

영상광용적맥파 기반 혈압 추정: 관심 영역 지정 여부에 따른 딥러닝 성능 평가

김연준^{1,2}, 김진원^{2,3}, 이성한², 정인철^{2,3*}

¹한림대학교 소프트웨어학부

²한림대학교 뇌혈관질환선도연구센터

³한림대학교 인공지능융합학과

yeonjunkim70@gmail.com, *incheol.jeong@hallym.ac.kr

Impact of Region-of-Interest on Deep Learning Performance in Imaging Photoplethysmography-based Blood Pressure Estimation

Yeonjun Kim^{1,2}, Jinwon Kim^{2,3}, Sunghan Lee², In cheol Jeong^{2,3*}

¹Department of Software Engineering, Hallym University

²Cardiovascular Disease Research Center, Hallym University

³Department of Artificial Intelligence Convergence, Hallym University

요약

본 연구는 영상 기반 딥러닝을 이용한 혈압 추정에서 관심 영역(region of interest, ROI) 설정 여부가 모델 성능에 미치는 영향을 검증하였다. 자체 수집한 데이터로 합성곱 신경망 (convolutional neural network, CNN)과 양방향 게이트 순환 신경망 (bidirectional gated recurrent unit, BiGRU) 을 합성한 모델을 학습하였다. ROI 기반 입력 구조와 전체 영상 입력 구조를 비교한 결과, 전체 영상 입력 모델이 수축기 혈압 2.93 mmHg, 이완기 혈압 4.90 mmHg 의 평균 절대 오차 (mean absolute error, MAE)를 기록하며 가장 우수한 성능을 보였다. 또한 학습, 검증, 시험 데이터셋 간 성능 편차가 낮아 안정적인 학습 특성이 확인되었다. 이러한 결과는 ROI 지정 과정 없이도 정확하고 편리한 비접촉식 연속 혈압 모니터링이 가능함을 시사하며, 임상 및 일상 환경에서의 활용 가능성을 제고한다.

I. 서론

가. 연구 배경

혈압은 임상 현장에서 환자의 건강 상태를 평가하는 핵심적인 생리학적 지표이다 [1]. 기존의 측정 방식은 침습적 방법과 비침습적 방법으로 구분된다. 침습적 방법은 높은 정확도를 제공하나 일상적 적용이 어렵고, 비침습적 방법 중 커프 (cuff) 기반 측정은 압박감과 불편감으로 인해 연속적 측정에 한계가 있다 [2, 3]. 심전도 (electrocardiography, ECG)와 광용적맥파 (photoplethysmography, PPG)를 활용한 맥박 전달 시간 기반 혈압 추정은 연속 측정에 유리하지만, 신체에 전극 및 광센서를 부착해야 하므로 사용자 편의성이 떨어진다. 이러한 제약을 극복하기 위해 최근에는 영상광용적맥파 (imaging PPG, iPPG)를 활용한 비접촉 혈압 추정 기술이 활발히 연구되고 있다 [4]. iPPG는 카메라 영상에서 피부 표면의 미세한 색 변화를 분석하여 맥파를 추출하고, 이를 통해 혈압을 간접적으로 산출하는 방식이다. 기존 연구들은 일반적으로 피부 영역을 관심영역 (region of interest, ROI)으로 지정하여 신호를 추출하고, 이를 딥러닝 모델에 입력하는 절차를 거친다 [5, 6]. 그러나 ROI 는 수작업 지정 또는 별도의 검출 알고리즘이 필요해 실제 적용에서 제약이 따른다. 본 연구는 ROI 를 지정하지 않고 전체 영상으로부터 직접 신호를 학습하는 딥러닝 기반 혈압 추정 모델을 제안하고, 이를 ROI 기반 모델과 비교하여 성능을 검증함으로써 보다 간편하고 실용적인 접근법을 제시하고자 한다.

II. 본론

나. 데이터 수집 및 전처리

혈압 추정을 위한 데이터를 수집하기 위해 그림 1 과 같이 PPG 와 영상을 동시에 획득하는 실험을 구성하였다. 실험은 심폐 장애 및 움직임에 제한이 없는 19 세 이상의 건강한 성인 남녀 30 명을 대상으로 진행되었으며, 한림대학교 생명윤리위원회 (HIRB-2024-014)의 승인을 받아 수행되었다. 혈압 추정을 위한 데이터는 그림 1-(a)

와 같이 PPG 와 영상 신호를 동시에 획득하는 실험을 통해 수집하였다. 영상데이터는 EX-F1 카메라 (Casio Computer Co., Ltd., Japan)를 이용해 해상도 384×512, 초당 30 프레임으로 얼굴과 왼손바닥을 촬영하여 수집하였다. 왼손 검지에는 반사형 PPG 센서 (BN-PPGED, BIOPAC Systems Inc., USA)를 착용하여 1,000 Hz 로 신호를 기록하였으며, 오른팔에는 혈압계를 부착하여 데이터 수집 시작 시점, 5 분, 종료 시점에 각각 측정하였다. 세 가지 신호는 동기화 과정을 거쳐 동시에 확보되었다. 실험은 안정 시와 경미한 운동 단계로 구성되었다 (그림 1-(b)). 안정 단계에서 참가자는 침대에 누운 상태로 10 분간 신호를 측정하였으며, 이후 2 분간 스태밍을 이용한 운동을 수행하였다. 전체 30 명 중 동기화에 실패한 18 명을 제외하고, 최종적으로 12 명의 데이터가 분석에 활용되었다. 획득된 혈압 값은 200 초 단위로 구간화 하여 레이블로 할당하였으며, 영상은 10 초 단위로 분할 후 PPG 및 혈압 값과 동기화하였다. 관심 영역 설정 여부에 따른 성능 비교를 위해 아래와 같이 네 가지 입력 구조를 구성하였다:

- 1 손 ROI: 왼손바닥의 중앙에서 30×30 영역 추출
- 2 얼굴 ROI: 코와 눈을 제외한 왼쪽 볼에서 30×30 영역 추출
- 3 다중 ROI: 손 ROI 와 얼굴 ROI 를 함께 사용
- 4 전체 영상: 전체 프레임을 다운 샘플링 (128×128)

다. 모델 학습

그림 1-(c)는 제안하는 모델의 구조를 나타낸다. 입력 데이터는 두 개의 CNN 블록 (3×3 커널, 채널 수 16 및 32)을 거쳐 공간적 특징을 추출하였다. 이후 BiGRU 블록에서 50 차원의 시계열 특징을 추출하였으며, 양방향 구조를 통해 최종 100 차원 벡터로 변환하였다. 입력 구조 1 (손 ROI), 2 (얼굴 ROI), 4 (전체 영상)은 동일한 모델 구조를 적용하였다. 입력 구조 3 (다중 ROI)은 손 ROI 와 얼굴 ROI 를 각각 독립적으로 CNN-BiGRU 모델에 입력한 후, 각각의 100 차원 특징 벡터를 병합하여

200 차원 벡터를 형성하였다. 이후 선형 계층을 통해 차원을 축소하여, 수축기 혈압 (systolic blood pressure, SBP)과 이완기 혈압 (diastolic blood pressure, DBP)을 mmHg 단위로 추정하도록 설계하였다. 모델 학습은 평균 절대 오차 (mean absolute error, MAE)를 손실 함수로, Adam 최적화 알고리즘 (학습률 0.001)을 사용하였다. 배치 크기는 16, 학습 에포크는 200 으로 설정하였다. 데이터셋은 피험자 단위로 분리하여 3-폴드 교차 검증을 수행하였으며, 12 명의 데이터 중 학습 8 명, 검증 2 명, 시험 2 명으로 구분하여 모델을 평가하였다.




그림 1 실험 절차 개요도. (a) 실험 참가자 촬영 장면 및 ROI 예시; (b) 실험 과정 개요도; (c) 모델 구조도

라. 결과

표 1 은 입력 구조 별 시험 데이터셋 성능을 평균 절대 오차 (mean absolute error, MAE)로 평가한 결과이다. Hand ROI, Face ROI, Multi ROI 입력 모델은 각각 SBP 8.97, 8.96, 8.97 mmHg, DBP 8.55, 8.45, 8.45 mmHg 로 유사한 성능을 보였다. 반면 전체 영상 입력 모델은 SBP 2.93 mmHg, DBP 4.90 mmHg 로 가장 우수한 성능을 기록하였다.

Input data	SBP (MAE±STD)	DBP (MAE±STD)
Hand ROI	8.97 ± 00.32	8.55 ± 0.11
Face ROI	8.96 ± 06.63	8.45 ± 6.55
Multi ROI	8.97 ± 11.14	8.45 ± 6.54
All Frame	2.93 ± 02.05	4.90 ± 4.35

SBP: systolic blood pressure, DBP: diastolic blood pressure, MAE: mean absolute error, STD: standard deviation, ROI: region of interest

표 1 입력 구조에 따른 모델의 성능

표 2 는 전체 영상 입력 모델의 학습, 검증, 시험 데이터셋별 성능을 나타낸다. SBP MAE 는 각각 2.62, 2.89, 2.93 mmHg, DBP MAE 는 4.94, 4.86, 4.90 mmHg 로, 세 데이터셋 간 성능 편차가 작았다.

Data set	SBP (MAE±STD)	DBP (MAE±STD)
Train	2.62±2.12	4.94±4.38
Validation	2.89±1.98	4.86±4.33
Test	2.93±2.05	4.90±4.35

표 2 전체 영상 입력 모델의 데이터 세트 별 성능

III. 논의

표 1 의 결과는 ROI 기반 모델보다 전체 영상 입력 모델이 더 효과적으로 학습되었음을 보여준다. ROI 방식은 수작업 지정 또는 별도 검출 알고리즘이 필요해 실제 적용에서 제약이 크다. 반면 전체 영상 입력 방식은 추가 절차 없이도 높은 정확도를 달성하여, 사용성과 성능 모두에서 우수함을 입증하였다. 이는 비접촉식 혈압 추정 기술의 실제 적용 가능성을 뒷받침한다.

다만 본 연구는 제한된 데이터셋에 기반한다는 한계를 가진다. 학습·검증·시험 데이터가 총 12 명으로 각각 8 명, 2 명, 2 명으로 구성되어 결과의 일반화 가능성이 충분히 확보되지 않았을 수 있다. 향후 연구에서는 본 연구 데이터 전수를 포함한 확장된 데이터와 공개 데이터셋을 활용하여 다양한 조건에서 성능을 검증할 필요가 있다.

IV. 결론

본 연구는 영상 기반 혈압 추정에서 ROI 설정 여부가 딥러닝 모델 성능에 미치는 영향을 평가하였다. 직접 수집한 30 명의 데이터 중 12 명을 활용하여 CNN-BiGRU 기반 모델을 학습한 결과, ROI 입력 모델들은 유사한 성능을 보였으나 전체 영상 입력 모델은 SBP 2.93 mmHg, DBP 4.90 mmHg 의 MAE 로 가장 우수한 성능을 기록하였다. 또한 학습, 검증, 시험 데이터셋 간 성능 차이가 작아 안정적인 학습을 확인할 수 있었다. 데이터 규모가 제한적이라는 한계는 존재하지만, 향후 확장된 데이터셋으로 검증할 경우 ROI 지정 과정을 생략한 영상 기반 혈압 추정이 정확성과 신뢰성을 동시에 확보할 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

이 논문은 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NR070859)

참 고 문 헌

- [1] S. Magder, "The meaning of blood pressure," Critical Care, vol. 22, p. 257, 2018. doi: 10.1186/s13054-018-2171-1.
- [2] A. S. Meidert and B. Saugel, "Techniques for non-invasive monitoring of arterial blood pressure," Frontiers in Medicine, vol. 4, p. 231, 2018. doi: 10.3389/fmed.2017.00231.
- [3] A. Charmoy, G. Würzner, et al., "Reactive rise in blood pressure upon cuff inflation: cuff inflation at the arm causes a greater rise in pressure than at the wrist in hypertensive patients," Blood Pressure Monitoring, vol. 12 (5), p. 275, 2007. doi: 10.1097/MBP.0b013e3282c9ac9a.
- [4] R. H. Goudarzi, S. Mousavi, and M. Charmi, "A Novel Method for Blood Pressure Estimation Using an Imaging Photoplethysmography (iPPG) Signal," Sensors, vol. 22, no. 18, p. 7037, 2022. doi: 10.3390/s22187037.
- [5] R. Meng and K. Li, "A blood pressure prediction method based on imaging photoplethysmography in combination with machine learning," Biomedical Signal Processing and Control, vol. 62, p. 102328, 2020. doi: 10.1016/j.bspc.2020.102328.
- [6] H. Cheng, J. Xiong, J. Chen, et al., "Deep learning-based non-contact iPPG signal blood pressure measurement research," Sensors, vol. 23, no. 12, p. 5528, 2023. doi: 10.3390/s23125528.