

딥러닝 모델과 비침습적 데이터를 활용한 수술 중 저혈압 예측에 관한 연구

김동원¹, 신유정¹

¹성균관대학교 소프트웨어학과
kdwaha@g.skku.edu, piha@g.skku.edu

A Study on Intraoperative Hypotension Prediction using Deep Learning Model and Non-Invasive Data

Dongwon Kim¹, Youjeong Shin¹

¹Dept. of Computer Science and Engineering, SungKyunKwan University

요 약

수술 중 저혈압 예측은 환자의 안전과 직결되는 중요한 과제이다. 그러나 인간이 저혈압을 예측하는 것은 많은 경험과 노하우를 필요로 하며, 현재 연구되고 있는 예측 기술은 단일 정보를 활용하여 복합적인 원인을 반영하지 못하거나, 침습적으로 데이터를 획득하여 환자에게 불편함을 준다. 비침습적으로 수집한 데이터를 통한 저혈압 발생 예측에 대한 연구는 꾸준히 진행되어 왔으나, 기존 딥러닝을 이용한 접근방법으로는 정확도가 낮다. 본 논문에서는 그 원인을 1)데이터 전처리 2)데이터 불균형 3)기존 모델의 한계로 구분하고, 이를 해결 가능한 방안을 제시한다. 실험 결과 CNN*CNN에서 Focal Loss를 사용할 때, 가장 높은 성능을 내는 것을 확인했다.

1. 서론

수술 중 저혈압은 수술 후 심근경색이나 급성 신장손상뿐 아니라 사망률에 영향을 주는 요소[1, 2]이므로 이에 대해 현장에서는 정확한 대처가 요구된다[3]. 그러나 인간이 저혈압을 예측하는 것은 많은 경험과 노하우를 필요로 하며, 현재 연구되고 있는 예측 기술은 단일 정보를 활용하여 복합적인 원인을 반영하지 못하거나[7], 침습적으로 데이터를 획득하여 환자에게 불편함을 준다[4, 5, 6].

침습성 방법은 환자의 몸에 바늘을 침투하여 데이터를 확보하는 방법으로써 데이터를 정확히 측정할 수 있지만, 환자에게 거부감을 줄 수 있다. 이와 반대로 비침습적 방법은 여러 가지 다양한 센서들을 신체 외적으로 수집한다. 따라서 데이터 측정값에 대한 오차가 다소 발생하고, 시스템 간에 지연이 발생하여 부정확하지만, 환자에게 부담이 적어 다양한 데이터들을 광범위한 획득이 가능하다.

현재 연구되고 있는 비침습성 데이터를 활용한 예측 모델[4]은 딥러닝 모델을 사용함에도 불구하고 침습성 데이터에 비해 모델 정확도가 낮다. 본 논문에서는 딥러닝 기술을 의료데이터에 적용함에 있어 모

델 정확도가 낮은 원인을 다음과 같이 세 가지 이유로 가정한다.

- 1) 데이터 전처리의 오류
- 2) 데이터의 불균형성
- 3) 인공지능 모델의 한계

따라서 본 연구는 기존 데이터를 보정하여 시계열 데이터로 재구성하고, 데이터의 불균형성을 해결함과 동시에 다양한 인공지능 모델을 활용하여 정확도의 변화를 관찰하여 최종적으로 비침습적 데이터를 활용한 저혈압 예측에 대한 딥러닝 기반 모델의 정확도를 높이는 것을 목표로 한다.

2. 관련 연구

기존 연구에서는 고해상도의 동맥 혈압 파형 데이터만을 사용하여 모델을 구성했다[4,5,6,7,8,9]. 저해상도 비침습 데이터를 활용한 연구는 아직 활발히 진행되고 있지 않으며, 딥러닝 모델을 사용했음에도 불구하고 낮은 성능을 보였다[4]. 로지스틱 회귀모델이 딥러닝 모델들보다 정확도가 높았지만, 로지스틱 회귀모델은 동맥혈압파형 데이터에서 특징을 추출하

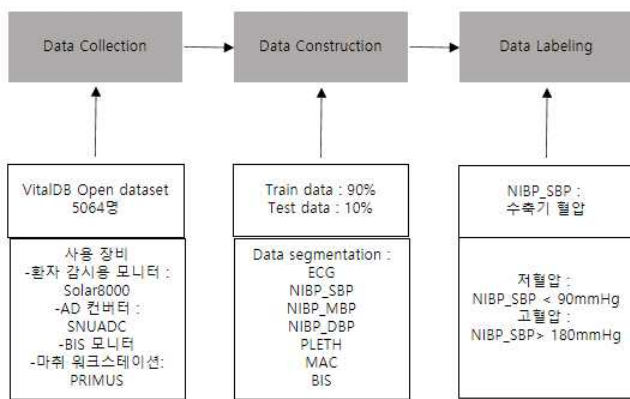
는 추가적인 단계가 있다[5, 9]. 딥러닝을 활용한 기존 연구는 대부분 CNN[4,6,7]과 LSTM[8]을 사용했다.

3. 본론

3.1 데이터 수집 및 전처리

3.1.1 데이터 수집

데이터는 Vital DB[10] 사이트에서 제공하는 환자 감시용 모니터, ADC, BIS 모니터들을 이용하여 수집한 데이터다. 본 연구에는 5,064명의 환자들의 수술 중 생체 데이터(혈압, 뇌심도, 심전도 등)를 1초 간격으로 보정된 데이터를 사용했다.



(그림 1) 데이터 전처리 과정

3.1.2 전처리

수집한 생체 데이터의 누락 값 중 시계열 데이터는 선형보간법을 이용하여 복원하였고, 혈압 데이터와 같이 numeric 데이터는 기존 값을 복사하는 방법으로 결측값을 제거했다. 분석에 사용한 생체 데이터 7개는 각각에게 Z-Score Normalization 를 이용한 특성 공학을 적용했다. 학습 데이터 구성을 위해 1분을 하나의 구간으로 설정하고, 설정한 구간의 마지막 시간을 기준으로 5분 뒤의 혈압 값을 목표값(고혈압, 저혈압, 일반혈압)으로 매칭했다.

<표 1> 데이터 속성 개요

영문 축약어	설명
ECG	심전도
NIBP_SBP	비침습적 혈압측정을 이용한 수축기 혈압
NIBP_SBP	비침습적 혈압측정을 이용한 평균 혈압
NIBP_SBP	비침습적 혈압 측정을 이용한 이완기 혈압
PLETH	체적변동기록
MAC	감시마취관리
BIS	바이스펙트럼지수

3.2 Loss 함수

수집한 의료데이터는 정상과 비정상의 비율이 8:2정도로 심각하게 불균형하다. 이러한 경우 모델이 편향되게 학습되어 정밀도(precision)와 재현율(recall)의 결과가 나쁘게 나타날 가능성이 높다. 데이터의 불균형 문제를 해결하기 위해서 up-sampling을 하거나, down-sampling을 할 수 있고, weight에 따라 배치를 조정 할 수 있으나, 많은 데이터를 처리하기 어렵고, 데이터의 손실을 최소화하기 위해서 본 연구에서는 데이터 불균형 문제를 해결하기 위해 Focal Loss를 사용했다.

<식 1> Focal Loss 정의

$$FL = -\frac{1}{N} \sum_{i=1}^N \sum_{j=1}^M y_{ij} \alpha (1 - p_{ij})^\gamma \log(p_{ij})$$

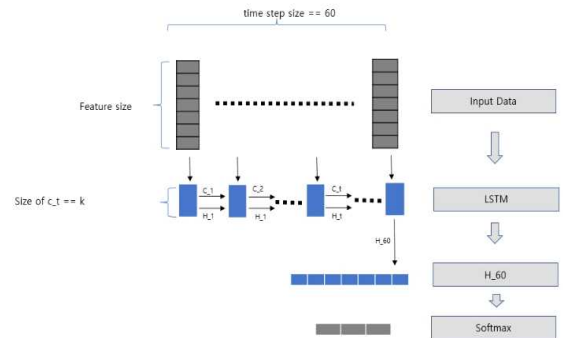
Focal Loss를 사용하면 낮은 난이도의 데이터에 낮은 학습률을 줘서 자연스럽게 불균형 데이터 학습에 대한 악영향을 낮춰준다. 본 연구에서는 이 함수가 불균형 데이터 학습에서 긍정적인 영향을 줄 것으로 기대하였다.

3.3 딥러닝 모델

각 모델에 동일한 트레이닝 파라미터를 주어 훈련을 진행하였다. 배치 크기 4096, 35 에포크 동안, keras에서 제공하는 Adam optimizer를 기본 설정 상태로 적용하였다.

3.3.1 LSTM

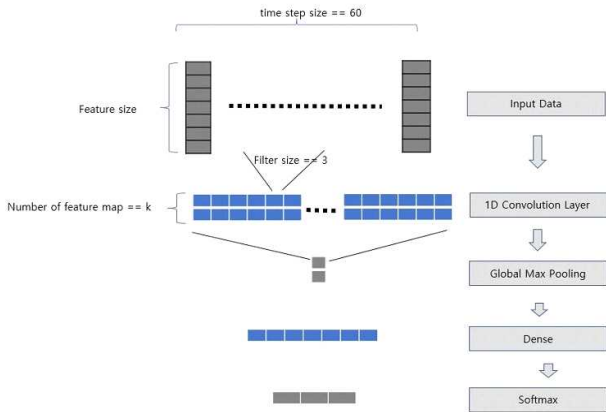
본 연구에서는 시계열 데이터의 예측에 용이한 RNN, 특히 LSTM을 통한 모델 구성을 고려하였다 [13]. 60초 동안 기록된 7개의 특징을 시간 단위로 cell state의 크기가 k인 LSTM Cell에 입력값으로 준다. LSTM Cell은 마지막 hidden state 값만 출력으로 선택하고, 그것을 크기 3의 softmax 출력층에 전달한다.



(그림 2) LSTM 모델 개념도

3.3.2 CNN

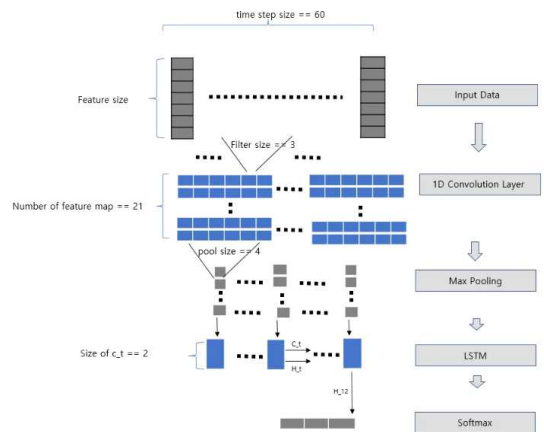
기존의 연구들에서 CNN을 통한 분석이 많았던 바[4,6,7,8], 본 연구에서도 CNN을 통한 모델 역시 구성하여 비교하도록 하였다. 7특징의 60초짜리 입력 데이터를 크기 7의 벡터 60개의 입력으로 받는다. 이 입력은 필터 크기가 3이고 특성 맵의 개수가 k인 합성곱 신경망을 통과하고, 이것을 다시 글로벌 풀링 층을 통과시킨다. 차례로 크기 7의 Dense층을 통과시킨 후 softmax층을 통과시켜 결과를 얻는다.



(그림 3) CNN 모델 개념도

3.3.3 CNN*LSTM


위에서 언급한 CNN과 LSTM을 결합하여 모델을 구성하였다. 7 특징의 60초짜리 입력 데이터를 크기 7의 벡터 60개의 입력으로 받는다. 이것을 필터 크기 3, 특성맵 개수 21의 합성곱 층에 통과시킨다. 이때 합성곱 층의 출력은 크기 21의 벡터 20개가 된다. 이것을 다시 풀 크기 4의 맥스 풀을 통과시키면 크기 21의 벡터 5개가 된다. 이것을 cell state의 크기가 k인 LSTM을 통과시킨다. 이때 LSTM은 마지막 hidden state만 출력한다.



(그림 5) CNN*LSTM 모델 개념도

3.3.3 CNN*CNN

위에서 실험한 CNN의 구조를 더 발전시켜 정확도를 높이고자 했다. 7특징의 60초짜리 입력 데이터를 크기 7의 벡터 60개의 입력으로 받는다. 이 입력은 필터 크기가 3이고 특성 맵의 개수가 42인 합성곱 신경망을 통과하고, 이것을 다시 풀 크기 4의 맥스 풀을 통과시키면 풀링 층을 통과시킨다. 이것을 다시 필터 크기가 3이고 특성맵의 개수가 63인 합성곱층, 크기 4의 맥스 풀을 차례로 통과시킨다. 그 결과를 Flatten 층을 통해 1차원으로 만들고, 크기 50의 Dense층을 통과 시킨 뒤 softmax층을 통과시켜 결과를 얻는다.



(그림 4) CNN*CNN모델 개념도

4. 실험 결과

모델의 성능평가는 AUROC값의 평균과 저혈압과 고혈압 예측의 AUPRC값의 합을 비교하는 방법을 선택하였다. AUPRC값은 불균형이 큰 소수의 경우에 대해서 더 좋은 지표가 되기에 평가지표로 선택하였다[14,15]. 본 연구에서 모델, k의 스케일, 손실 함수 3가지를 변경하며 결과를 확인해 보았고 다음은 각각의 가장 좋은 값이다.

<표 2> 모델별 결과 요약

손실함수	평가지표	CNN	LSTM	CNN*LSTM	CNN*CNN
Cross Entropy	AUPRC (저혈압+고혈압)	0.7914	0.9582	0.7557	0.9673
	Mean AUROC	0.9030	0.9176	0.9151	0.9189
Focal Loss	AUPRC (저혈압+고혈압)	0.7951	0.9095	-	0.9685
	Mean AUROC	0.9072	0.9134	-	0.9198
기존연구	Mean AUROC	0.889	-	-	-

5. 결론

기존 연구들에서는 낮은 해상도의 비침습적 데이터에서 딥러닝 모델의 정확도는 침습적 데이터와 비교해 낮은 값을 가졌다. 이번 연구에서 Focal Loss를 통한 데이터 불균형 처리, 전처리 과정의 오류 처리, 모델의 차별화 세 측면에 집중하여 실험해본 결과

기존 비침습적 모델보다 향상된 성능 결과를 얻을 수 있었다.

사사문구

이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2020-0-00990, 5G-IoT 환경에서 이기종·비정형·대용량 데이터의 고신뢰·저지연 처리를 위한 플랫폼 개발 및 실증)

참고문헌

- [1] Vafi Salmasi, Kamal Maheshwari, Dongsheng Yang, Edward J. Mascha, Asha Singh, Daniel I. Sessler, Andrea Kurz, "Relationship between Intraoperative Hypotension, Defined by Either Reduction from Baseline or Absolute Thresholds, and Acute Kidney and Myocardial Injury after Noncardiac Surgery: A Retrospective Cohort Analysis," *Anesthesiology*,126(1):47-65.
- [2] Lee, Eun Joon¹ ·Shim, Mi Young² ·Song, Suk Heel ·Lee, Mimi³ · Kim, Hye mi⁴ ·Kang, Bong Sun⁴ ·Yang, Eun Jeon⁴ ·Lim, Ji Young⁴ ·Kim, Jin A⁴ ·Lee, Mina⁴, "외과계 중환자실의 심망 발생 위험 요인 조사연구", *Journal of Korean Critical Care Nursing* Vol. 3, No. 2, p37-48, (2010)
- [3] Laurent Lonjaret,¹ Olivier Lairez,² Vincent Minville,³ and Thomas Geeraerts³ "Optimal perioperative management of arterial blood pressure". *Integr Blood Press Control.* (7),p49 - 59,(2014)
- [4] Solam Lee, Hyung-Chul Lee, Yu Seong Chu, Seung Woo Song, Gyo Jin Ahn, Hunju Lee, Sejung Yang, Sang Baek Koh. "Deep learning models for the prediction of intraoperative hypotension." *British Journal of Anaesthesia.* 126(4). (2021).
- [5] Feras Hatib, Zhongping Jian, Sai Buddi, Christine Lee, Jos Settels, Karen Sibert, Joseph Rinehart, Maxime Cannesson; . "Machine-learning Algorithm to Predict Hypotension Based on High-fidelity Arterial Pressure Waveform Analysis". *Anesthesiology* 129:663 - 674 (2018)
- [6] 이지현. "수술 환자 저혈압 발생 예측을 위한 생체신호 분석 인공지능 모델 개발." 국내석사학위논문 순천향대학교 대학원. 충청남도, 2020
- [7] Jacobsson, M., Navid, Z., Thorir, S., Håkan, B., Caroline, H S. "Deep Learning-Based Early Prediction of Intraoperative Hypotension"43rd Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE EMBC'21)(2021)
- [8] Choe S, Park E, Shin W, Koo B, Shin D, Jung C, Lee H, Kim J. "Short-Term Event Prediction in the Operating Room (STEP-OP) of Five-Minute Intraoperative Hypotension Using Hybrid Deep Learning: Retrospective Observational Study and Model Development". *JMIR Med Inform* ;9(9):e31311 . DOI: 10.2196/31311, (2021)
- [9] Maheshwari, K., Buddi, S., Jian, Z. et al. "Performance of the Hypotension Prediction Index with non-invasive arterial pressure waveforms in non-cardiac surgical patients." *J Clin Monit Comput* 35(1) : 71 - 78 . <https://doi.org/10.1007/s10877-020-00463-5> (2021)
- [10] <https://vitaldb.net/>
- [11] De Boer, P-T., Kroese, D.P, Mannor, S. and Rubinstein, R.Y. "A Tutorial on the Cross-Entropy Method. *Annals of Operations Research*", 134 (1), 19-67. (2005).
- [12] Lin, Tsung-Yi, et al. "Focal loss for dense object detection." *Proceedings of the IEEE international conference on computer vision.* (2017)
- [13] Y. Wang, S. Zhu and C. Li, "Research on Multistep Time Series Prediction Based on LSTM," 2019 3rd International Conference on Electronic Information Technology and Computer Engineering (EITCE), 2019, pp. 1155-1159
- [14] Saito, Takaya, and Marc Rehmsmeier. "The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets." *PloS one* 10.3 (2015): e0118432.
- [15] Jesse Davis Mark Goadrich. (2006)"The Relationship Between Precision-Recall and ROC Curves"*ICML(6)* P233-240