

이미지 기반 뇌파 데이터 분류 딥러닝 모델 연구

유하늘, 서정렬, 손경아
아주대학교

skysky2387@ajou.ac.kr, jrseojr@ajou.ac.kr, kasohn@ajou.ac.kr

Image-based Deep Learning Approach for EEG Signal Classification

Haneul Yoo, Jungyul Seo, Kyung-Ah Sohn
Ajou University.

요 약

본 논문은 뇌파 데이터에 기계학습 기법을 적용하여 상황을 식별하는 연구가 늘어나고 있다. 본 연구는 공개 데이터인 MindBigData 의 The MNIST of Brain Digits 를 스펙트로그램으로 변환하여 특징을 추출하고, CNN 기반의 사전 학습 모델을 이용하여 사용자가 0-9 중 어떤 숫자를 보았는지를 판단하는 모델을 학습했다. 본 연구는 신호처리 기반의 기존 연구에서 벗어나 이미지 기반의 학습 모델을 도입했고 유사한 성능을 보였다는 점에서 그 의의가 있다.

I. 서 론

Brain Computer Interface (BCI) 분야에서 뇌파를 활용하여 감정 인식, 상태 감지 등을 시도한 연구가 늘어나고 있다. 대표적인 예로서, Seo et al. 과 Seo and Sohn 은 각각 뇌파와 기계학습을 활용하여 사용자의 지루한 감정 유무를 식별 [1], 알코올 중독자를 식별하는 모델을 학습하였다 [2]. 또한, 공개된 MindBigData 의 The MNIST of Brain Digits (MBD) [3]을 활용하여, 사람이 어떤 숫자를 보았는지 식별하는 연구도 다수 존재한다. D. Chen et al.은 K-최근접 이웃 알고리즘에 가중치를 두어 학습할 것을 제안했으며 그 정확도는 84%이다 [4]. Bird et al. 은 Adaptive Boosted Multi-Layer Perceptron (MLP)를 제안했으며, 그 정확도는 31%이다 [5]. Jolly et al.은 GRU Network 를 제안했으며 그 정확도는 33%이다 [6].

상기 MBD 데이터셋을 활용한 연구들을 고찰하였을 때, Convolutional Neural Network (CNN) 기반 딥러닝을 활용한 연구가 없었다. 아울러, 사전 연구에서 제안된 모델을 재현함에 있어, D. Chen et al.이 제안한 모델 학습 방법으로 구현된 모델은 논문에 기술된 내용과 달리 성능이 재현되지 아니하였다.

본 연구에서는, MBD 데이터를 CNN 기반 사전 학습 모델을 사용하여, 새로운 모델을 학습을 시도하였으며, 도출된 모델을 본 연구와 동일한 센서로 수집된 데이터로 모델을 학습한, D. Chen et al.의 재현된 모델의 성능과 비교하였다. 본 연구에서 도출된 모델은 다른 사전 연구의 모델들과 비교하여, 성능은 다소 부족하나, 현재로서 MBD 데이터셋의 뇌파 데이터를 이미지로 전환 후 모델 학습에 사용한 전례가 없으므로, 본 연구에서는 이를 제안하고자 한다.

기타 사물을 2 초간 보았을 때의 뇌파를 수집하였다. 각 센서는 각기 다른 수의 전극을 사용하여 뇌의 각 부분에서 뇌파를 수집하였으며, 전극의 수는 MindWave 1 개, EPOC 14 개, Muse 4 개, Insight 는 5 개이다.

표 1. MBD 데이터셋에서의 센서별 샘플

센서	"0" ~ "9" 샘플 (평균/표준편차)	기타 샘플 수
MindWave	5493.4 (58.71)	12701
EPOC	90825 (1374.97)	2226
Muse	11952 (236.53)	44412
Insight	6525 (115)	0

본 연구에서는 MBD 중 Emotiv 의 Insight 를 사용하여 측정된 데이터를 실험에 사용하였다. 그 이유는 상기 표 1 에서 나타난 것과 같이, 숫자를 본 샘플 수의 표준편차 값이 EPOC 와 Muse 센서로 수집한 샘플들의 표준편차가 낮아, 좀더 고르게 샘플들이 분포되어 있어, 도출되는 모델의 견고함을 향상하고자 하였다. MindWave 로 수집한 샘플의 경우, Insight 보다 낮은 표준편차 값을 보여주나, 사용된 전극의 수가 1 이므로, 본 연구에서는 Insight 로 수집된 뇌파를 사용하였다.

또한 MBD 데이터를 사용한 사전 연구에서는, Bird et al. 과 Jolly et al. 은 Muse 로 수집한 데이터를 사용하였으며, Chen et al.은 본 연구와 동일한 Insight 로 수집한 데이터를 사용하였다[4-6].



그림 1. 데이터 전처리 예시

II. 연구 방법

1. MBD 데이터셋

MBD 데이터셋은 총 4 종류의 뇌파 센서를 사용하여 수집된 데이터를 포함한다. 각 피험자가 0~9 숫자와

2. 데이터 전처리 및 모델 학습

본 연구에서는 정확한 실험을 위해 데이터의 95%인 243 개 이상의 값이 존재하는 데이터 중 가운데 부분만을 사용했다. Librosa 라이브러리를 활용하여 뇌파 신호인 MBD 를 이미지 형태인 로그 배율의 스펙트로그램 (Spectrogram)으로 변환하였고, 시점을 고려하여 각 채널별로 이미지를 수평으로 병합했다. 상기 그림 1 은 뇌파 데이터를 CNN 으로 모델 학습시키기 위한 전처리 과정을 보여준다.

이후 위 데이터를 CNN 계열의 사전 학습 모델인 VGG16 과 ResNet101 를 사용하여 학습했다. VGG16 이후의 완전 연결 레이어의 깊이를 다르게 하며 모델을 학습했다. 마지막으로 채널별로 모델을 구현하고 이를 앙상블하여 기존 모델과 결과를 비교했다. 본 연구에서는 데이터를 학습 80%, 검증 10%, 테스트 10%로 나누어 학습을 진행했다.

III. 결과

표 2. 사용 알고리즘에 따른 정확도 비교

사용 알고리즘	데이터 형태	정확도 (%)
무작위 선택	신호	10.00
Chen et al.	신호	11.24
VGG16	이미지	21.85
ResNet101	이미지	18.39

본 연구 문제의 경우 분류 클래스가 0-9 의 숫자로 총 10 개이다. 따라서 어떤 모델이 무작위로 결과값을 맞힌다고 할 때 그 정확도는 10%라고 할 수 있다. 이때, D. Chen et al.에서 제안한 K-최근접 이웃 알고리즘의 경우 11.24%의 정확도에 그쳤다. 반면에 이를 본 연구에서 제안하는 방법대로 이미지 형태의 스펙트로그램으로 변환하여 학습한 모델의 성능이 더 좋은 것을 알 수 있다. CNN 계열 사전 학습 모델인 VGG16 과 ResNet101 을 사용한 모델의 결과는 각각 21.85%와 18.39%로 기존 모델보다 뛰어난 성능을 보인다.

표 3. 연결 레이어 깊이에 따른 정확도 비교

연결 레이어 개수	정확도 (%)
VGG16 에 연결 레이어 4 개 사용	21.85
VGG16 에 연결 레이어 2 개 사용	15.60

VGG16 을 기준으로 할 때 그 이후에 연결하는 레이어의 깊이를 다르게 하며 더 나은 결과를 보이는 조건을 찾았다. 연결 레이어의 개수가 2 개일 때보다 4 개일 때 21.85%의 정확도로 더 좋은 성능을 보였다. 이는 MBD 가 충분히 큰 데이터이기에 연결 레이어를 깊게 하여 많은 변수를 학습할 수 있기 때문이라고 추정한다.

표 4. 앙상블 기법 적용에 따른 정확도 비교

앙상블 기법 적용 여부	정확도 (%)
기존 VGG16	21.85
VGG16 에 앙상블 기법 적용	23.47

앙상블 기법을 적용할 때의 정확도는 23.47%로, 기존 모델에 비해 성능이 소폭 개선된 것을 확인할 수 있다. 다만, 앙상블 기법에서는 채널별로 모델을 구성하였기에 기존 모델에 비해 학습 속도가 느리고 학습 시 요구되는 메모리가 크다는 단점이 있다.

IV. 결 론

본 논문에서는 MBD 를 스펙트로그램으로 변환했고 CNN 계열의 사전 학습 모델을 사용하여 모델을 학습했다. 그중 VGG16 을 사용했을 때의 정확도는 21.85%로, 선행 연구를 바탕으로 선정된 기준 모델인 K-최근접 이웃 알고리즘의 정확도가 11.24%였다는 것을 고려한다면 상당히 좋은 성과이다. 따라서 뇌파 데이터를 이미지로 변환하여 학습하는 것이 성공적인 접근법임을 알 수 있다. 또한, 뇌파 데이터를 이미지로 변환하게 된다면 다양한 기존 사전 학습 모델을 사용할 수 있다는 장점도 있다. 본 연구에서는 다양한 CNN 계열 사전 학습 모델을 시도하여 정확도를 비교하고, 연결 레이어의 깊이를 다르게 하고 앙상블 기법을 시도하며 성능을 개선했다. 또한, Bird et al. 과 Jolly et al.이 제안한 모델 성능과 본 연구에서 제안하는 모델과의 성능을 비교 시, 다소 부족한 것이 사실이나, 모델을 학습 시 사용한 데이터가 다르므로, 직접적인 비교가 어렵다.

향후 후속 연구에서는, 채널 별 모델의 성능을 비교하여 어떤 채널이 MBD 를 활용한 숫자 분류에 큰 영향을 미치는지 파악하고, 주요한 영향을 주는 채널만을 앙상블하는 연구로 확장하고자 한다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW 중심대학사업의 수행결과로 추진되었음(2015-0-00908)

참 고 문 헌

- [1] Seo, J, Laine, T.H. and Sohn, K. "Machine learning approaches for boredom classification using EEG", Journal of Ambient Intelligence and Humanized Computing, 2019.
- [2] Seo, J. and Sohn, K. "Alcoholic classification model using EEG", in Proceedings of Korea Software Congress 2018, Pyeongchang, Republic of Korea.
- [3] "MindBigData", <http://www.mindbigdata.com/opendb/>
- [4] D. Chen, W. Yang, L. Huang, L. Zhang and C. Deng, "Novel joint algorithm based on EEG in complex scenarios", Computer Assisted Surgery, 24(2):117-125, 2019.
- [5] J. J. Bird, D. R. Faria, L. J. Manso, A. Ekárt and C. D. Buckingham, "A Deep Evolutionary Approach to Bioinspired Classifier Optimisation for Brain-Machine Interaction", Complexity, 2019.
- [6] B. L. K. Jolly, P. Aggrawal, S. Nath, V. Gupta, M. Grover and R. R. Shah, "Universal EEG Encoder for Learning Diverse Intelligent Tasks", in IEEE Fifth International Conference on Multimedia Big Data, 2019.