

합성곱 신경망 기반 뇌파 디코딩을 위한 데이터 증강 기법의 성능 평가

남혜린¹, 권진욱², 임창환^{1,2,3*}

한양대학교 인공지능학과¹

한양대학교 전자공학과²

한양대학교 바이오메디컬공학과³

Performance Evaluation of Data Augmentation Methods for Convolutional Neural Network-based EEG Decoding

Hyerin Nam¹, Jinuk Kwon², and Chang-Hwan Im^{1,2,3*}

¹School of Artificial Intelligence, Hanyang University, Korea

²School of Electronic Engineering, Hanyang University, Korea

³School of Biomedical Engineering, Hanyang University, Korea

*ich@hanyang.ac.kr

Abstract

Recently, deep learning has been widely used as a new approach to improve the overall performance of electroencephalography (EEG)-based classification of mental states and intentions. To address the issues regarding the limited amount of available EEG data, various data augmentation (DA) methods have been actively studied. However, the performance of the currently available DA methods for EEG classification has not been fully validated. In this study, we compared the performances of five DA methods by applying them to convolution neural network (CNN)-based motor imagery classification data.

1. 연구 배경

운동상상(Motor Imagery, 이하 MI)은 정상상태 시각유발 전위(Steady-state visual evoked potential, SSVEP), 사상관련 전위(Event-related potential, ERP) 등과 함께 뇌파(Electroencephalography, EEG) 기반 뇌-컴퓨터 인터페이스(Brain-computer Interface, BCI)에 사용되는 대표적인 패러다임의 한 종류이다. MI 기반 BCI는 사용자가 특정 신체의 운동 상상을 수행할 때 발생하는 뇌파의 변화를 이용하여 사용자의 의도를 파악한다. 예를 들어, 물리적인 움직임 없이 왼손의 움직임을 상상하면 우반구 운동피질에서 특정 주파수 대역 신호의 파워가 감소하는 사상관련비동기화(event related desynchronization, ERD) 현상이 나타나며, 움직임 상상이 끝나면 좌반구 운동피질에서 신호의 파워가 증가하는 사상관련동기화(event related synchronization, ERS) 현상이 발생한다. 이 현상은 발, 혀, 손 등 서로 다른 신체에서 구별이 가능한 양상의 차이를 보이기 때문에, 사용자가 상상한 신체 부위를 인식함으로써 사용자의 의도를 구별할 수 있다. 이러한 이유로, MI로부터 유발되는 EEG는 다양한 의도의 분류가 가능하고, 반응 시간이 상대적으로 짧다는 장점이 있다. 반면에, 역학적인 움직임을 상상하는 것이 익숙하지 않은 사용자를 위한 사전 훈련이 필요할 수 있으며, 다른 EEG 기반 BCI 패러다임들에 비해 분류 정확도가 상대적으로 낮다는 단점이 있다.

최근, 딥러닝(Deep Learning, DL)은 뇌파 기반의 정신 상태 및 의도 분류 기술의 전반적인 성능을 향상시키는 새로운 접근 방식으로 널리 연구되고 있다. 딥러닝의 가장 큰 장점은 계층적 구조 특성으로 종단간 학습(end-to-end learning)이 가능하다는 것이다. 획득한 원 데이터를 별도의 처리 과정 없이 딥러닝 모델에 입력으로 사용하여도 모델은 데이터의 유의미한 특징을 효과적으로 학습하여 기존보다 향상된 분류 성능을 보일 수 있다. 특히 이미지 처리

분야에서 뛰어난 성능을 보이는 합성곱 신경망(Convolutional neural network, CNN)을 EEG 분석에 사용하게 되면, 커널의 크기, 방향에 따라 다양한 시간, 주파수 및 공간 정보를 학습할 수 있기 때문에, BCI를 포함한 다양한 뇌파 기반 기술의 발전에 기여할 수 있을 것으로 기대된다.

하지만 사용가능한 데이터의 양이 풍부한 자연어 처리 및 컴퓨터 비전과 같은 DL의 기존 응용 프로그램 영역과 달리, 일반적으로 DL 모델을 훈련하는 데 사용할 수 있는 EEG 데이터의 양은 매우 제한되어 있다. 이러한 문제를 해결하기 위해 원신호가 포함하는 정보의 왜곡 또는 손상을 최소화하면서 인공 신호를 생성하는 다양한 데이터 증강(Data Augmentation, 이후 DA) 방법이 활발히 연구되고 있다.

EEG 분류를 위해 현재 사용 가능한 DA 방법은 다수 개발되었으나, 그 성능은 완전히 검증되지 않았다. 따라서 본 연구에서는 5가지 DA 방법을 CNN 기반 MI(motor imagery) 분류에 적용하여 그 성능을 비교하였다.

2. 연구 방법

본 연구에 사용된 EEG 데이터는 본 연구실의 이전 연구에서 획득한 데이터의 일부로, 18명의 성인 참가자의 뇌 중앙 영역에 부착한 11개의 전극을 통해 측정되었다[1].




그림 1. 실험 패러다임

이전 연구의 실험에서 참가자들은 오른손 운동 상상 (MI), 암산, 유휴 상태 (Idle state, IS)의 세가지 작업을 수행하였고 본 연구에서는 이 중 MI와 IS의 두 가지 클래스의 EEG 데이터만 사용하였다. 한 피험자는 각 클래스 당 30회씩 작업을 수행하였으며, 작업 1회의 길이는 10초였다. 실험의 패러다임은 그림1과 같다.

본 논문에서는 다음과 같은 다섯가지 종류의 EEG 데이터 증강기법을 구현하였다: 데이터보다 짧은 길이의 윈도우로 데이터를 추출하여 임의의 스텝 크기로 슬라이딩하여 데이터를 증강시키는 윈도우 슬라이딩 방법 (Window sliding, WS), 단시간 푸리에 변환으로 획득한 진폭 스펙트럼에 노이즈를 추가하는 단시간 푸리에 변환 진폭 섭동 방법 (short-time Fourier transform amplitude perturbation, AP), 각 데이터에서 추출한 고주파 성분을 다른 데이터의 진폭 스펙트럼에 노이즈로 추가하는 단시간 푸리에 변환 진폭 고주파 노이즈 추가 방법 (short-time Fourier transform amplitude high-frequency noise adding, ANA), 고속 푸리에 변환 후 임의의 위상을 적용하여 역 고속 푸리에 변환을 적용하여 새로운 인공데이터를 제작하는 고속 푸리에 변환 임의 위상 대체 방법 (fast Fourier transform phase randomized surrogates, PRS), 단시간 푸리에 변환을 통해 시간-주파수 맵을 구성한 후 이를 중첩되지 않은 시간 축에서 임의로 재조합하는 단시간 푸리에 변환 시간-도메인 재조합 방법 (short-time Fourier transform time-domain recombination, TDR)의 5가지 방법을 구현하였다. PRS는 본 논문에서 최초로 DL 기반 EEG 분석에 사용하였다.

WS의 경우 윈도우와 스텝 크기는 일반화되어 있지 않기 때문에 데이터에 최적화된 윈도우와 스텝 크기를 결정하는 과정이 필요하다. AP의 경우 범용적으로 널리 알려진 가우시안 노이즈, salt & pepper 노이즈, speckle 노이즈를 추가하여 각 노이즈에 대한 성능 향상을 비교하여 가장 성능이 좋은 방법의 정확도를 선정하였다. ANA, PRS와 TDR의 경우 기존 데이터의 2배부터 10배까지 증강된 데이터의 양에 따른 정확도를 산출하여 가장 높은 정확도를 선정하였다.

분석에 사용한 DL 모델은 EEGNet으로, EEG 디코딩을 위한 집약적인 합성곱 신경망 모델로 알려져 있다[2]. 모델의 성능 평가를 위해 5 중 (5-fold) 교차 검증을 수행하였다.

3. 연구 결과

그림 2는 DA를 적용하지 않은 원신호와, 다섯가지 DA를 적용하여 인공적인 신호를 추가한 데이터의 평균 분류 정확도를 비교한 것이다. DA를 적용하지 않았을 때 MI, IS에 대한 DL 기반 2-클래스 분류 정확도는 $74.07 \pm 20.75\%$ 이며, 그림 2에서 Real 지표로 표시되었다. 다섯가지 데이터 증강 기법을 각각 적용했을 때의 정확도는 WS, AP, ANA, PRS, TDR이 각각 $88.06 \pm 9.77\%$, $73.70 \pm 19.92\%$, $77.41 \pm 17.20\%$, $79.62 \pm 14.74\%$, $82.13 \pm 7.50\%$ 로 나타났다.

WS의 경우 6초의 윈도우, 0.6초의 스텝 크기를 사용하였다. 이는 본 논문에 사용된 MI-EEG 데이터에 대해 경험적으로 선정한 최적의 값이다. AP의 경우 세 가지 종류의 노이즈 중 가우시안 노이즈가 가장 좋은 성능을 보이는 것을 확인하였다. ANA의 경우 데이터가 기존 데이터의 9배만큼 증강되었을 때 가장 높은 정확도를 보였으며, PRS는 10배 증강되었을 때 가장 높은 정확도를 보였다. TDR의 경우 2배 증강되었을 때 가장 높은 정확도를 달성하여 위의 두 방법과는 대조적으로 증강한 데이터의 양이 가장 적을 때 가장 좋은 결과를 보였다.

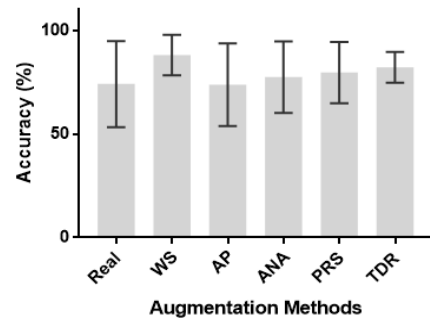


그림 1. 다양한 데이터 증강 기법을 적용했을 때 평균 분류 정확도 비교

Bonferroni correction과 Wilcoxon signed-rank test를 이용한 통계분석에서 WS의 정확도가 Real의 정확도와 유의미한 차이를 보이는 것으로 나타났다($p < 0.05$). TDR, PRS, ANA 방법 또한 유의미한 차이는 보이지 않으나 Real 대비 평균 분류 정확도의 향상을 보였다.

AP 방법을 제외한 모든 방법이 분류 성능을 향상시킬 수 있는 것으로 나타났으며 특히 WS 방법이 성능을 가장 많이 개선시켰다. WS와 TDR 방법은 상대적으로 긴 데이터의 길이를 필요로 한다는 점을 고려할 때 PRS 방법이 DL 기반 EEG 분석에 사용가능한 유망한 DA 방법이 될 것으로 보인다.

추후 본 논문에서 보인 여러 DA 방법을 결합하는 등, 추가적인 성능 개선을 위한 DA 방법에 대한 연구를 진행할 예정이다.

4. Acknowledgements

본 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2019R1A2C2C086593 & NRF-2021M3E5D2A01019547)

5.참고 문헌

- [1] J. Kwon, J. Shin, and C-H. Im, "Toward a compact hybrid brain-computer interface (BCI): Performance evaluation of multi-class hybrid EEG-fNIRS BCIs with a limited number of channels," PLoS ONE, vol. 15, 2020
- [2] Vernon J Lawhern et al, "EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces," J. Neural Eng., vol. 15, 2018