

1. Introduction

암은 심각한 질병으로 인식되며, 암 치료 과정에서 환자들의 삶은 많은 변화를 겪는다. 병원은 환자들에게 약물 요법, 면역 요법, 방사선 요법, 화학 요법 등 다양한 치료 방법을 제공하지만, 치료 후 환자들이 집으로 돌아가게 되면 부작용을 지속적으로 모니터링하기가 어렵다. 특히, 환자들이 3주 주기의 정기 방문을 꾸준히 이행할 수 있을지 여부도 불확실하다. 이러한 상황 속에서 디지털 헬스케어 서비스가 주목받고 있으며, 웨어러블 기기를 활용한 환자 모니터링 방법이 활발히 연구되고 있다.

특히, 웨어러블 기기가 치료 방법이나 약물의 부작용을 감지할 수 있다면, 환자의 시계열 데이터를 기반으로 다음 방문이 응급실 방문으로 이어질 가능성을 예측할 수 있을 것이다. 이러한 예측은 환자의 상태를 보다 효과적으로 관리하고, 응급 상황을 사전에 파악하는 데 큰 도움을 줄 수 있다.

2. Method

2.1. 데이터 수집 및 전처리

본 연구는 삼성서울병원에 내원한 총 161명의 non-small cell lung cancer (NSCLC) 환자를 대상으로 최소 12주간 웨어러블 기기(fitbit inspire3)를 통해 분별 심박수를 수집하였다. 나이 60세 이상 환자 72% 이상으로 데이터 수집의 일관성을 유지 하였고, 성별은 남자 96명 여자 65명 으로 구성 하여 수집 되었다 <Table 1 참조>.

인구학적 정보

N (전체 환자)	161
나이 60 세 이상	116 (72.0%)
성별 (남/여)	96/65
항암치료(CTX/CCRT/TKI/IO)	96/9/45/11

Table1. 등록된 폐암환자의 정보 요약

본 연구에서는 항암 치료 전 1~10일 동안 수집된 생체로그 중 임의로 선택한 3일 동안의 데이터를 사용하여, 항암 치료 후 응급실 방문 여부를 예측하는 시계열 인공지능 모델의 성능을 비교 분석했다 (<Figure 1> 참조). 본 연구에서 비교한 모델은 Logistic regression (LR), Support vector machine (SVM), Random forest (RF), Recurrent neural net (RNN), Gated recurrent units (GRU), Long Short-Term Memory (LSTM), Attention-LSTM 이다.

생체로그 지표는 다음과 같은 전 처리 과정을 거쳤다:

- 1) 일별 70% 이상의 순응도를 가진 데이터 수집
- 2) 평균 대체법을 통한 결측치 보완
- 3) SMOTE 기법을 활용한 데이터 불균형 해소.

인공지능 모델의 성능 평가는 stratified nested 5-fold cross-validation을 통해 검증하였으며, BACC, AUC, ACC 지표를 기반으로 평가했다.

본 연구에서는 실험을 총 2가지로 진행하였다:

1. 머신 러닝 모델을 활용한 응급실 방문 예측:

머신 러닝 모델은 수집된 생체 로그 데이터 에서 수집된 방문일자 기준으로 1일 전 데이터 부터 10 일전 데이터 까지의 생체로그 지표 중 총 3일 동안의 연속된 데이터를 사용하였다.

2. 딥러닝 모델을 활용한 응급실 방문 예측:

시계열 인공지능 모델에서는 방문일자 기준 전 20일 동안의 생체로그 지표를 사용하였다. 20일의 생체 로그 데이터를 시퀀스로 시계열 인공지능 모델 RNN, GRU, LSTM, Attention LSTM 에 사용하였다.

3. Result

3.1. 방문 일자에 따른 구간별 머신 러닝 응급실 방문예측 결과

이 중 방문일자 기준으로 2일전 에서부터 4일 전 동안의 데이터 평균값을 이용한 Logistic Regression이 가장 높은 성능(BACC: 0.62, ACC: 0.64, AUC: 0.64)을 보였다 (<Figure 2> 참조).

기간	Logistic Regression			SVM			Random Forest		
	BACC ↑	ACC ↑	AUC ↑	BACC ↑	ACC ↑	AUC ↑	BACC ↑	ACC ↑	AUC ↑
-1~-3	0.60±0.11	0.62±0.12	0.62±0.11	0.56±0.08	0.59±0.13	0.58±0.13	0.47±0.02	0.91±0.03	0.49±0.10
-2~-4	0.62±0.14	0.64±0.11	0.64±0.15	0.50±0.13	0.68±0.13	0.62±0.23	0.48±0.01	0.92±0.03	0.47±0.11
-3~-5	0.59±0.18	0.64±0.10	0.61±0.15	0.57±0.16	0.66±0.09	0.59±0.17	0.47±0.01	0.90±0.03	0.45±0.07
-4~-6	0.60±0.08	0.62±0.11	0.60±0.07	0.57±0.11	0.63±0.09	0.57±0.09	0.49±0.07	0.90±0.03	0.53±0.03
-5~-7	0.60±0.04	0.62±0.11	0.59±0.05	0.54±0.08	0.62±0.18	0.58±0.06	0.49±0.07	0.88±0.03	0.55±0.04
-6~-8	0.56±0.08	0.63±0.11	0.61±0.16	0.51±0.12	0.65±0.18	0.57±0.17	0.54±0.08	0.90±0.04	0.53±0.11
-7~-9	0.57±0.14	0.60±0.09	0.59±0.15	0.50±0.12	0.66±0.16	0.57±0.16	0.53±0.09	0.89±0.04	0.58±0.12
-8~-10	0.54±0.05	0.60±0.10	0.58±0.05	0.51±0.07	0.73±0.17	0.54±0.06	0.56±0.08	0.91±0.02	0.57±0.11

Table 2. 생체로그지표의 날짜 범위 변화에 따른 머신 러닝 모델 Logistic regression, Support vector machine, Random forest 성능 비교 표. 예측 성능은 stratified nested 5-fold cross-validation을 통해 BACC, ACC, AUC로 평가하였으며, 모델 성능은 평균과 표준편차 (Mean ± std)로 표시함.

3.2. 시계열 인공지능 모델 별 응급실 방문예측 결과

Attention-LSTM 이 가장 높은 성능(BACC: 0.72, ACC: 0.84, AUC: 0.83)을 보였다 (<Table 3> 참조). 이러한 결과는 Attention-LSTM 모델이 시간에 따른 생체로그의 패턴을 더 잘 포착할 수 있음을 시사한다.

Model	BACC ↑	ACC ↑	AUC ↑
RNN	0.55±0.18	0.65±0.11	0.54±0.19
GRU	0.59±0.15	0.77±0.08	0.68±0.18
LSTM	0.49±0.09	0.83±0.07	0.56±0.21
Attention-LSTM	0.72±0.07	0.84±0.09	0.83±0.06

Table 3. 시계열 인공지능 모델 Recurrent neural network, Gated Recurrent Units, Long Short-Term Memory, Attention LSTM 성능 비교. 예측 성능은 stratified nested 5-fold cross-validation을 통해 BACC, ACC, AUC로 평가하였으며, 모델 성능은 평균과 표준편차 (Mean ± std)로 표시함.

4. Conclusion

본 연구는 폐암 환자의 생체로그 데이터를 기반으로 한 응급실 방문 예측의 가능성을 제시하며, 특히 Attention-LSTM 모델이 가장 우수한 성능을 보였다. 이러한 결과는 디지털 헬스케어 기기를 활용한 지속적 모니터링 시스템 개발에 중요한 기여를 할 수 있으며, 환자 관리와 예측 정확도를 향상시키는 데 기여할 수 있을 것이다. 향후 연구에서는 더 다양한 생체로그 지표와 장기간의 데이터 수집을 통해 모델의 정확성을 높이는 방향으로 발전할 수 있을 것이다.

5. Acknowledgements

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단(NRF-2022R1F1A1068529), 정보통신기획평가원(No.2019-0-01842, AI대학원 (GIST), No. 2021-0-02068, AI혁신허브), 대한암연구재단(2022 암연구지원사업, CB-2022-B-2)의 지원을 받아 수행된 연구임. 또한, GIST SCENT를 통한 HPC-AI 개방형 인프라의 GPU 컴퓨팅 지원에 감사드립니다.

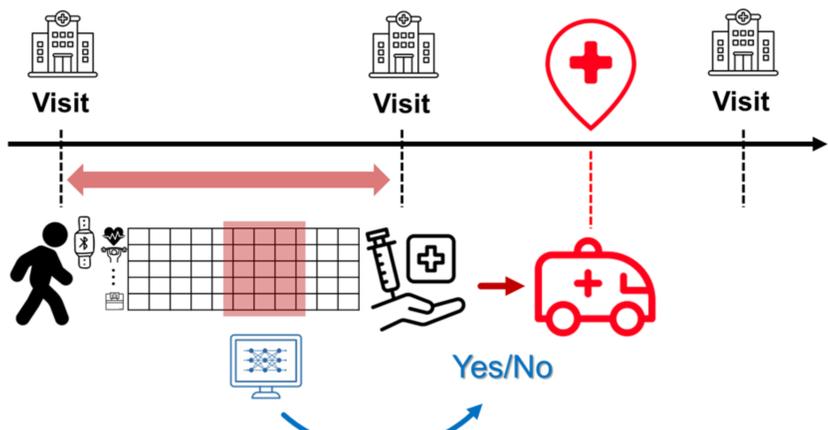


Figure 1. 암 환자 응급실 방문 예측 모델 구조