

효율적인 수면단계 분류를 위한 딥러닝 모델 압축 연구

허재욱¹, 이철희¹, 김학승¹, 김동주^{1,2,3*}

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

{kinik33, dlcfjgmlnasa28, mkhsm, dongjookim}@korea.ac.kr

Efficient Sleep Stage Classification Based on Deep Learning Using Model Compression

Jae-Wook Heo¹, Choelhui Lee¹, 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

수면단계는 수면장애의 진단에 있어 중요한 지표로 사용된다. 수면단계 진단의 검사자 의존성 및 많은 시간소요를 해결하기 위해 딥러닝 연구가 활발하게 이루어지고 있지만, 아직까지 생체신호 수집의 낮은 접근성으로 인해 많은 사람이 수면장애를 진단받지 못한 채로 남아있으며, 딥러닝 모델의 경량화를 통한 웨어러블 디바이스의 탑재가 이에 대한 해결방안으로 떠오르고 있다. 본 논문은 수면단계 분류를 위한 딥러닝 모델의 경량화를 위해 두 단계의 모델 압축 기법을 제안한다. 해당 압축기법을 통해 높은 성능을 유지하며 모델의 파라미터 수를 획기적으로 줄여 모델을 경량화 시킬 수 있다. 실험 결과, 압축을 통해 모델의 파라미터 수를 약 85.6% 줄일 수 있었으며, 압축된 모델은 기존 모델에 비해 약 12%의 분류 속도 향상을 보였다.

I. 서 론

수면단계는 수면장애의 진단에 있어 중요한 지표로 사용되지만, 수면다원검사를 통한 수면단계 분류는 시간이 많이 걸리고 힘든 과정일 뿐만 아니라 평가자의 숙련도 및 주관에 따라 영향을 받을 수 있다는 문제가 있다. [1] 최근에는 이러한 문제점을 해결하고자, 딥러닝 방법론을 적용한 수면단계 분류 연구가 활발하게 이루어지고 있지만, 여전히 생체신호 수집의 낮은 접근성으로 인해 많은 사람들이 수면장애를 진단받지 못한 채로 남아있다.

모델압축 기법은 많은 파라미터를 가지는 딥러닝 모델의 경량화를 통해 웨어러블 디바이스 탑재를 가능케 하여 수면단계 분류의 접근성을 크게 높일 수 있다. 그럼에도 불구하고, 아직 수면단계 분류를 위한 딥러닝 모델을 압축하려는 시도는 관련 연구가 부족한 상태이다. [2]

본 논문에서는 분류 정확도가 높지만, 모델의 크기가 큰 딥러닝 모델인 DeepSleepNet 에 두 단계의 압축 기법을 적용하여 수면단계를 분류하였으며, 압축정도에 따른 분류 성능과 모델 크기에 대한 고찰을 진행하였다. [3]

II. 본론

본 논문에서는 수면단계 분류를 위한 딥러닝 모델인 DeepSleepNet 이 CNN(Convolutional neural network) 층으로 이루어진 representation learning 부분과 LSTM(Long short-term memory) 층으로 이루어진 sequential residual learning 부분으로 나뉘어진 점에

착안하여 다음과 같은 두 단계의 압축기법을 제안한다.

1 단계에서는 채널 가지치기 기법을 이용하여 representation learning 부분의 각 층에서 중요도가 낮은 채널의 가중치를 제거하여 파라미터 수를 줄인 후 재학습을 하여 가중치의 미세조정을 진행한다. 2 단계에서는 1 단계에서 학습된 모델의 LSTM 층의 hidden state 수를 줄여가며 재학습을 하여 파라미터 수를 줄이고, 가중치의 미세조정을 진행한다. [4]

모델의 성능평가를 위해 PhysioNet 의 Sleep-EDF-39 데이터베이스를 wake, REM(Rapid eye movement), N1, N2, N3 의 5 클래스로 나누어 분류를 진행하였다. [5, 6] 데이터는 100Hz 로 기록되었으며, Fpz-Cz 채널을 학습에 사용하였다. 해당 데이터셋을 subject 단위로 train set, validation set, test set 을 나누어 학습을 진행하였으며, 사용된 최적화 기법은 AdamW 이고, 학습률은 0.0001 으로 설정하였다. 1 단계 압축의 가지치기는 각 층별로 L1 norm 최소화를 통해 5% 단위로 가지치기를 진행하였다. 2 단계 압축은 1 단계 압축의 압축률이 0%, 20%, 40%, 60%, 80% 인 모델들에 대하여 진행되었으며, LSTM 층은 hidden state 수를 128 씩 줄이며 학습을 진행하였다.




그림 1. 1 단계 압축 정도에 따른 정확도 및 f1 점수

그림 1은 1 단계 압축을 진행한 모델의 압축 정도와 성능 사이의 상관관계를 나타낸다. 압축의 진행에 따른 눈에 띄는 성능저하가 발견되지 않는 것을 확인할 수 있다. 1 단계 압축 정도가 0%, 20%, 40%, 60%, 80%인 모델들에 대하여 2 단계 압축을 진행하였다.




그림 2. 압축모델의 파라미터 수에 따른 정확도의 변화. 붉은 선은 기존 모델의 95% 정확도를 나타낸 선이다.

그림 2는 2 단계 압축까지 진행한 모델들의 파라미터 수에 따른 정확도를 나타낸다. 전체 압축 모델 중 5% 이상의 성능 저하가 있는 모델은 7 개에 불과하며, 특히 압축 정도가 가장 높은 모델의 경우, 압축이 진행되지 않은 기존모델에 비해 1.8% 정도의 정확도 하락만이 발견되었다.

III. 결론

본 논문에서는 수면단계 분류를 위한 딥러닝 모델에 두 단계의 모델 압축 기법의 적용을 제안하였다.

압축 정도가 가장 높은 모델과 기존모델 사이의 분류 속도 및 모델의 파라미터 수를 비교한 결과, 기존모델에 비해 압축모델의 분류 속도가 12% 정도 빠르며 모델의 파라미터 수를 약 85.6% 줄일 수 있음을 확인하였다.

수면단계 분류 연구에서 모델 압축은 모델 성능을 유지하며 모델의 크기를 획기적으로 줄일 수 있는 것으로

보이며, 더 많은 데이터 및 다양한 압축 조건에서 모델 압축의 효용성을 검증하고, 최적의 압축 조건을 찾는 후속연구가 필요하다.

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] 김형욱, 이영록, and 박동규, "안전도, 뇌파도, 근전도 분석을 통한 수면 단계 분류," 멀티미디어학회논문지, vol. 22, no. 12, pp. 1491-1499, 2019
- [2] R. Duggal, S. Freitas, C. Xiao, D. H. Chau, and J. Sun, "REST: Robust and efficient neural networks for sleep monitoring in the wild," in Proceedings of The Web Conference 2020, 2020.
- [3] A. Supratak, H. Dong, C. Wu, and Y. Guo, "DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG," arXiv [stat.ML], 2017.
- [4] H. Li, A. Kadav, I. Durdanovic, H. Samet, and H. P. Graf, "Pruning Filters for Efficient ConvNets," arXiv [cs.CV], 2016.
- [5] A. L. Goldberger et al., "PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals: Components of a new Research Resource for Complex Physiologic Signals," Circulation, vol. 101, no. 23, pp. E215-20, 2000.
- [6] B. Kemp, A. H. Zwinderman, B. Tuk, H. A. Kamphuisen, and J. J. Oberyé, "Analysis of a sleep-dependent neuronal feedback loop: the slow-wave microcontinuity of the EEG," IEEE Trans. Biomed. Eng., vol. 47, no. 9, pp. 1185-1194, 2000.