

가상현실에서의 개인 맞춤형 사이버멀미 선제적 예측 모델 개발

(Development of a Personalized Early Prediction Model for Cybersickness in Virtual Reality)

최 윤 선[†] 정 다 영^{††} 김 보 관[†] 한 경 식^{†††}
(Yoonseon Choi) (Dayoung Jeong) (Bogoan Kim) (Kyungsik Han)

요 약 가상현실(Virtual Reality, VR) 사용성을 저해하는 사이버멀미 현상을 완화하기 위해 최근 연구들은 인공지능 기반의 사이버멀미 예측 모델을 제안해 왔으나, 대부분은 사용자가 사이버멀미를 경험한 후 적용되어 선제적 대응에는 제한적이다. 또한, 사이버멀미 측정 지표인 Fast Motion Sickness Scale (FMS)은 사용자마다 상대적일 수 있어, 개인화된 모델의 중요성이 강조된다. 본 논문은 Head Mounted Display (HMD) 센서 데이터를 기반으로, 장기 시계열 예측 모델인 PatchTST를 활용한 사이버멀미 선제적 예측 모델을 제안한다. 실험 결과, MAE 0.14, RMSE 0.67로 baseline 모델에 준하는 성능을 보였다. PatchTST의 활용 가능성을 바탕으로 개인 맞춤형 모델을 개발하였으며, Accuracy 0.71을 달성하였다. 이는 장기 시계열 예측 모델을 활용한 사이버멀미 선제적 예측과 개인 맞춤형 모델 발전의 가능성을 시사한다.

키워드: 사이버멀미, PatchTST, HMD 센서 데이터, 선제적 예측, 개인 맞춤형 모델

Abstract To mitigate cybersickness, which disrupts the usability of virtual reality (VR), recent studies have proposed prediction models using artificial intelligence. However, most of these models can only be applied after users have experienced cybersickness, limiting their usefulness for proactive response. The importance of personalized cybersickness prediction models is underscored by the fact that the Fast Motion Sickness Scale (FMS), an indicator for measuring cybersickness, is somewhat subjective for each individual. This paper proposes a model for the early prediction of cybersickness based on sensor data from a Head Mounted Display (HMD), utilizing a long-term time-series forecasting model called PatchTST. The experimental results demonstrate that the proposed model achieved performance comparable to the baseline models, with a mean absolute error (MAE) of 0.14 and a root mean square error (RMSE) of 0.67. By leveraging PatchTST's the potential for early prediction, we developed a personalized model that achieved an accuracy of 0.71. These results suggest the feasibility of an early prediction model for cybersickness and highlight the potential for developing personalized models.

Keywords: cybersickness, PatchTST, HMD sensor data, early prediction, personalized model

· 이 논문은 2024년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No.RS-2020-II201373, 인공지능대학원 지원(한양대학교)).
· 이 논문은 2024 한국컴퓨터종합학술대회에서 '장기 시계열 예측 모델을 활용한 가상현실에서의 사이버멀미 선제적 예측'의 제목으로 발표된 논문을 확장한 것임

논문접수 : 2024년 8월 30일

(Received 30 August 2024)

논문수정 : 2024년 11월 11일

(Revised 11 November 2024)

심사완료 : 2024년 11월 11일

(Accepted 11 November 2024)

[†] 학생회원 : 한양대학교 데이터사이언스학과 학생

yoonseonchoi@hanyang.ac.kr

bogoankim@hanyang.ac.kr

^{††} 학생회원 : 한양대학교 인공지능학과 학생

dayoungjeong@hanyang.ac.kr

^{†††} 정 회 원 : 한양대학교 데이터사이언스학과 교수(Hanyang Univ.)

kyungsikhan@hanyang.ac.kr

(Corresponding author)

Copyright©2025 한국정보과학회: 개인 목적이나 교육 목적인 경우, 이 저작물의 전체 또는 일부에 대한 복사본 혹은 디지털 사본의 제작을 허가합니다. 이 때, 사본은 상업적 수단으로 사용할 수 없으며 첫 페이지에 본 문구와 출처를 반드시 명시해야 합니다. 이 외의 목적으로 복제, 배포, 출판, 전송 등 모든 유형의 사용행위를 하는 경우에 대하여는 사전에 허가를 얻고 비용을 지불해야 합니다.
정보과학회 컴퓨팅의 실제 논문지 제31권 제2호(2025. 2)

1. 서론

가상현실(Virtual Reality, VR) 기술이 교육, 의료, 엔터테인먼트 등 다양한 분야에서 점차 중요한 도구로 자리 잡으면서, 그 활용도는 계속해서 증가하고 있다[1-3]. 그러나 VR 사용 중 발생하는 사이버멀미 현상은 사용자에게 눈의 피로, 메스꺼움, 현기증 등 신체적 불편을 초래하여 몰입감을 방해하고, VR의 사용성을 저해하는 주요한 요인 중 하나이다.

최근 사이버멀미 연구들은 VR 사용자 경험을 증진하기 위해 너전도, 비디오, Head Mounted Display (HMD) 데이터 등을 활용하여 사이버멀미 예측 모델을 제안하고 있다[4,5]. 특히, 너전도 데이터는 사용자의 인지적 활동을 포착하는 데 효과적이지만, HMD 이외에 추가적인 측정 장치의 침습적 착용은 사용자 불편함과 VR 사용자 경험 감소를 초래할 수 있다. 이로부터 수집된 데이터는 사용자가 편안함을 느끼는 환경에서 수집된 데이터 대비 신뢰도 및 범용성이 부족할 수 있다[6].

대부분의 사이버멀미 예측 모델은 현재 시점의 point-wise 센서 데이터를 입력으로 사용하여 단일 시점의 사이버멀미를 예측하며, 높은 성능을 보여왔다[7-9]. 그러나 이러한 모델을 VR 콘텐츠에 탑재할 경우, 사용자가 사이버멀미를 체감하였을 때를 기점으로 완화 조치가 가능하기에 시야각 조절, blurring 등과 같은 기존 사이버멀미 완화 기술의 선제적 적용이 어려울 수 있다.

사이버멀미를 측정하는 대표적인 지표로는 Simulator Sickness Questionnaire (SSQ)[10]와 Fast Motion Sickness Scale (FMS)[11]가 있다. 최근 연구들에서 SSQ 결과의 일관성 문제가 대두되면서, 더 신뢰성 있고 표준화된 방법인 FMS 사용을 선호하는 경향이 증가하고 있다[12]. FMS는 사용자가 경험하는 멀미의 정도를 0 (멀미 없음)에서 20 (멀미 심함) 사이의 점수로 측정된다. 그러나 FMS는 사용자 주관에 의해 측정되기 때문에 동일한 FMS 값일지라도 사용자마다 그 값이 의미하는 사이버멀미 정도는 상이하다. 따라서, 사용자 주관의 개입없이 객관적으로 측정된 센서 데이터(e.g., HMD 센서 데이터)에 기반하여 개인별 사이버멀미 정도의 차이를 분석하고 개인화된 사이버멀미 예측 모델을 개발하는 것이 중요하다[13].

Transformer 기반의 장기 시계열 예측(Long-term Time Series Forecasting, LTSF) 모델은 시계열 데이터의 특성(e.g., 데이터의 증감 경향성)을 학습하여 높은 성능을 보인다[14-16]. 그 중, PatchTST[17]는 다변량 데이터를 분해하여 단변량 데이터로 처리함으로써 높은 시·공간적 계산 효율성을 보인다는 점에서, 사이버멀미와 연관성이 높은 다양한 변수(e.g., 눈/머리 움

직임)를 포함하고 있는 HMD 센서 데이터 학습에 효율적이다.

본 논문은 HMD에서 수집 가능한 센서 데이터를 기반으로 PatchTST를 활용한 사이버멀미 선제적으로 예측하는 모델을 제안한다. 실험 결과, 본 모델은 baseline 모델인 Vanilla Transformer[18]와 DLinear[19] 대비 높은 성능(MAE 0.14, RMSE 0.67)을 달성하였다. 이는 사이버멀미 도메인에서도 HMD 센서 데이터만을 사용하여 LTSF 모델을 적용함으로써, 미래 시점의 사이버멀미를 선제적으로 예측할 수 있다는 연구적 의의를 제시한다. 또한, PatchTST의 사이버멀미 선제적 예측 가능성을 바탕으로, 사용자마다의 상대적인 사이버멀미 정도를 예측할 수 있는 개인 맞춤형 모델 제안한다. PatchTST 기반의 개인 맞춤형 사이버멀미 선제적 예측 모델은 Accuracy 0.70, Precision 0.70, Recall 0.69, F1 score 0.70 성능을 달성하였다. 이러한 결과는 사용자 개인마다의 HMD 센서 데이터를 기반으로 사이버멀미 정도를 예측할 수 있는 개인화된 모델의 발전 가능성을 시사한다. 더 나아가 개인 맞춤형 사이버멀미 선제적 예측 모델을 VR 콘텐츠에 탑재함으로써 사용자에게 높은 사용자 경험 제공 가능성을 기대할 수 있다.

2. 사이버멀미 선제적 예측 모델링

2.1 HMD 센서 데이터 기반 PatchTST 방법론

우리는 사이버멀미 선제적 예측을 위해 PatchTST 모델을 채택하였다. 그림 1과 같이, PatchTST는 L 길이의 데이터($x_1, \dots, x_L$, x_t 는 t 시점의 모든 신호 값)를 입력받아 T 길이의 미래 데이터($x_{L+1}, \dots, x_{L+T}$)를 예측한다. 이때, L 길이의 다변량 데이터를 단변량 데이터로 분해하여 각각의 feature별로 정규화하는 instance normalization을 수행한다. 그림 2는 각 단변량 시계열 데이터를 일정 길이의 연속된 patch로 쪼개는 patching 기법을 보여주며, 하나의 patch를 입력 토큰으로 사용한다. 각 patch는 Transformer의 latent space 차원으로 변환되고, 시간적 순서 정보를 보존하기 위해 linear projection 및 positional embedding을 수행한다. Transformer 인코더 및 flatten layer를 거쳐 도출된 각 단변량 데이터는 합쳐진 후 최종 예측값이 도출된다.

우리는 VR 환경에서 수집된 데이터를 PatchTST에 적용하기 위해 모델을 튜닝하였다. HMD 센서 데이터는 참여자와 영상별로 시계열 데이터가 구분되어 있다. 따라서 입력 데이터가 연속적으로 모델에 들어갈 때, 한 영상의 마지막 시점 데이터와 다음 영상의 첫 시점 데이터가 함께 입력으로 사용되지 않도록 모델을 개발하였다.




그림 1 PatchTST 전체 구조

Fig. 1 Overall Architecture of PatchTST




그림 2 Patching 방법

Fig. 2 Method of Patching

2.2 MSCVR 데이터셋

우리는 45명의 실험 참여자를 대상으로 사용자 스테디를 통해 각 45초 길이의 사이버멀미 유발 영상 20개를 시청하도록 하여 수집한 MSCVR 데이터셋[8]을 사용하였다. MSCVR 데이터셋은 각 참여자로부터 수집된 HMD 센서 데이터와 FMS 점수를 포함한다. HMD 센서 데이터는 초당 90Hz로 수집된, 눈 움직임에 대한 23개의 신호(e.g., 양쪽 눈의 시선 방향 및 중심)와 머리 움직임에 대한 6개의 신호(e.g., 머리 위치 및 회전)로 구성된 2개의 모달리티 센서 데이터이다. 또한, FMS 점수는 VR 영상 시청 중 15초마다 측정되었다.

PatchTST를 사이버멀미 선제적 예측 모델로 활용하기 위해 MSCVR 데이터셋을 모델 구조에 맞게 전처리하였다. 우선, HMD를 착용하고 벗을 때의 센서 데이터와 중복되는 Hz 값을 제거함으로써 데이터를 초당 25Hz로 다운 샘플링하여, 영상별 데이터의 길이를 1125Hz (45초×25Hz)로 균일화하였다. 다음으로, 데이터 간 시간의 흐름을 나타내기 위해, 1부터 1125까지 Hz가 표기된 열을 추가하였다. PatchTST는 연속된 값을 예측하는 회귀 모델이지만, FMS는 0에서 20 사이의 값을 갖는 등간척도 데이터이기 때문에, 15초마다 측정된 FMS 값을 1125Hz 길이로 평탄화하였다.

3. 사이버멀미 예측 실험 및 결과 기능

3.1 PatchTST 실험 세팅

본 연구에서는 전처리된 29개 변수(눈 움직임 23개,

머리 움직임 6개)의 HMD 센서 데이터와 평탄화한 FMS 데이터를 사용하였다. 각 45초 길이 영상의 처음 70%는 훈련 데이터셋으로, 다음 10%는 테스트 데이터셋으로, 나머지 20%는 검증 데이터셋으로 나누어 모델을 학습시켰다. 영상별 1125Hz 길이의 데이터에서, $L=225$ Hz (9초×25Hz) 길이의 데이터를 입력 데이터로 사용하여, 다음 $T=75$ Hz (3초×25Hz) 길이의 FMS score를 예측하였다. 그림 2와 같이, 입력 데이터의 patch 길이 P 는 16, slide 길이 S 는 8로 설정하였다. patch의 개수 N 은 (1)과 같이 정의되며, 이에 따라 28개의 patch를 입력 토큰으로 설정하였다.

$$N = \left\lfloor \frac{L-P}{S} \right\rfloor + 2 \quad (1)$$

PatchTST에서의 hyperparameter는 batch size=64, epoch=5, loss function=MSELoss, optimizer=Adam, learning rate=0.0001로 설정하였다. 또한, 회귀 모델의 예측 성능 평가를 위해 MAE와 RMSE 평가지표를 사용하였다.

3.2 LTSF 모델별 성능 비교

MSCVR 데이터셋을 사용하여, PatchTST와 baseline LTSF 모델들의 성능을 비교하였다. Vanilla Transformer의 인코더 부분을 사용하는 PatchTST의 다변량 데이터 처리 방식과 patching 기법의 효과성을 확인하기 위해, Vanilla Transformer를 비교 모델로 채택하였다. 또한, DLinear는 단순한 선형 모델임에도 불구하고, Vanilla Transformer 기반의 모델보다 높은 성능을 보였기에 [17], 비교 모델로 사용하였다. 표 1과 같이, 사이버멀미 선제적 예측 모델인 PatchTST는 MAE 0.14, RMSE

표 1 LTSF 모델별 성능

Table 1 Performances by LTSF Models

Models	MAE	RMSE	R ² score
Vanilla Transformer	0.69	1.35	0.81
DLinear	0.25	0.68	0.94
PatchTST	0.14	0.67	0.95

표 2 사이버멀미 예측 모델별 성능

Table 2 Performances by Cybersickness Prediction Models

Models	Modalities	MAE	RMSE
DeepTCN [20]	Eye Movement	-	0.49
	Head Movement		
Kundu et al. [21]	Physiological Signal	0.21	0.36
PatchTST	Eye Movement	0.14	0.67
	Head Movement		

0.67 성능을 보였으며, Vanilla Transformer와 DLinear 보다 높은 성능을 보였음을 확인하였다. 또한, PatchTST의 R^2 score 0.95로, 모델의 예측값과 실제값 간의 비교를 통해 baseline 모델 대비 높은 설명력을 보여주었다. 이러한 결과는 patching을 적용하여 연속된 시계열 데이터의 지역적 정보를 보존하여 모델의 정확도를 높였으며, 다변량 데이터를 단변량 데이터로 처리하는 PatchTST가 다수의 변수를 포함한 HMD 센서 데이터에 효율적으로 활용될 수 있음을 의미한다. 또한, 사이버멀미 도메인에서도 Vanilla Transformer 기반의 LTSF 모델을 활용하여 선제적 예측이 가능함을 시사한다.

3.3 사이버멀미 예측 모델 성능 비교

PatchTST의 patching 기법의 효과성을 확인하기 위해, point-wise를 입력 데이터로 사용한 기존 모델과 성능을 비교하였다. 우리는 기존 사이버멀미 예측 모델의 코드가 제한적으로 공개되어 있고, 논문에서 모델 구현에 대한 세부 설명이 충분하지 않아 직접 구현 시 신뢰성에 영향을 미칠 수 있다고 판단하였다. 이에 본 연구에서는 MSCVR 데이터셋을 이용한 실험을 진행하지 않고, 기존 연구의 실험 결과를 인용하였다. 표 2와 같이, PatchTST는 Kundu et al.의 모델보다 MAE가 0.07만큼 감소하여 높은 성능을 보였다. 그러나 RMSE는 0.31만큼의 성능 감소가 있었음을 확인하였다. Patching된 센서 데이터는 표준화된 전처리 방식(e.g.,

중복값 제거, smoothing)으로는 다소 처리하기 어려운 다수의 이상치를 포함할 수 있으며, RMSE는 이상치에 비교적 민감하기 때문에 성능에 영향을 미쳤을 것으로 예상된다. 또한, 선행연구에서는 모델 학습에 있어 HMD 뿐만 아니라 추가적인 생리 신호 측정 장비에서 수집된 모달리티를 함께 사용하였다. 이는 사이버멀미와 상대적으로 더 직결되는 features를 학습하여 모델을 구축하였다는 점에서 성능에 긍정적 요인을 주었을 수도 있다. 이러한 점에서, 기존 모델 대비 상회하는 MAE 성능을 보여준 제안된 모델은 HMD 센서 데이터만으로도 충분히 사이버멀미 예측이 가능함을 시사하며, series-wise 입력 데이터를 사용하는 patching 기법의 활용이 효과적임을 보여준다. 또한, 향후 계획된 대규모 사용자 스터디를 통해 추가적으로 데이터를 수집하고, 이를 기반으로 전처리 방법 및 모델 구조를 보완하여 RMSE 또한 상회하는 결과를 기대한다.

4. 개인 맞춤형 사이버멀미 선제적 예측 모델

PatchTST의 사이버멀미 선제적 예측 가능성을 바탕으로, MSCVR 데이터셋과 모델의 구조를 변형하여 PatchTST 기반의 개인 맞춤형 사이버멀미 선제적 예측 모델을 개발하였다. 참여자별 상대적인 사이버멀미 정도를 나타내기 위해, FMS를 참여자별로 범주화하였다. 모델이 FMS 값 자체가 아닌, 참여자별로 범주화된 FMS를 분류 예측할 수 있도록 PatchTST 구조를 기반으로 분류 모델을 구현하였다.

4.1 데이터 범주화

그림 3은 MSCVR 데이터셋으로부터 얻은 참여자 일부의 참여자별 FMS 빈도수 분포와 평균(Mean), 표준편차(SD), 왜도(Skewness)를 나타낸 그래프이다. 대부분의 참여자 그래프에서 FMS 빈도수 분포는 비대칭을 보이고 있다. 또한, 우리는 각 참여자가 경험하는 사이




그림 3 참여자별 FMS 빈도수 분포 그래프 예시

Fig. 3 Examples of FMS Frequency Graphs by Participants

표 3 개인 맞춤형 모델 성능
Table 3 Performance of the Personalized Models

Models	Accuracy	Precision	Recall	F1 score
Vanilla Transformer	0.47	0.59	0.53	0.40
DLinear	0.70	0.70	0.69	0.69
PatchTST	0.71	0.71	0.70	0.71




그림 4 개인 맞춤형 모델(PatchTST)의 혼동 행렬
Fig. 4 Confusion Matrix of the Personalized PatchTST

버멀미의 정도가 FMS 전체가 아닌, 한정된 범위 내에서 나타나는 경향이 많다는 점을 발견하였다. 이는 FMS로 표현된 사이버멀미 정도가 참여자마다 상대적일 수 있음을 뜻하며, 이를 고려한 모델의 필요성을 시사한다. 이에 맞추어, 우리는 FMS 빈도수 분포와 상대성을 고려하여, 참여자별 FMS의 중앙값(m_i , i 는 참여자 번호)을 기준으로 FMS를 범주화하였다. 이 방법은 각 참여자의 상대적인 사이버멀미 정도를 고려하여 예측을 할 수 있도록 한다. 개인화된 사이버멀미 정도(Personalized Cybersickness Level, PCL)는 FMS 값(FMS_i^t , t 는 시점)이 각 개인의 중앙값보다 높은 경우를 High로, 낮은 경우를 Moderate로 구분하였다.

$$PCL_i = \begin{cases} High & \text{if, } FMS_i^t > m_i \\ Moderate & \text{if, otherwise} \end{cases} \quad (2)$$

4.2 PatchTST를 활용한 분류 모델과 성능 평가

우리는 PatchTST 기반의 개인 맞춤형 사이버멀미 선제적 예측 모델을 개발하였다. 본 모델은 HMD 센서 데이터의 시간적 흐름을 고려하여 미래 시점의 PCL을 분류 예측한다. 본래 회귀 모델인 PatchTST를 분류 모델로 변환하기 위해 binary cross entropy loss를 사용하였으며, 마지막 layer에 sigmoid function을 적용하였다. 또한, FMS 평탄화로 인해 발생할 수 있는 overfitting을 방지하기 위해 5초마다의 HMD 센서 데이터 평균을 모델 학습에 사용하였다(45초 길이 영상 1개당 9개의 data point). 이는 PCL의 반복적인 문제를 최소화하면서 모델의 성능을 유지할 수 있다.

변형된 MSCVR 데이터셋으로 영상별 학습이 가능하

도록 5개 영상에 대한 데이터를 입력 데이터($L=45$)로 하여, 다음 1개 영상($T=9$)에 대한 PCL을 예측할 수 있도록 하였다. 입력 데이터 길이를 고려하여 P 는 15, S 는 5로 설정하여 모델 학습을 진행하였다. 개인 맞춤형 모델의 성능 평가를 위해 Accuracy, Precision, Recall, F1 score 평가지표를 활용하였다.

모델 학습 결과, 제안된 개인 맞춤형 모델은 표 3과 같이 Accuracy 0.71, Precision 0.71, Recall 0.70, F1 score 0.71 성능을 달성하였으며, baseline 모델들의 성능을 능가하는 결과를 보여주었다. 이러한 결과는 미래 시점의 PCL 분류 예측에 상당한 잠재력을 보유하고 있음을 시사한다. 또한, HMD 센서 데이터를 기반으로, PatchTST를 활용하여 PCL의 선제적 예측이 가능하며, 개인화된 사이버멀미 예측 모델로서 충분히 활용될 수 있을 것으로 기대한다.

5. 사이버멀미 예측 결과의 실시간 적용 가능성

본 연구에서 제안한 모델은 사이버멀미 선제적 예측에서 잠재력 있는 성능을 보였다. 그러나 VR 사용자 경험 증진을 위해서는 모델의 정확도뿐만 아니라, VR 콘텐츠에 모델을 탑재했을 때 사용자가 사이버멀미를 느끼기 전에 이를 실시간으로 예측할 수 있어야 한다. PatchTST는 추론 시간이 데이터 포인트 하나당 0.01초로 짧은 편이며, 이는 사이버멀미 실시간 예측에 적합한 성능을 보이고 있음을 의미한다. 우리는 우선적으로 현재 시점의 사이버멀미를 예측하는 기존 모델을 VR 콘텐츠에 탑재하고 Transmission Control Protocol (TCP) 통신을 통해 실시간으로 데이터를 수집하여 예측 결과의 실시간 적용 가능성을 탐구하였다. 그 결과, 데이터와 모델 간 통신 시간으로 인해 예측까지 약 5초의 지연이 발생하였으며, 시간이 지남에 따라 데이터가 축적되며 예측 지연 시간이 증가하는 것을 확인하였다. 이러한 경험적 결과를 바탕으로, 본 연구에서 제안한 모델 역시 추론 시간이 짧더라도 VR 콘텐츠에 탑재될 경우, 실시간 예측에서 지연이 발생할 가능성이 있다. 따라서 최대 지연 시간을 고려하여 본 모델의 예측 시점을 조정한다면, 예측 지연이 일부 발생하더라도 사용자가 불편을 느끼기 전에 결과를 제공할 수 있을 것으로 기대된다.

6. 결론 및 향후 연구

본 논문에서는 HMD 센서 데이터를 기반으로 LSTF 모델을 활용하여 사이버멀미를 선제적으로 예측하는 모델을 제안하였다. 실험 결과, 사이버멀미 도메인에서도 PatchTST를 활용하여 선제적으로 사이버멀미를 예측할 수 있음을 보여주었다. 또한, VR 경험을 위한 스텐

다드 디바이스인 HMD로부터 수집된 센서 데이터만으로도 사이버멀미의 효과적인 예측이 가능함을 보였다. 이를 바탕으로 구축된 개인 맞춤형 사이버멀미 선제적 예측 모델은 사용자별로 범주화된 FMS와 HMD 센서 데이터를 기반으로, 미래 시점의 PCL을 선제적으로 분류 예측할 수 있다는 가능성을 보여주었다.

향후 연구에서는 대규모 사용자 스터디를 통해 모델의 예측에 기반한 선제적 사이버멀미 완화 조치의 가능성을 탐색할 예정이다. 이때, HMD 센서 데이터뿐만 아니라, 윤리적 고려 사항(e.g., 개인 정보 보호)을 준수하여 인구통계 정보 및 VR 경험 여부 등 참여자 특성을 추가 변수로 고려함으로써 모델 예측 결과의 정당성을 강화하고자 한다. 더하여, 모델의 잘못된 예측 결과로 인한 사용자에게 미칠 수 있는 부정적 영향(e.g., 멀미로 인한 넘어짐)을 방지하기 위해 파일럿 스터디를 통한 모델 검증 및 개선 과정을 수행할 필요가 있다.

References

- [1] B. Kim, D. Jeong, M. Jeong, T. Noh, S. I. Kim, T. Kim, S. Jang, H. J. Yoo, J. G. Kim, H. Hong, and K. Han, "Vista: User-centered VR Training System for Effectively Deriving Characteristics of People with Autism Spectrum Disorder," *Proc. of the 28th ACM Symposium on Virtual Reality Software and Technology*, 1-12, 2022.
- [2] B. Kim, D. Jeong, J. G. Kim, H. Hong, and K. Han, "V-DAT (Virtual Reality Data Analysis Tool): Supporting Self-Awareness for Autistic People from Multimodal VR Sensor Data," *Proc. of the 36th Annual ACM Symposium on User Interface Software and Technology*, 1-13, 2023.
- [3] P. E. Paredes, S. Balters, K. Qian, E. Murnane, L., F. Ordóñez, W. Ju, and J. A. Landay, "Driving with the Fishes: Towards Calming and Mindful Virtual Reality Experiences for the Car," *Proc. of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 2(4), 1-21, 2018.
- [4] D. Jeong, S. Yoo, and J. Yun, "Cybersickness Analysis with EEG Using Deep Learning Algorithms," *In 2019 IEEE Conference on Virtual Reality and 3D User Interfaces (VR)*, 827-835, 2019.
- [5] W. Jin, J. Fan, D. Gromala, and P. Pasquier, "Automatic Prediction of Cybersickness for Virtual Reality Games," *In 2018 IEEE Games, Entertainment, Media Conference (GEM)*, 1-9, 2018.
- [6] M. Soufneyestani, D. Dowling, and A. Khan, "Electroencephalography (EEG) Technology Applications and Available Devices," *Applied Sciences*, 10(21), 7453, 2020.
- [7] D. Jeong, S. Paik, Y. Noh, and K. Han, "MAC: Multimodal, Attention-based Cybersickness Prediction Modeling in Virtual Reality," *Virtual Reality*, 27(3), 2315-2330, 2023.
- [8] D. Jeong and K. Han, "PRECYSE: Predicting Cybersickness Using Transformer for Multimodal Time-Series Sensor Data," *Proc. of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 8(2), 1-24, 2024.
- [9] R. Islam, K. Desai, and J. Quarles, "Cybersickness Prediction from Integrated HMD's Sensors: A Multimodal Deep Fusion Approach Using Eye-tracking and Head-tracking Data," *In 2021 IEEE International Symposium on Mixed and Augmented Reality (ISMAR)*, 31-40, 2021.
- [10] R. S. Kennedy, N. E. Lane, K. S. Berbaum, and M. G. Lilienthal, "Simulator Sickness Questionnaire: An Enhanced Method for Quantifying Simulator Sickness," *The International Journal of Aviation Psychology*, 3(3), 203-220, 1993.
- [11] B. Keshavarz and H. Hecht, "Validating an Efficient Method to Quantify Motion Sickness," *Human Factors*, 53(4), 415-426, 2011.
- [12] T. Van Gemert, N. C. Nilsson, T. Hirzle, and J. Bergström, "Sicknificant: A Systematic Review and Meta-analysis of VR Sickness in Walking-based Locomotion for Virtual Reality," *Proc. of the CHI Conference on Human Factors in Computing Systems*, 1-36, 2024.
- [13] U. Tasnim, R. Islam, K. Desai, and J. Quarles, "Investigating Personalization Techniques for Improved Cybersickness Prediction in Virtual Reality Environments," *IEEE Transactions on Visualization and Computer Graphics*, 2024.
- [14] N. Wu, B. Green, X. Ben, and S. O'Banion, "Deep Transformer Models for Time Series Forecasting: The Influenza Prevalence Case," *arXiv preprint*, arXiv: 2001.08317, 2020.
- [15] H. Zhou, S. Zhang, J. Peng, S. Zhang, J. Li, H. Xiong, W. Zhang, "Informer: Beyond Efficient Transformer for Long Sequence Time-Series Forecasting," *Proc. of the AAAI Conference on Artificial Intelligence*, Vol. 35, No. 12, 11106-11115, 2021.
- [16] T. Zhou, Z. Ma, Q. Wen, X. Wang, L. Sun, R. Jin, "FEDformer: Frequency Enhanced Decomposed Transformer for Long-term Series Forecasting," *In International Conference on Machine Learning (PMLR)*, 27268-27286, 2022.
- [17] Nie, Y., et al., A time series is worth 64 words: Long-term forecasting with transformers. *arXiv preprint arXiv:2211.14730*, 2022.
- [18] A. Vaswani, "Attention Is All You Need," *Advances in Neural Information Processing Systems*, 2017.
- [19] A. Zeng, M. Chen, L. Zhang, and Q. Xu, "Are Transformers Effective for Time Series Forecasting?," *Proc. of the AAAI Conference on Artificial Intelligence*, Vol. 37, No. 9, 11121-11128, 2023.
- [20] R. Islam, K. Desai, and J. Quarles, "Towards Forecasting the Onset of Cybersickness by Fusing

Physiological, Head-tracking and Eye-tracking with Multimodal Deep Fusion Network," *In 2022 IEEE International Symposium on Mixed and Augmented Reality (ISMAR)*, 121-130, 2022.

- [21] R. K. Kundu, R. Islam, J. Quarles, and K. A. Hoque, "LiteVR: Interpretable and Lightweight Cybersickness Detection using Explainable AI," *In 2023 IEEE Conference Virtual Reality and 3D User Interfaces (VR)*, 609-619, 2023.



최 윤 선

2024년 한양대학교 테이터사이언스학부 졸업(학사). 2024년~현재 한양대학교 테이터사이언스학과 석사과정. 관심분야는 인간-컴퓨터 상호작용, 시계열 데이터, 디지털 헬스



정 다 영

2021년 아주대학교 전자공학과 졸업(학사) 2022년~현재 한양대학교 인공지능학과 석박사통합과정. 관심분야는 인간-컴퓨터 상호작용, 디지털 헬스, 센서 데이터



김 보 관

2017년 미네소타 대학교 통계학과 졸업(이학사). 2025년 한양대학교 테이터사이언스학과 졸업(공학박사). 관심분야는 인간-컴퓨터 상호작용, 디지털 헬스케어, 소셜 컴퓨팅



한 경 식

2015년 펜실베이니아 주립대학교 박사 2015년~2017년 미국 퍼시픽 노스웨스트 연구소 선임연구원. 2017년~2021년 아주대학교 컴퓨터공학과·인공지능학과 조교수 2021년~현재 한양대학교 테이터사이언스학과 및 인공지능학과 부교수. 관심분야는 인간-컴퓨터 상호작용, 인공지능, 소셜 컴퓨팅