

딥러닝 기반의 수정조기경보지수(Modified Early Warning Score) 예측 방법에 관한 연구

진용식^{1*}, 김범휘¹, 김규형¹, 조성현¹, 신우상²
¹ 한국전자통신연구원, ² 한국생산기술연구원, *교신 저자

{yongsik, bumhwi.kim, jaykim, seonghyeonjo}@etri.re.kr, welldone@kitech.re.kr

A Study on deep learning-based methods for MEWS (Modified Early Warning Score) prediction

Yongsik Jin^{1*}, Bumhwi Kim¹, Kyu hyung Kim¹, Seonnghyeon Jo¹, Woo Sang Shin²
¹Electronics and Telecommunications Research Institute (ETRI), ²Korea Institute of Industrial Technology (KITECH), *Corresponding author

요 약

본 논문은 수정조기경보지수(Modified Early Warning Score)를 기반으로 환자의 위험 상태를 예측하기 위한 딥러닝 기반의 알고리즘을 제안한다. 효율적인 예측 방법을 개발하기 위하여 Convolutional neural networks, Long short-term memory 기반의 방법들이 주어진 데이터에 대해 성능이 평가된다. 특히 Long short-term memory의 성능을 개선하기 위하여 Attention 알고리즘과 입력 데이터를 변형하는 방법들이 제안된다. 본 논문의 실험 결과는 수정조기경보지수(Modified Early Warning Score)를 기반으로 환자의 위험 상태를 예측하기 위한 모델들의 효율성을 보여주고 추후의 연구 방향을 제시한다.

I. 서 론

수정조기경보지수(MEWS: Modified Early Warning Score)는 환자의 위험 징후를 효율적으로 나타낼 수 있는 지표 중 하나로 위험 환자들의 모니터링 방법에 사용되고 있다 [1]. MEWS는 환자의 위험 추이를 예측하기 위하여 혈압, 맥박, 호흡률, 체온, 환자의 의식 상태를 통계적으로 분석하여 개발된 점수로서 주로 MEWS를 4개의 위험 단계(안정, 주의, 경고, 위험)로 나누어 환자의 건강 상태를 적절하게 관리한다. 미리 환자의 상태를 예측한다는 점에서 환자의 생존률을 높이고 의료자원을 효율적으로 운영할 있다는 장점을 가지고 있다.

환자 위험 상태 예측과 관련하여 최근 딥러닝 기반의 알고리즘들이 많은 관심을 받고 있다. 특히 류노에서 연구되어진 딥러닝 기반의 조기 경보 시스템은 임상 시험을 통해 효율성을 증명하였고 실용화를 위해 실제 의료 현장에서 시험을 진행 중이다.

본 논문에서는 환자의 MEWS를 기반으로 환자의 위험 상태를 한 시간 미리 예측하는 딥러닝 기반의 알고리즘을 제안한다.

II. 본론

본론에서는 1시간 후의 MEWS 예측에 사용된 방법들이 소개된다. 시계열 데이터를 처리를 위한 convolutional neural network (CNN)와 Long short-term memory (LSTM), Attention 알고리즘, onehot

encoding, MEWS 환산식을 활용한 입력 데이터 처리 기법들이 사용된다. MEWS 계산 식은 아래의 표와 같이 주어진다.

표 1. MEWS 계산 테이블(SBP: Systolic Blood Pressure, HR: Heart Rate, RR: Respiratory rate, BT: Body Temperature, AVPU: Alert, Voice, Pain, Unresponsive)

Socore	0	1	2	3
SBP (mmHG)	101-199	81-100	70-80, ≥ 200	<70
HR (bpm)	51-100	40-50, 101-110	<40 , 111-129	≥ 130
RR (bpm)	9-14	15-20	21-29, <9	≥ 30
BT (°C)	35-38.4	-	<35 , ≥ 38.5	-
AVPU score	Alert	Reacting to Voice	Reacting to Pain	Unresponsive

II-1. 실험 데이터

본 논문의 실험에서는 영남대학교 병원에서 후향적 임상 시험으로 획득되어진 데이터를 사용한다. 환자의 MEWS를 계산하기 위해 1시간 마다 수축기 혈압, 맥박, 체온, 호흡률을 측정하였다. 하나의 데이터 단위는 총 9시간동안 측정된 9개의 수축기 혈압, 맥박, 체온, 호흡률로 구성되며 딥러닝 모델의 입력으로는 앞의 8시간 동안

의 8 개의 수축기 혈압, 맥박, 체온, 호흡률 값들이 사용된다. 딥러닝 모델의 목표 출력 값으로는 마지막 시점인 9 번째 시점의 MEWS 으로부터 계산된 환자 위험 상태가 주어진다. MEWS 값에 따라 환자 위험 상태는 다음과 같이 주어진다.

표 2. MEWS 점수별 위험 단계 구분 기준

위험 단계	점수 분포	위험 단계
0	MEWS ≤ 1	안정
1	2 ≤ MEWS ≤ 4	주의
2	5 ≤ MEWS ≤ 6	경고
3	7 ≤ MEWS	위험

시험에 사용되어진 모델들의 평가를 위해 학습 데이터 30000 개, 검증 데이터 15000 개, 테스트 데이터 15000 개를 하나의 학습, 검증, 테스트 셋으로 구성하였다. 총 5 개의 학습, 검증, 테스트 셋에 대하여 학습 결과를 검증한다.

II-2. 학습 방법 및 모델

딥러닝 모델들은 Pytorch Python 라이브러리를 사용하여 구현되었고 손실함수는 Cross entropy, 최적화를 위해 Adam optimizer 를 사용하였다. 모델 구조에 대한 설명을 다음과 같이 간략하게 요약하였다.

- CNN 구조:

Layer 1
(cnn_1): Conv1d(4, 8, kernel_size=(3,), stride=(1,), padding=(1,)), (relu_1): ReLU()
Layer 2
(cnn_2): Conv1d(8, 8, kernel_size=(3,), stride=(1,), padding=(1,)), (relu_2): ReLU()
Layer 3
(cnn_3): Conv1d(8, 8, kernel_size=(3,), stride=(1,), padding=(1,)), (relu_3): ReLU()
Layer 4 (dense): Linear(in_features=64, out_features=4, bias=True)

- LSTM 구조:

Layer 1
(lstm): LSTM(4, 120, num_layers=3, batch_first=True)
Layer 2
(dense): Linear(in_features=120, out_features=12, bias=True)

- LSTM 구조 (Onehot encoding 을 사용하는 경우):

Layer 1
(lstm_1): LSTM(4, 100, num_layers=2, batch_first=True)
(lstm_2): LSTM(4, 100, num_layers=2, batch_first=True)
(lstm_3): LSTM(4, 100, num_layers=2, batch_first=True)
(lstm_4): LSTM(4, 100, num_layers=2, batch_first=True)
Layer 2
(dense): Linear(in_features=100, out_features=4, bias=True)
* lstm_1, lstm_2, lstm_3, lstm_4 의 출력 값들을 더한 후 dense layer 에 입력함

- Input attention:

아래의 수식에서 계산된 a_t^k 를 입력 데이터에 곱하여 새로운 입력 데이터를 계산한다 [3].

$$e_t^k = V_{\epsilon}^T \tanh(W_{\epsilon} [h_{t-1}; s_{t-1}] + U_{\epsilon} x^k), a_t^k = \frac{\exp(e_t^k)}{\sum_{i=1}^n \exp(e_t^i)}$$

- EWS encoding:

입력 데이터를 MEWS 환산 테이블을 이용하여 0~3 사

이의 정수값으로 변환한다. 예) 75mmHg 값을 가지는 SBP 는 2 점으로 변환된다.

* 최종 입력으로는 3 으로 나누어 0~1 사이의 값으로 변환되어 사용되어진다.

- Onehot encoding:

EWS encoding 에서 변환된 점수 값들을 onehot encoding 된 벡터 형태의 입력으로 변환한다.

III. 실험 결과

MEWS 예측에 효율적인 모델을 찾기 위해 본문에서 설명된 모델에 대하여 5 개의 실험 데이터 군에 대해서 실험을 수행하였다. 실험 결과는 다음과 같이 주어진다.

표 3. 5개의 데이터셋에 대한 예측 정확도 (단위: %)

데이터셋/모델	1	2	3	4	5
EWS encoding+ CNN	76.3	71.0	76.7	76.2	76.9
EWS encoding+ LSTM	77.6	64.1	77.2	75.9	77.4
EWS encoding + Attention+ LSTM	76.3	68.2	76.2	75.8	76.3
Onehot encoding + LSTM	90.5	87.1	90.6	90.9	91.0

III. 결론

본 논문에서는 효율적인 MEWS 예측 알고리즘을 개발하기 위하여 다양한 모델들의 성능을 비교하였다. 실험 결과에서 입력 데이터들을 onehot encoding 하여 LSTM 을 기반으로 예측 알고리즘을 구성하는 것이 가장 효율적임을 볼 수 있었다.

ACKNOWLEDGMENT

This work was supported by Electronics and Telecommunications Research Institute (ETRI) grant funded by the Korean government. [21ZD1140, Development of ICT Convergence Technology for Daegu-Gyeongbuk Regional Industry].

참 고 문 헌

- [1] Subbe, Christian P., et al "Validation of a modified Early Warning Score in medical admissions," QJM, pp. 521-526, Oct. 2001.
- [2] Kwon, Joon-myung, et al. "An algorithm based on deep learning for predicting in-hospital cardiac arrest," Journal of the American Heart Association, Jun. 2018.
- [3] Qin, Yao, et al. "A dual-stage attention-based recurrent neural network for time series prediction," arXiv preprint arXiv:1704.02971, 2017.