위한 합성곱 신경망 기반의 전이학습에 관한 연구

송하윤¹, 김동규¹, 김영탁¹, 김학승¹, 김동주^{1,2,3*}

¹ 고려대학교 뇌공학과, ² 고려대학교 의과대학 신경과, ³ 고려대학교 인공지능학과

{hayoonsong, dien200318, kyt3426, mkhsm, dongjookim}@korea.ac.kr

A Study on the Transfer Learning with Convolution Neural Network for Electroencephalogram Based Motor Imagery Classification

Ha-Yoon Song¹, Dong-Kyu Kim¹, Young-Tak Kim¹, Hakseung Kim¹, Dong-Joo Kim^{1,2,3*}

¹Dept. of Brain and Cognitive Engineering, Korea University,

²Dept. of Neurology, College of Medicine, Korea University,

³Dept. of Artificial Intelligence, Korea University

요 약

뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI)는 뇌활성도를 통해 외부기기를 움직이거나 제어하는 기술로, 신체적 기능에 제한이 있는 노약자 및 장애인에게 새로운 움직임 보조수단이 될 수 있다. 최근 딥러닝 기술은 BCI 분야에서 안정적이고 높은 수준의 뇌파(Electroencephalogram, EEG) 특징 추출 및 분류 성능을 보여주었으나, 데이터가 충분하지 않을 경우 학습하는 과정에서 과적합 문제를 초래할 수 있다. 본 논문에서는 합성곱 신경망 기반의 전이 학습을 활용하여 BCI 동작 상상 EEG 를 분류하는 기법을 제안한다. 이를 위해 BCI competition IV-2a 데이터셋에서 대상 사용자의 EEG 데이터를 제외한 나머지 데이터로 합성곱 신경망 모델을 생성하고 대상 사용자의 EEG 데이터를 이용하여 전이학습을 수행하였다. 제안하는 기법은 소규모 데이터만으로 생성된 모델보다 평균 10.8%의 분류 정확도 향상을 이끌어내었다 (64.7%).

I. 서 론

뇌-컴퓨터 인터페이스(Brain-Computer Interface, BCI)는 뇌활동을 통해 외부기기를 움직이거나 제어할 수 있는 새로운 기술이다. 그 중 뇌파(Electroencephalogram, EEG) 기반의 동작 상상(Motor Imagery)을 분류하는 기술은 신체장애가 있는 사람에게 새로운 움직임 보조수단으로 각광받고 있다[1].

기계학습 모델 중 합성곱 신경망(Convolutional Neural Network, CNN)은 이미지 및 음성인식 분야에서 특징 추출 및 분류 알고리즘으로 우수한 성능을 보이면서, 최근 BCI 분야에서도 효과적인 EEG 의 특징 추출 및 분류를 위해 사용되고 있다[2]. CNN 을 학습하기 위해서는 충분한 양의 데이터가 필요하다. 그러나 개인 차의 영향을 받는 BCI 분야에서 대규모 EEG 데이터를 구축하기에는 한계가 있다[3]. 이러한 데이터 부족을 해결하거나 비용 절감을 위한 하나의 방법으로 전이학습(Transfer learning)이 사용된다[4].

전이학습은 사전에 학습이 완료된 모델의 가중치를 초기 가중치로 설정하여, 목적하는 새로운 모델로 가중치를 전이하여 학습하는 기법이다[5]. 전이학습은 비용 절감 뿐만 아니라, 사전 학습된 네트워크의 지식이 새로운 데이터로 전이되어 적은 데이터로도 좋은 성능을 나타낸다는 장점이 있다[6].

본 논문은 대상 사용자를 제외한 나머지 데이터로 학습된 CNN 을 대상 사용자의 데이터로 전이학습한

모델과, 대상 사용자의 데이터만으로 학습한 CNN 모델 사이의 성능을 비교하였다.

II. 본 론

본 논문에서는 비교를 위해 BCI Competition IV-2a 오픈 데이터셋을 사용하였다[7]. EEG 데이터는 9 명의 사용자로부터 22 개의 EEG 채널과 3 개의 안전도(Electrooculography, EOG) 채널로 총 25 채널을 사용하여 기록되었고 250Hz 로 샘플링 되었다. 총 4 클래스(왼손, 오른손, 혀, 양발)로 구성되어 있으며 각 클래스 마다 72 trials 가 제공된다. 이 연구에서는 cue 가 주어진 후 0.5 초부터 2 초간의 EEG 데이터가 사용되었다.




그림 1. 모델의 학습 방법: (a) 일반적인 기계학습 방법
(b) 전이학습 방법




그림 2. 사용자에 따른 분류 정확도

그림 1 은 일반적인 기계학습과 전이학습에서의 모델 학습 방법을 나타낸다. 전이학습의 성능을 비교하기 위하여, 그림 1 (a)와 같이 각 사용자마다 구축된 모델을 기준으로 설정하였다. CNN 기반의 전이학습은 그림 1 (b)와 같이 대상 사용자를 제외한 나머지 사용자들의 데이터를 이용하여 사전 모델을 구축하고, 구축된 사전 모델의 지식 이전(Knowledge transfer)과 함께 대상 사용자의 데이터만을 활용하여 모델을 학습하였다. 이 때, 미세조정을 통해 사전 학습된 CNN 의 모든 층의 가중치를 미세하게 재조정하였다[8].

본 논문에서 사용된 모델인 EEGNet 은 EEG 기반 분류 문제를 위한 경량형 CNN 으로, 적은 데이터셋에서도 좋은 성능을 보여주었다[9]. 최적화 알고리즘으로 Adam(Adaptive moment)을 사용하였으며, 학습률은 0.001 으로 설정하였다. 배치사이즈(Batch Size)와 반복 횟수(EPOCH)를 각각 128, 500 으로 고정하였고, 학습 조기 종료(Early stopping) 함수의 patience 를 50 으로 지정하였고, 각 모델별로 10-fold 교차 검증을 수행하였다.

그림 2 는 전이학습을 여부에 따른 동작상상 분류 모델의 정확도를 보여준다. 전이학습의 효과를 평가하기 위한 기준으로, 대상 사용자의 데이터만을 이용하여 학습된 EEGNet 은 평균 53.89%의 분류 정확도를 보였다. 반면에 다른 사용자의 데이터로 사전 학습하고 대상 사용자의 데이터로 전이학습 시킨 EEGNet 의 경우 평균 64.69 %로 기준점보다 높은 정확도를 보였다.

III. 결 론

본 논문에서는 동작 상상 뇌파 분류의 정확도를 향상시키기 위해 CNN 기반의 전이학습을 제안하였다. 제안하는 방법은 사전 학습 없이 학습된 CNN 모델에 비해 10.8% 이상의 성능 증가를 보였다.

ACKNOWLEDGMENT

This research was supported by the MSIT(Ministry of Science and ICT), Korea, under the ITRC(Information Technology Research Center) support program (IITP-2021-2016-0-00464) supervised by the IITP (Institute for Information & Communications Technology Planning & Evaluation); IITP grant funded by the Korea government (MSIT) (No. 2017-0-00432, Development of non-invasive integrated BCI SW platform to control home appliances and external devices by user's thought via AR/VR interface); National Research Foundation of Korea (NRF) grant funded by the Korean government (Ministry of Science and ICT, MSIT) (No. 2020R1C1C1006773).

참 고 문 헌

- [1] P. Gaur, R. B. Pachori, H. Wang, and G. J. E. S. w. A. Prasad, "A multi-class EEG-based BCI classification using multivariate empirical mode decomposition based filtering and Riemannian geometry," vol. 95, pp. 201–211, 2018.
- [2] A. Craik, Y. He, and J. L. J. J. o. n. e. Contreras-Vidal, "Deep learning for electroencephalogram (EEG) classification tasks: a review," vol. 16, no. 3, p. 031001, 2019.
- [3] Z. Wan, R. Yang, M. Huang, N. Zeng, and X. J. N. Liu, "A review on transfer learning in EEG signal analysis," vol. 421, pp. 1–14, 2021.
- [4] H. Lee, J. Kim, J. Yu, Y. Jeong, and S. J. J. o. K. I. o. I. S. Kim, "Multi-class Classification using Transfer Learning based Convolutional Neural Network," vol. 28, no. 6, pp. 531–537, 2018.
- [5] S. Chung, M. G. J. J. o. I. C. Chung, and Services, "Pedestrian Classification using CNN's Deep Features and Transfer Learning," vol. 20, no. 4, pp. 91–102, 2019.
- [6] D.-K. Kim, Y.-T. Kim, H.-R. Jung, H. Kim, and D.-J. Kim, "Sequential Transfer Learning via Segment After Cue Enhances the Motor Imagery-based Brain-Computer Interface," in *2021 9th International Winter Conference on Brain-Computer Interface (BCI)*, 2021, pp. 1–5: IEEE.
- [7] C. Brunner, R. Leeb, G. Müller-Putz, A. Schlögl, and G. J. I. f. K. D. Pfurtscheller, Graz University of Technology, "BCI Competition 2008- Graz data set A," vol. 16, pp. 1–6, 2008.
- [8] H.-W. Ng, V. D. Nguyen, V. Vonikakis, and S. Winkler, "Deep learning for emotion recognition on small datasets using transfer learning," in *Proceedings of the 2015 ACM on international conference on multimodal interaction*, 2015, pp. 443–449.
- [9] V. J. Lawhern, A. J. Solon, N. R. Waytowich, S. M. Gordon, C. P. Hung, and B. J. J. J. o. n. e. Lance, "EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces," vol. 15, no. 5, p. 056013, 2018.