

딥러닝을 이용한 뇌파 기반 VR 사이버 멀미 상태 분류

박재현¹, 임창환^{1,2}

¹한양대학교 인공지능학과, ²한양대학교 바이오메디컬공학과

EEG-based VR Motion Sickness Classification Using Deep Learning

Jaehyun Park¹, Chang-Hwan Im^{1,2}

¹Department of Artificial Intelligence, Hanyang University, ²Department of Biomedical Engineering, Hanyang University

*ich@hanyang.ac.kr

Abstract

Cybersickness causes nausea and dizziness in exposure to a virtual reality (VR) environment and it is considered important to dig deeper into how to deal with cybersickness affecting the user experience in VR. Electroencephalography (EEG) has been used to capture changes in brain responses related to motion sickness and to classify cybersickness with the deep learning algorithms learning temporal and spatial representations. This study deals with the application of deep learning frameworks used for EEG analysis to the classification of VR cybersickness. ShallowFBCSPNet and TSception were employed for the detection of VR cybersickness in a subject-independent manner. From the datasets from 26 subjects with 16 males and 10 females, our study compared subject-independent classification accuracies from two different models with additional networks. The results showed that the TSception outperforms ShallowFBCSPNet with motion-sickness-related EEG datasets.

1. 연구 배경

최근 딥러닝 기법을 활용한 뇌파 기반의 사이버 멀미 측정을 위한 다양한 방법론들이 연구되고 있다. 전통적인 머신러닝 기법으로 SVM 등이 적용된 연구에서 더 나아가 CNN, LSTM 등 딥러닝 기법을 적용하여 모델 성능과 분류 정확도를 높이고자 하는 연구[1]가 수행되고 있다. 또한, 사이버 멀미 측정 관련 연구 중 개별 사용자 데이터 내에서 학습 및 결과 분석을 진행하는 경우, 동일한 사용자에서 획득한 뇌파 데이터의 특성에 따라 데이터 분포에 영향을 받지 않아 높은 분류 정확도가 보고되는 연구 결과를 찾아볼 수 있다. 하지만 여러 사용자의 뇌파 데이터를 종합하여 학습한 모델을 다른 사용자의 뇌파 데이터에 적용하였을 때 높은 분류 성능의 결과를 보이기 어렵다는 한계점이 존재한다. 본 연구에서는 뇌파 데이터 분석에서 사용되고 있는 BrainDecode toolbox의 ShallowFBCSPNet 모델 및 사용자의 감정 인식에 활용된 최근 방법인 TSception 모델을 사이버멀미 데이터에 적용하여 분류 성능 향상의 가능성을 확인하였다.

2. 연구 방법

본 실험에서는 총 35 명 (남: 19 명, 여: 16 명)의 참가자를 모집하여 사이버 멀미 측정 실험을 진행하였다. 실험 과정은 다음과 같이 진행되었다. 먼저, 뇌파 데이터 측정을 위해 실험 참가자의 두피 표면에 32 개의 전극을 부착한 후, VR 헤드셋 착용을 진행하였다. 실험 참가자는 의자에 앉아 헤드 마운트 디스플레이(HMD, Head Mounted Display) 형태의 HTC VIVE VR 헤드셋을 착용한 상태에서 미리 제작한 360 도 롤러코스터 동영상을 통해 가상의 롤러코스터를 체험하는 방식으로 실험이 진행되었다. 원활한 실험 환경을 위해 실험 참가자가 의자에 앉아 VR 헤드셋을 착용한 상태에서 화면의 화질 및 수평 조절을 진행하였다.

미리 제작한 360 도 롤러코스터 동영상의 경우, 총 15 분 길이로 제작하였으며, 첫 5 분은 안정 상태에서 시작하여 이후 5 분 간격으로 점차 멀미가 유발될 수 있는 형태로 구성되었다. 0 단계 구간(0~5 분)의 경우, 멀미 유발이 일어나지 않는 형태로 제작되었으며, 1 단계 구간 (5~10 분) 및 2 단계 구간 (10~15 분)의 경우, 멀미가 유발될 수 있는

구간으로 제작되었다. 실험 진행 시, 각 참가자마다 멀미에 대한 민감도가 다를 수 있음을 고려하여, 참가자 본인이 멀미를 심하게 느껴 VR 롤러코스터 체험을 지속하기 어렵다고 판단하는 경우 실험을 종료하는 방식으로 진행되었다. 실험 시작 전 과 종료 후에는 설문 방식(참조)을 통해 실험 참가자의 멀미 상태를 조사하였다.

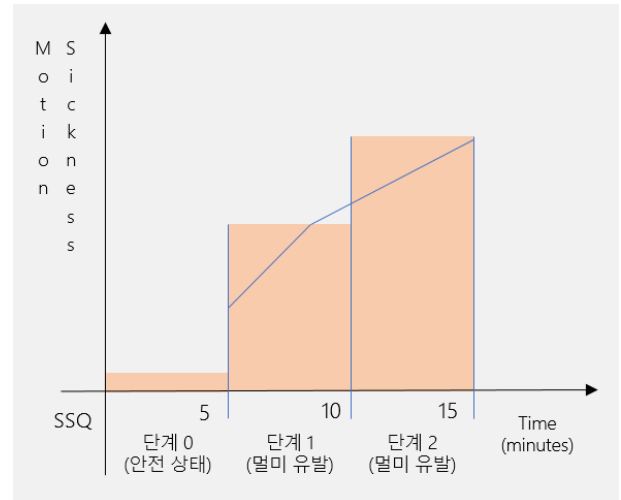


그림 1: VR 롤러코스터 동영상 단계별 멀미 유발 정도

3. 데이터 분석

사이버 멀미 측정 실험을 통해 획득한 각 개인별 뇌파 신호에 대하여 고역 차단 주파수가 1 Hz 이고 저역 차단 주파수가 50 Hz 인 3 차 butterworth 대역통과필터를 사용하여 잡음 신호를 제거하였고, 3 차 60 Hz 및 120 Hz 노치 필터를 이용하여 전원 잡음을 제거하였다. 또한, 실험에서 측정된 각 참가자의 뇌파 신호에 대하여, 1 초 길이의 슬라이딩 윈도우를 적용하여 2 초 길이의 여러 개의 신호로 중첩하여 분할한 뒤, 32 개의 전극 채널에 대하여 신호의 진폭이 100 μ V 기준에 부합하는 데이터를 추출하였다.

전체 35 명의 실험 참가자의 뇌파 데이터에 대해서 딥러닝 알고리즘에 적용하여 분류 학습 및 결과 분석에 사용할 수 있는 참가자 데이터를 취합하는 과정을 진행하였다. 뇌파 전처리 과정에 따라 0 단계에서 사용 가능한 데이터 및 실험 전후 SSQ 점수 차이에 따라 선택된 1 단계 또는 2 단계 구간에서 사용 가능한 데이터가 없는 경우에 해당하는 2 명의 실험 참가자의 데이터는 학습 및 결과 분석에서 제외하였다. 또한, 실험 시작 전과 종료 후 조사한 SSQ 점수 차이가 10 미만인 경우에 해당하는 경우 무증상으로 분류하여 3 명의 실험 참가자의 데이터는 학습 및 결과 분석에서 제외하였다. 전체 35 명의 참가자 데이터 중 사용 가능한 데이터가 없거나 무증상으로 분류되어 제외된 인원 이외에 총 30 명의 참가자 데이터를 추출하였다.

30 명의 각 실험 참가자에 대하여 실험 시작 전과 종료 후 진행한 멀미 상태 설문 (SSQ, Simulator Sickness Questionnaire) 결과를 기반으로 실험 전후 SSQ 점수 차이[2]에 따라 멀미 민감도를 다르게 규정하여, 실험 진행 시 멀미 유발에 해당하는 1 단계 구간 또는 2 단계 구간에서 측정된 데이터 중 하나를 선택하여 사용하였다. 실험 전후 SSQ 점수 차이가 20 미만인 경우 개인의 멀미 민감도가 상대적으로 낮은 것으로 규정하여 2 단계 구간에 해당하는 뇌파 데이터를 선택적으로 사용하였으며, 실험 전후 SSQ 점수 차이가 20 이상인 경우 개인의 멀미 민감도가 상대적으로 높은 것으로 규정하여 1 단계 구간에 해당하는 뇌파 데이터를 선택적으로 사용하였다.

SSQ Score	Categorization
0	No symptoms
<5	Negligible symptoms
5-10	Minimal symptoms
10-15	Significant symptoms
15-20	Symptoms are a concern
>20	A bad simulator

표 1: SSQ Score.

또한, 30 명의 참가자에 대하여 두 단계의 구간에서 측정된 데이터 개수 중 60 개 (1 분 길이) 미만인 것에 해당하는 4 명의 참가자의 데이터는 학습 및 결과 분석에서 제외하였다.

총 26 명의 실험 참가자 데이터를 딥러닝 모델을 활용한 학습 및 분석에 사용하였다. 딥러닝 알고리즘을 사용한 데이터 분류 학습 및 결과 분석에 사용한 26 명의 참가자 데이터에 대하여, 2 개의 구간 (안정 상태에 해당하는 0 단계 및 멀미 유발에 해당하는 1 단계 또는 2 단계) 내에서 분석에 사용될 데이터를 선택하는 과정을 추가로 진행하였다. 멀미 유발이 없는 0 단계 구간에서 측정된 뇌파 데이터의 경우, 전반부에 측정된 데이터를 사용하였으며, 멀미 유발이 있는 1 단계 또는 2 단계 구간에서 측정된 뇌파 데이터의 경우, 후반부에 측정된 데이터를 사용하였다.

4. 딥러닝 모델

본 연구에서는 뇌파 신호 기반 멀미 상태 분류 학습 및 결과 분석을 위한 딥러닝 모델로서 ShallowFBCSPNet,[3] TSception[4] 모델을 사용하여 진행하였다.

ShallowFBCSPNet (Schirmermeister et al., 2017) 모델은 종단간(end-to-end) 학습 방식 기반의 합성곱 신경망 딥러닝 기법 (deep ConvNets)을 바탕으로 뇌파 신호의

디코딩 정확도를 높이기 위한 목적으로 설계된 모델 구조이다. 해당 네트워크는 시간 축에 대한 컨볼루션 필터와 공간(채널) 축에 대한 컨볼루션 필터와 함께, 높은 디코딩 정확도에 기여하는 배치 정규화(batch normalization) 및 지수 선형 함수(ELU, Exponential Linear Units)가 사용되었다.

TSception (Ding et al., 2020) 모델은 뇌파 신호를 기반으로

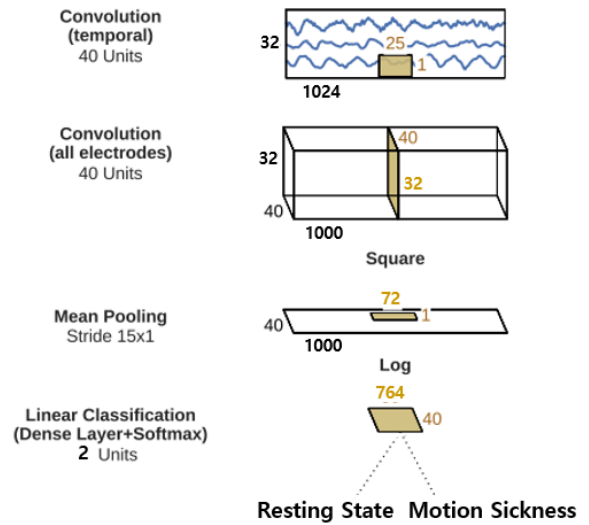


그림 2: Structure of ShallowFBCSPNet.

감정 상태 분류를 위해 설계된 모델이다. 시간과 공간 축에 대한 합성곱층(convolution layers)을 기반으로, 시간 축에 대해서 주파수 특징을 추출하였으며, 공간 축에 대해서 좌반구와 우반구에서 특징을 추출하는 방식이다.

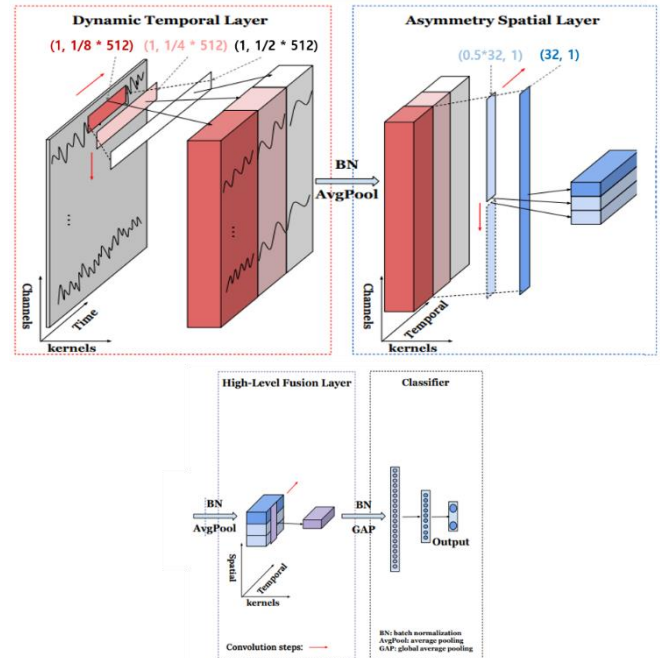


그림 3: Structure of TSception.

5. 연구 결과

최종적으로 26명(남: 16명, 여: 10명)의 실험 참가자 데이터를 딥러닝 알고리즘에 적용하였으며 진행 과정은 다음과 같다. 25명의 실험 참가자의 뇌파 데이터를 사용하여

분류 학습을 진행하여 학습 모델을 생성하고, 나머지 1명의 실험 참가자의 뇌파 데이터를 학습 모델에 적용하여 멀미 상태에 대한 분류 정확도를 분석하는 방식으로 진행되었으며, 26명의 실험 참가자의 뇌파 데이터에 대하여 같은 방식으로 적용하여 각각 분류 정확도를 분석하였다.

본 연구에서 진행한 VR 사이버 멀미 측정 실험을 통해 획득한 뇌파 데이터를 ShallowFBCSPNet과 TSception 두 모델에 적용하였으며, 또한 기존 두 모델에 SENet (Squeeze-and-Excitation Networks), scSENet (Concurrent Spatial and Channel Squeeze and Channel Excitation Networks) 모델을 추가하여 분류 정확도를 측정된 결과를 비교 분석하였다.

먼저, TSception 모델을 적용했을 때의 분류 정확도가 ShallowFBCSPNet 모델을 적용했을 때와 비교하여 더 향상되는 것을 확인할 수 있었다. TSception 모델이 ShallowFBCSPNet 모델과 비교하여 갖는 특징은 다음과 같다. TSception 모델 구조는 시간 도메인에 대하여 multi-scale 컨볼루션 필터 적용을 통해 여러 시간 정보 및 주파수 정보에 대한 특징을 병합하는 방식과 함께, 공간(채널) 도메인에 대해서 전체 전극 채널의 수에 해당하는 크기의 필터로 특징을 추출하며, 절반의 크기에 해당하는 필터를 사용하여 좌반구와 우반구에 위치한 전극 채널에 대해서도 특징을 추출하는 방식을 적용하여 더 높은 분류 정확도를 보인 것으로 판단한다.

TSception 모델 적용 시, 32개의 전극 채널의 순서를 좌반구와 우반구 형태(전극 채널 순서 B 형태)로 재배열하여 진행하였으며, 좌반구와 우반구에 쌍으로 존재하는 각각의 전극 채널의 순서를 인접시키는 형태(전극 채널 순서 A 형태)로 배열하여 분류 성능의 차이 여부를 확인하는 과정도 함께 진행하였다.

또한, TSception 모델에 SENet[5]과 scSENet[6] 모델을 추가하였을 때의 정확도가 더 높은 것을 확인할 수 있었다. 이를 통해 TSception 모델에 SENet 또는 scSENet 네트워크를 결합한 형태의 구조가 멀미 상태 분류에 활용될 수 있는 가능성을 확인하였다.

정보통신기술진흥센터의 지원을 받아 수행된 연구임 (2017-0-00432)

7. 참고 문헌

[1] Liao, C. Y., Tai, S. K., Chen, R. C., & Hendry, H. (2020). Using EEG and deep learning to predict motion sickness under wearing a virtual reality device. *IEEE Access*, 8, 126784-126796.

[2] Stanney, K. M., Kennedy, R. S., & Drexler, J. M. (1997, October). Cybersickness is not simulator sickness. In *Proceedings of the Human Factors and Ergonomics Society annual meeting* (Vol. 41, No. 2, pp. 1138-1142). Sage CA: Los Angeles, CA: SAGE Publications.

[3] Schirrmester, R. T., Springenberg, J. T., Fiederer, L. D. J., Glasstetter, M., Eggenberger, K., Tangermann, M., ... & Ball, T. (2018). Deep learning with convolutional neural networks for brain mapping and decoding of movement-related information from the human EEG. *arXiv preprint arXiv:1703.05051*.

[4] Ding, Y., Robinson, N., Zhang, S., Zeng, Q., & Guan, C. (2021). Tsception: Capturing temporal dynamics and spatial asymmetry from EEG for emotion recognition. *arXiv preprint arXiv:2104.02935*.

[5] Hu, J., Shen, L. and Sun, G. Squeeze-and-excitation networks. In CVPR 2018.

[6] Roy, A. G., Navab, N., & Wachinger, C. (2018, September). Concurrent spatial and channel 'squeeze & excitation' in fully convolutional networks. In *International conference on medical image computing and computer-assisted intervention* (pp. 421-429). Springer, Cham.

Subject-Independent EEG-based VR Motion Sickness Classification Accuracy

Model	Electrode Scan Order (A)			Electrode Scan Order (B)		
	Accuracy	Specificity	Sensitivity	Accuracy	Specificity	Sensitivity
ShallowNet	70.98%	78.70%	63.26%	71.57%	75.99%	67.16%
ShallowNet w/ SE-Net (1 Block)	70.78%	71.55%	70.02%	69.92%	74.51%	65.34%
ShallowNet w/ scSE-Net (1 Block)	69.21%	78.45%	59.96%	69.65%	68.74%	70.56%

표 2: ShallowFBCSPNet 모델 분류 정확도 결과

Subject-Independent EEG-based VR Motion Sickness Classification Accuracy

Model	Electrode Scan Order (A)			Electrode Scan Order (B)		
	Accuracy	Specificity	Sensitivity	Accuracy	Specificity	Sensitivity
TSception	73.77%	71.79%	75.76%	72.52%	72.82%	72.58%
TSception w/ SE-Net (1 Block)	73.72%	72.27%	75.35%	72.69%	74.07%	71.59%
TSception w/ scSE-Net (1 Block)	74.38%	74.99%	74.25%	73.87%	73.21%	74.28%
TSception w/ SE-Net (3 Block)	75.93%	73.33%	76.97%	75.32%	76.18%	73.97%
TSception w/ scSE-Net (3 Block)	75.50%	75.65%	76.11%	76.20%	73.55%	77.59%

표 3: TSception 모델 분류 정확도 결과

6. Acknowledgements

이 논문은 2017년도 정부(과학기술정보통신부)의 재원으로