

# LLM을 활용한 가상현실에서의 사이버멀미 선제적 예측 모델 및 개인 맞춤형 모델 개발

최윤선<sup>1</sup>, 정다영<sup>2</sup>, 김보관<sup>1</sup>, 한경식<sup>1, 2</sup>

<sup>1</sup> 한양대학교 데이터사이언스학과

<sup>2</sup> 한양대학교 인공지능학과

## 연구 배경 및 동기

[Keywords] 사이버멀미, LLM 기반의 장기 시계열 예측 모델, 선제적 예측, 개인 맞춤형 모델

### 선행연구 모델의 한계점

- ▶ 대부분의 모델은 현재 시점의 point-wise 시계열 센서 데이터를 입력하여 단일 시점의 사이버멀미를 예측함
- ▶ 사용자가 사이버멀미를 체감한 후 완화 조치가 가능하며, 이는 VR 환경에서의 자연스러운 사용자 경험을 방해할 수 있음

### LLM의 필요성


- ▶ 사전학습된 LLM을 통해 모델은 참여자와 영상별로 구분된 VR 환경의 시계열 센서 데이터셋의 맥락을 이해할 수 있음
- ▶ 사전학습된 LLM의 수많은 파라미터는 시계열 센서 데이터의 복잡한 비선형 패턴 이해와 숨은 추세 및 계절성 파악에 효과적임

### 개인 맞춤형 모델의 필요성

- ▶ 사이버멀미를 측정하는 정량적 척도인 Fast Motion Sickness Scale (FMS)는 사용자 주관에 의해 측정됨
- ▶ FMS 점수 전체(0부터 20)가 아닌 한정된 범위 내에 분포되는 경향이 있어, 사용자마다 FMS 점수는 상대적일 수 있음

우리는 시계열 센서 데이터를 사용하여 LLM 기반의 장기 시계열 예측 모델을 활용한 미래 시점의 사이버멀미 선제적 예측 가능성을 확인하였으며, 이를 토대로 개인 맞춤형 모델을 개발함

## 모델 학습 방법



- ▶ **Input Embedding:** 각 feature별로 instance normalization 수행 후, 정규화된 데이터를 일정 길이의 patches로 분할
- ▶ **Patch Reprogramming:** Patches를 LLM에 임베딩하기 위해, 사전학습된 LLM으로부터 얻은 word embeddings와 patches를 cross-attention
- ▶ **Prompt-as-Prefix:** 데이터셋 설명(dataset context), 모델 task에 대한 가이드라인(task instruction), 입력 데이터의 통계 정보(input statistics)를 포함한 프롬프트를 마치 접두사(prefix)처럼 reprogrammed patches 앞에 붙여 하나의 벡터로 만드는 과정

## 모델 학습 결과

### MSCVR 데이터셋

- ▶ 45명의 참여자를 대상으로 45초 길이의 사이버멀미 유발 영상 20개를 시청하도록 하여 수집한 공개 데이터셋
- ▶ 눈 및 머리 움직임에 대한 시계열 센서 데이터 + FMS

| Models | Transformer | DLinear | PatchTST    | Time-LLM |
|--------|-------------|---------|-------------|----------|
| MAE    | 2.14        | 1.33    | <b>0.93</b> | 0.97     |
| RMSE   | 3.04        | 1.91    | <b>1.68</b> | 1.69     |

- ▶ Time-LLM은 baseline 모델에 준하는 성능을 보였으며, **사이버멀미 예측에서 효과적으로 활용될 수 있음**을 시사함
- ▶ 사전학습된 LLM은 **모달리티를 통합적으로 학습하는데 도움**을 주어 **학습 과정을 단순화**할 수 있기 때문에, 고무적인 학습 결과를 보여줌

## 개인 맞춤형 모델

- ▶ 사이버멀미 선제적 예측 가능성을 바탕으로, **개인화된 사이버멀미 정도 (Personalized Cybersickness Level, PCL)** 분류 예측 모델 개발
- ▶ 개인별  $FMS_i^t$  ( $t$ 는 시점,  $i$ 는 참여자 번호)의 **중앙값( $m_i$ )**을 기준으로, *High* 혹은 *Moderate*로  $PCL_i$  구분

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

| Models   | Accuracy    | Precision   | Recall      | F1 score    |
|----------|-------------|-------------|-------------|-------------|
| PatchTST | 0.71        | 0.71        | 0.70        | 0.71        |
| Time-LLM | <b>0.73</b> | <b>0.72</b> | <b>0.71</b> | <b>0.71</b> |

- ▶ **사전학습된 LLM의 활용이 예측 결과에 긍정적인 영향**을 주고 있으며, 개인화된 사이버멀미 선제적 예측 모델의 발전 가능성을 보여줌

## 결론 및 향후 연구

- ▶ LLM 기반 장기 시계열 예측 모델을 활용하여 **사이버멀미 도메인에서도 선제적 예측이 가능하다는 것**을 입증하였으며, 이를 바탕으로 구축된 개인 맞춤형 모델은 **미래 시점의 PCL을 선제적으로 분류 예측**하여 VR 사용성을 증진시킬 수 있다는 잠재력을 보여줌
- ▶ 입력 데이터 표현의 변화, patch reprogramming 방법론의 개선을 통해 **모델의 성능을 보완**할 예정임
- ▶ 모델을 **VR 콘텐츠에 탑재한 후 대규모 사용자 스터디를 진행**함으로써, 사이버멀미 선제적 예측 모델의 사용성을 검증할 계획임
- ▶ 개인 맞춤형 모델의 프롬프트에 눈 및 머리 움직임에 대한 시계열 센서 데이터 정보 이외에도 **사용자의 인구통계정보를 함께 사용**함으로써, **LLM이 사이버멀미와 관련한 사용자의 feature를 함께 학습**하도록 하여 **초개인화된 모델의 개발**을 목표로 함

**Acknowledgements:** This research was supported by the National Research Foundation of Korea (NRF) (No. 2021M3A9E4080780, No. 2018R1A5A7059549).