

휴대용 및 웨어러블 측정기를 위한 ECG와 PPG 신호를 활용한 합성곱 신경망 알고리즘 기반의 비가압식 혈압 추정 방법⁺

(Cuffless Blood Pressure Estimation Based on a Convolutional
Neural Network using PPG and ECG Signals for Portable or
Wearable Blood Pressure Devices)

조진우¹⁾, 최아영^{2)*}
(Jinwoo Cho and Ahyoung Choi)

요약 본 논문에서는 시계열 심전도 (Electrocardiogram: ECG) 및 광전용맥파 측정센서 (Photoplethysmography: PPG)을 이용하여 혈압을 추정하는 알고리즘을 제안한다. 혈압 (Blood pressure: BP)을 추정하기 위해 주기적 입력 신호를 생성하고 차동 및 임계값 방법에 따라 잡음을 제거한 다음 합성곱 신경망 알고리즘을 기반으로 하여 수축기 혈압과 이완기 혈압을 예측한다. 본 논문에서 사용된 데이터는 MIMIC 데이터베이스에서 총 3.1GB의 49명의 환자 데이터를 사용하였다. 실험 결과 수축기 혈압의 평균 제곱근 오차는 5.80mmHg, 이완기 혈압의 예측 오차는 2.78mmHg을 나타내었다. 또한, 영국 고혈압 협회가 제안한 혈압계 평가 방법을 적용하였을 때, 최고 성능인 등급 A를 만족함을 확인할 수 있었다.

핵심주제어: 비가압식 혈압 추정방법, 합성곱 신경망, 심전도 신호, 광전용맥파 신호

Abstract In this paper, we propose an algorithm for estimating blood pressure using ECG (Electrocardiogram) and PPG (Photoplethysmography) signals. To estimate the BP (Blood pressure), we generate a periodic input signal, remove the noise according to the differential and threshold methods, and then estimate the systolic and diastolic blood pressures based on the convolutional neural network. We used 49 patient data of 3.1GB in the MIMIC database. As a result, it was found that the prediction error (RMSE) of systolic BP was 5.80mmHg, and the prediction error of diastolic BP was 2.78mmHg. This result confirms that the performance of class A is satisfied with the existing BP monitor evaluation method proposed by the British High Blood Pressure Association.

Keywords: Cuff-less blood pressure estimation, Convolutional neural network, ECG, PPG

* Corresponding Author: aychoi@gachon.ac.kr

+ 이 논문은 2019년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(NRF-2019R1F1A1060731), 2019년도 가천대학교 교내연구비 지원에 의한 결과임. (GCU-2019-0386)

Manuscript received November 18, 2019 / revised April 20, 2020 / accepted April 21, 2020

1) 뷰노 연구원, 제1저자

2) 가천대학교 소프트웨어학과, 교신저자

1. 서론

고혈압은 전 세계적으로 10 억 명이 넘는 사람들이 앓고 있는 질환으로 주기적인 모니터링을 통해 혈압을 관리하는 것이 중요하다. 이를 모니터링하기 위해 대표적으로 사용되고 있는 방법은 Babbs (2012)이 제안한 커프를 착용하여

커프에 주입된 압력 변화로부터 혈압을 측정하는 오실로메트리(Oscillometry) 방식이 있다. 오실로메트리는 측정하기 쉽고 정확도가 높아 널리 사용되고 있으나, 동맥을 압축하기 위해서는 커프 및 공기 주입 장치가 필요하기 때문에 장치의 크기가 커지고 일상생활에서 연속적인 측정이 쉽지 않다. 따라서 웨어러블 또는 모바일 환경에서 사용하기가 어렵다.

이러한 문제를 해결하기 위하여, 모바일 환경에서 측정할 수 있는 PPG (Photoplethysmography) 센서, ECG (Electrocardiogram) 센서에 대한 연구가 이루어지고 있다 (Choi et al., 2009; Cho et al., 2014; Rundo et al., 2018, Lee et al., 2019). Rundo et al. (2018)은 웨어러블 환경에서 심장과 관련한 혈압, 심박수 등을 측정하고 모니터링 할 수 있도록 Cellular Neural Network을 적용하여 ECG와 PPG 신호의 정상 패턴을 모니터링 하는 연구를 수행하였다. Lee et al. (2019)은 운전자의 졸음 감지를 위하여 ECG와 PPG 신호의 Recurrence Plot 기반의 특징을 추출해서 합성곱 신경망 알고리즘을 통해 졸음상태와 깨어있는 상태를 분석하였다. 이와 같이 최근 웨어러블 환경에서의 ECG, PPG 측정 및 신호처리와 딥러닝 기반의 알고리즘들이 적용되고 있다. 그러나 ECG와 PPG로 혈압을 예측하는 응용은 상용화 가능한 수준으로 연구가 이루어지고 있지 않다.

기존의 혈압을 ECG와 PPG로 측정하기 위한 방법으로 펄스 전이 시간 (Pulse transition time: PTT) 또는 펄스 도달 시간 (Pulse arrival time: PAT)에 기초하여 혈압 값을 획득하기 위한 간접적인 접근법이 제안되었다 (Allen et al, 1981; Wippermann et al., 1995; Naschitz et al., 2004; Payne et al., 2006). 펄스 전이시간 혹은 펄스 도달 시간은 맥박파전파속도 (Pulse wave velocity: PWV)에 상호비례적인 관계가 있고, PWV는 혈압과 연관성을 가지고 있으므로 이를 통해 혈압을 유추한다. 그러나 이 방식은 PTT나 PAT가 혈압뿐만 아니라 동맥의 탄성도, 경화도 등의 특성에 따라 변화하므로 주기적으로 혈관 특성이 변화할 때 마다 모델의 파라미터를 갱신해 주어야 하는 문제점이 있다 (Chen et al., 2000; Kim et al., 2015;

Ding et al., 2016).

이러한 문제를 해결하기 위해 최근 다양한 분야에서 머신러닝 및 딥러닝 기술이 적용되고 있다 (Choi et al., 2019; Chung and Lee, 2018; Lee et al., 2019). 헬스케어 분야에서도 최신의 딥러닝 기술을 적용하여 혈압을 예측하는 연구가 수행이 되었다 (Baker, 1990; Forouzanfar et al., 2011; Ruiz-Rodríguez et al., 2013; Zhang et al., 2017; Lee et al., 2017). Ruiz-Rodríguez et al. (2013)은 심층 네트워크 제한 볼츠만 머신 (Deep belief network - Restricted Boltzman machine, DBN-RBM)을 기반으로 커프 내의 압력 진동을 나타내는 오실로메트리 파형 또는 오실로메트리 파형 엔벨로프에 파형을 도출하여 혈압을 예측하는 방식을 제안하였다. 또한, 기존 연구자들은 합성곱신경망 (Convolutional neural network: CNN) 기반으로 하여 오실로메트리 파형을 통해 혈압을 측정하는 방법을 제안하였다 (Baker, 1990; Forouzanfar et al., 2011; Zhang et al., 2017; Lee et al., 2017). Lee et al. (2017)은 오실로메트리 파형의 특징값을 추출하여 DBN (Deep faith network) 및 DNN (Deep neural network)을 적용하여 혈압을 예측하는 알고리즘을 제안하였다. 기존의 대부분의 연구는 혈압의 직접적인 특성을 분석할 수 있는 오실로메트리 파형을 예측하여 파형을 통해 혈압을 도출하는 연구를 수행하였는데, 실제 오실로메트리 방식의 경우 웨어러블 또는 모바일 환경에서 사용하기 어려운 단점이 있으며 연속적으로 혈압을 예측이 어려운 단점이 있다.

따라서 본 논문에서는 웨어러블 기기에서 쉽게 측정 할 수 있는 시계열 ECG 및 PPG를 기반으로 혈압을 예측하는 알고리즘을 제안한다. ECG나 PPG의 신호 자체는 혈압의 특성을 반영하기 어려운 성질을 가지고 있으나, 혈압이 변할 때 ECG와 PPG의 진폭과 패턴의 변화가 발생한다는 것을 기반으로 딥러닝 알고리즘인 합성곱신경망 알고리즘을 기반으로 혈압을 예측하는 방법을 제안한다. 전반적인 데이터 프로시저는 Fig. 1과 같다. 공용 데이터베이스를 통해 데이터를 수집한 후, 데이터 프로세싱 과정을 거쳐 잡음과 아웃라이어 제거하고, ECG, PPG의 한주기 데이터를 획득하여 입력 데이터를 생

성한다. 입력 데이터로는 ECG 및 PPG의 원시 파형 데이터를 사용하였고, 출력 데이터로 연속 혈압 파형에서 도출한 최고 혈압과 최저 혈압 값을 사용하였다. 이후 입출력 데이터를 기반으로 합성곱신경망 모델에 학습을 시켜 최고혈압과 최저혈압을 구한다. 본 논문은 다음과 같은 방식으로 서술되어 있다. 2장에서는 제안하는 방식에 대한 프로세스와 알고리즘을 소개하고, 3장에서는 실험을 통해 도출한 결과를 소개하고 4장에서 결론을 맺는다.

2. 혈압예측 알고리즘

2.1 데이터 처리 방법

데이터 처리는 크게 4 단계로 나뉘어져 있다. ECG, PPG 및 연속 혈압 파형에 대한 잡음 필터링, 데이터 세분화, 이상치 제거 및 데이터 셔플링을 수행하였다. 첫 번째 단계로 잡음 필터링을 위해 표본 윈도우 크기가 100 인 이동 평균화 방법으로 저역 통과 필터링을 적용하였다. 두 번째 단계는 데이터 분할 프로세스로 주석이 달린 연속 혈압 값과 최대 피크를 기반으로 동일한 윈도우의 PPG와 ECG를 세그먼트화하였다. 연속 혈압 파형에서 최저 혈압값을 기준으

로 한주기 길이에 해당하는 ECG와 PPG 신호를 추출하였다. 추출한 데이터는 150×2 차원의 행렬에 저장하여 입력 데이터를 생성한다. 표본의 길이를 150으로 지정한 이유는 평균적으로 한주기 데이터의 길이가 150개 표본으로 획득되었기 때문이며, 한 주기에 150개 미만의 표본이 있는 경우 데이터를 0으로 채웠다.

세 번째 단계로 이상 값 제거 프로세스를 적용하였다. 데이터 분포는 정규 분포로 가정하여 데이터 분포의 99 %를 포함하는 범위는 $\mu \pm 3\sigma$ 로 가정하여 일반적으로 발생할 수 없는 범주의 데이터를 일차적으로 제거하였다. 여기서 μ 는 평균 값이고 σ 는 표준 편차이다. 또한 Table 1과 같이 Sun et al. (2006)이 제안한 기준을 적용하여 비정상적인 신호 유형을 파악하고 제거하였다.

Table 1에서 SBP는 최고혈압, DBP는 최저혈압을 의미하며, 맥압 (Pulse pressure)는 최고혈압과 최저혈압의 차이를 의미한다. SBP[t]는 시간 t 시점에서 측정된 최고혈압을 의미하며, SBP[t-1]는 1 표본 이전에 측정된 최고혈압을 의미한다. 본 연구에서는 300mmHg 이상의 최고혈압, 20mmHg 미만의 최저혈압 및 20mmHg 미만의 펄스 압력을 잡음으로 간주하였다. 또한, 맥압이 20mmHg 미만인 경우, 현재 측정혈압과 이전에 측정된 혈압이 20mmHg 이상 차이가 나는 경우도 측정 오류로 간주하였다. 측정값이

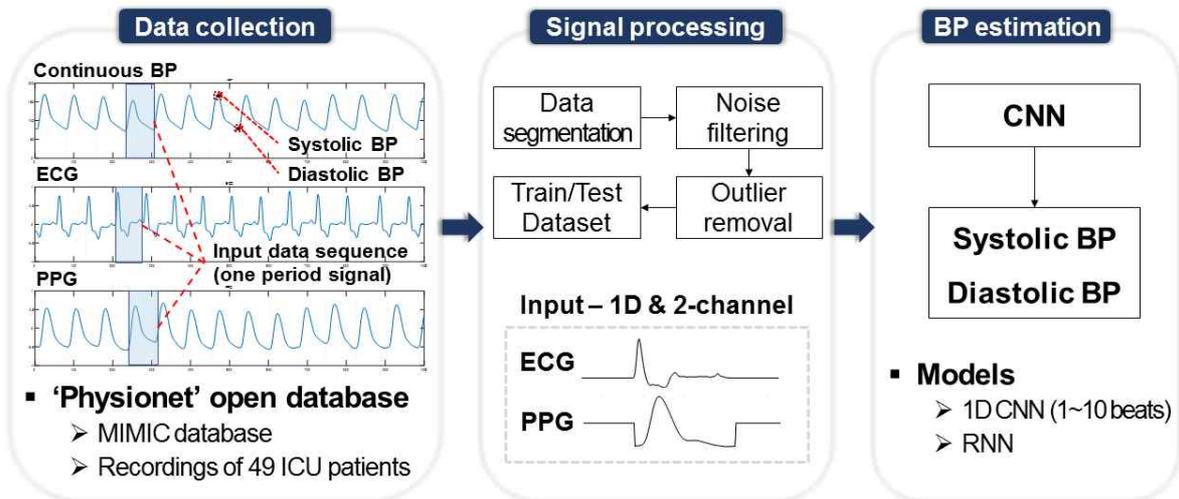


Fig. 1 Data Processing Procedure

지속적으로 0이 기록이 되거나 nan으로 측정이 안된 비정상적인 형태의 ECG 및 PPG 및 ECG 신호를 제거하였다. ECG, PPG 데이터에서 발생되는 잡음은 Fig. 2와 같고, 연속 혈압 신호의 잡음 처리 결과는 Fig. 3과 같다.

마지막으로 데이터 셔플링을 수행하여 혈압 값 데이터를 그룹화 하여 1 mmHg 간격으로 저장하고, 그룹 간에 데이터를 무작위로 혼합하였다.

2.2 합성곱신경망 기반 혈압 예측 모델

혈압 예측을 위해서 본 논문에서는 Fig. 4는와 같은 합성곱신경망 모델의 구조를 사용하였다.

기존에는 Fully-connected NN을 사용하여 PPG를 기반으로 혈압을 예측하는 연구들이 수행이 되었다 (Xing and Sun, 2016; Wang et al., 2018). 일반적으로 Fully connected NN을 사용하는 경우 입력 신호로부터 특징값을 추출하여 NN의 입력으로 사용한다. 특징값을 추출

하기 위해서 Xing 등은 FFT를 적용하여 Phase와 Amplitude 값을 입력으로 사용하였으며, Wang et al. (2018)은 Spectral Feature Extraction과 신호의 형태를 나타내는 수학적인 모델을 통해 특징을 추출하였고, 추출한 특징값을 NN에 적용하여 결과를 획득하였다. 그러나 Fully-connected NN에 의한 예측 방식은 일반적으로 도출한 특징값이 많을수록 성능이 향상되고, 추출된 특징이 데이터베이스가 바뀌면 성능이 보장되지 않는 경우가 발생한다. 따라서 본 연구에서는 특징값을 입력으로 사용하는 것이 아니라 Raw 데이터를 입력으로 넣고, CNN을 적용하여 특징 값을 도출하고, NN을 적용하여 혈압을 예측하는 모델을 제안한다.

제안한 모델은 2채널 및 3개의 Convolution Layer와 1개의 Fully-connected Layer를 로 구성되어 있다. 데이터 처리 후 ECG 및 PPG 데이터는 2 차원 CNN 입력으로 사용된다. 입력 시퀀스 매트릭스의 크기는 150×2 이며, 입력 데이터

Table 1 Abnormality Criteria of Signals

Signal	Criteria
Systolic BP (SBP)	> 300mmHg
Diastolic BP (DBP)	< 20mmHg
Pulse pressure (SBP-DBP)	< 20mmHg
SBP[t]-SBP[t-1]	> 20mmHg
DBP[t]-DBP[t-1]	> 20mmHg
PPG	sum(PPG) = 0 or isnan (PPG)
ECG	sum(ECG) = 0 or isnan (ECG)

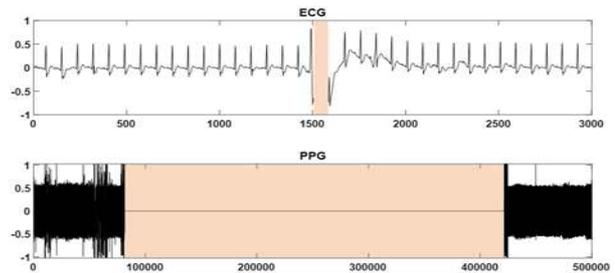


Fig. 2 Noise of ECG and PPG Signals

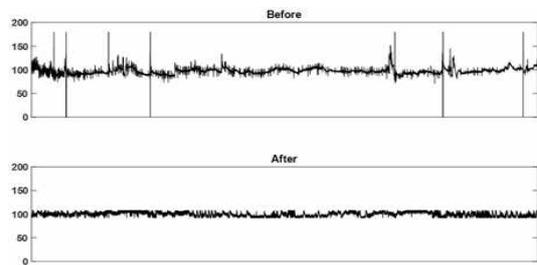


Fig. 3 Noise Removal of Continuous BP Signal

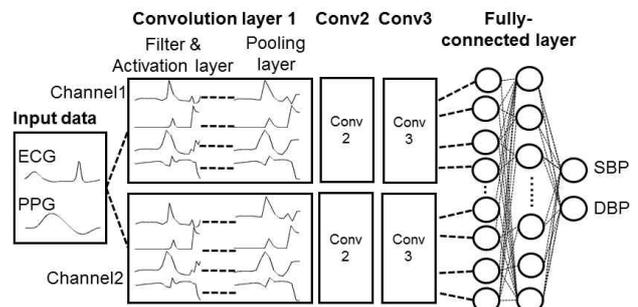


Fig. 4 Overall Architecture of CNN Model

는 필터 사이즈 2와 5인 1차원 필터를 갖는 합성곱 연산을 통해 특징맵을 출력한다. 각각의 Convolution Layer에서는 ReLU 활성화 함수를 사용하였으며, 데이터 크기를 줄이는데 사용하는 Pooling Layer에서 최대값을 찾는 Max-pooling을 적용하여 결과를 획득하였다. 마지막으로 Convolution Layer 출력을 평탄화하고 결합하여 Fully-connected Layer로 데이터를 전달하여 최종적으로 최고혈압 (SBP) 및 최저혈압 (DBP) 값을 출력하도록 하였다. 최상의 학습 매개 변수를 얻기 위해 필터 크기, 필터 수, 풀링 방법 및 레이어 수를 변경하여 Table 2와 같은 파라미터를 도출하였다.

Table 2 Parameters of CNN Model

Features	Numbers
Number of features	32, 64, 128
Number of feature maps	6
Number of hidden layers	3
Dropout ratio	0.5
Learning rate for weight	0.0001
Mini-batch size	2048
Iterations	500

학습 및 테스트 데이터를 생성하기 위해 Bootstrap 방법과 Stratified Split 방법을 사용하여 학습 데이터와 테스트 데이터를 나누었다. 일반적으로 자연 신호는 중심 한계 정리로 인해 데이터의 양이 무한대인 경향이 있으므로, 정규 분포를 따르는 특성을 갖는다. 혈압 분포의 경우, 데이터의 양이 매우 많을 때 이러한 분포가 따르지만 저혈압 또는 고혈압 영역의 데이터는 상대적으로 부족하기 때문에 고혈압 혹은 저혈압의 경우 예측 오류가 증가하는 문제가 발생할 수 있다. 따라서 이 문제를 최소화하기 위해 데이터 표본이 적은 영역의 무게를 조정하기 위해 Bootstrap 방법을 적용하여 데이터가 적은 부분의 데이터를 Bagging 하여 추가적으로 획득하였으며, Stratified Split을 적용하여 인식 정확도를 향상시켰다. Stratified Split은 테스트와 트레이닝 데이터를 구분할 때 데이터 분포가 균일하지 않

는 경우 테스트와 트레이닝 데이터 분포를 동일한 분포가 되도록 데이터를 만드는 과정을 의미한다. 랜덤하게 일정 데이터를 뽑아 트레이닝 하는 경우, 최고혈압의 예측 오차가 특정 사용자의 경우 14.92mmHg에서 19.52mmHg 까지 증가하였으나, Stratified Split을 적용한 경우 평균 최고혈압 예측 오차는 5.80 mmHg ± 5.0 mmHg 으로 정확도가 향상이 되었다.

3. 실험결과 및 분석

3.1 데이터 셋

본 논문에서는 MIT-BIH MIMIC 데이터베이스를 사용하여 제안한 방법을 검증했다 (Moody and Mark, 1996; Goldberger et al, 2000). MIMIC에서 ICU 환자의 멀티파라미터 파형 데이터를 사용하였다. 총 3.1GB 크기의 49 명의 ICU 환자에 대한 총 240 만 개의 레코드가 포함되어 있으며, 남성 데이터는 30개 여성 데이터는 19개로 구성되었다. 환자의 평균 나이는 69.48세이며, 21세부터 92세까지의 다양한 연령대의 환자 데이터가 포함되어 있다. 데이터에는 ECG 파형, PPG 파형, 연속 혈압 파형이 저장되어 있으며, PPG 신호는 손가락 끝에서 측정하고, 연속혈압 파형은 침습적으로 동맥 혈압을 모니터링 하는 방식으로 측정되었으며, ECG는 전극을 통해서 총 8채널 ('I', 'II', 'III', 'V', 'MCL1', 'aVL', 'aVR', 'aVF') 신호가 측정되었다.

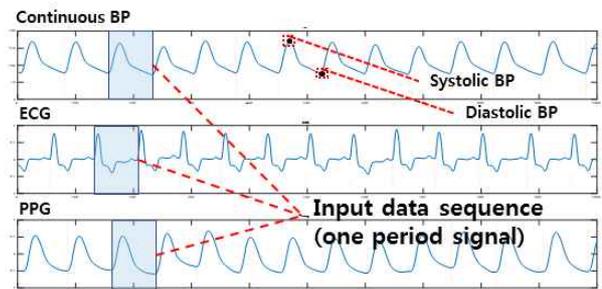


Fig. 5 Input Data Sequence

각 신호의 샘플링 속도는 125Hz이고, 평균 40.8

시간의 데이터가 기록이 되어 있다. 본 논문에서 사용한 원본 데이터 시퀀스는 Fig. 5와 같다.

3.2 결과분석

예측 모델의 검증을 위해 훈련에 80% 데이터 (1,920,000)를 사용하고 테스트에 20% 데이터 (480,000)를 사용하였다. 데이터 분석 환경은 Windows 10, Ubuntu 16.04, 64GB RAM, Nvidia 1080Ti의 컴퓨터를 사용하였으며, 합성곱신경망 모델은 Tensorflow, Scikit-learn Framework를 사용하였다. 예측된 값과 원본 데이터의 차이를 비교한 결과 최고혈압의 평균 제공근 오차는 5.80 mmHg이고 최저혈압의 평균 제공근 오차는 2.78 mmHg로 나타났다. Fig. 6은 최고 혈압과 최저혈압의 Bland-altman 그래프를 나타내고 있다. 다수의 데이터가 평균에서 2 표준편차 이내 들어오는 것을 확인할 수 있으며, 최고혈압의 예측보다 최저혈압의 예측분포가 고르고 정확도가 높게 나타남을 확인할 수 있다. Table 3은 제안한 방식과 기존 연구들의 최고혈압과 최저혈압의 평균 제공근 오차를 나타낸 표이다. 비교 결과 Teng and Zhang (2003)이 제안한 Linear Regression을 통한 데이터 기반의 예측방식보다는 제안한 방식이 예측오차가 적었다. PAT나 PTT를 이용한 기존의 방식은 제안된 방법보다 평균 예측 오차는 적지만 표준편차가 큰 경향이 있고, 다른 데이터를 사용하여 검증하는 경우 예측 오차가 증가하는 제약점이 있다 (Zhang et al., 2017; Ding et al., 2017).

최고혈압이 최저 혈압보다 더 큰 오차를 보이는 이유는 최고혈압의 분포가 40 ~ 200mmHg로 최저혈압의 분포인 30 ~ 100mmHg 보다 넓게 분포가 되어 있기 때문으로 판단된다. 또한, 최고 혈압의 경우 70 ~ 90mmHg 범위의 데이터가 누락이 되어 데이터 분포가 고르지 못한 특성을 보이고 있기 때문으로 판단된다. 본 논문에서 분석한 MIMIC 데이터베이스에서 획득한 최고 혈압 데이터 분포는 Fig. 7과 같다. 최고 혈압과 최저 혈압의 차이인 맥압의 분포에서 20mmHg 이하 100mmHg 이상의 데이터는 특

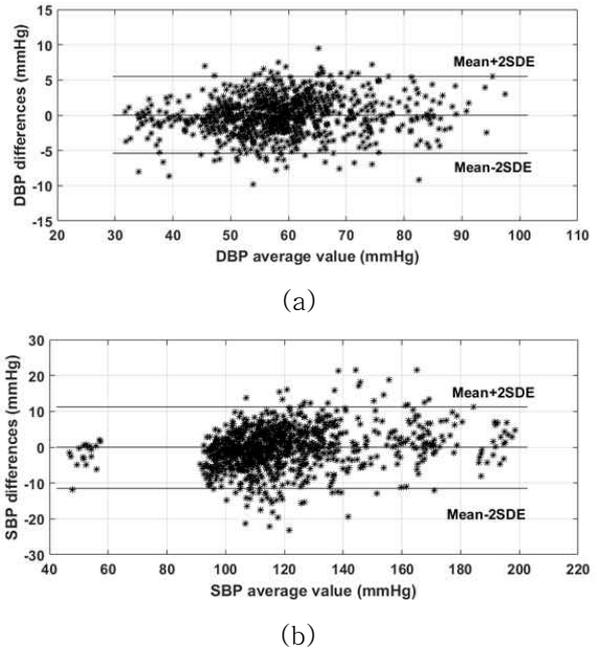


Fig. 6 Bland-Altman Plot of Blood Pressure Estimation (a) Diastolic Blood Pressure (DBP), (b) Systolic Blood Pressure (SBP)

Table 3 Performance Comparison

Method	DBP Error (mmHg)	SBP Error (mmHg)
Linear regression (Teng and Zhang, 2003)	4.39±0.02	7.32±0.21
PAT (Zhang et al., 2017)	4.41±5.85	7.45±9.79
PTT & PIR (Ding et al., 2017)	0.40±7.11	1.17±5.72
Proposed method CNN+FNN	2.78±2.55	5.80±5.02

정 피험자의 데이터만 존재하거나 30mmHg 근방에서는 아예 데이터가 존재하지 않는 것을 확인할 수 있다. 따라서 본 연구에서 모델을 학습한 입력 데이터의 패턴에 따라 혈압예측에 오차가 발생할 수 있다.

생리학적으로도 혈압의 경우 최고혈압의 변동은 일반적으로 최저혈압의 변동보다 크므로 데

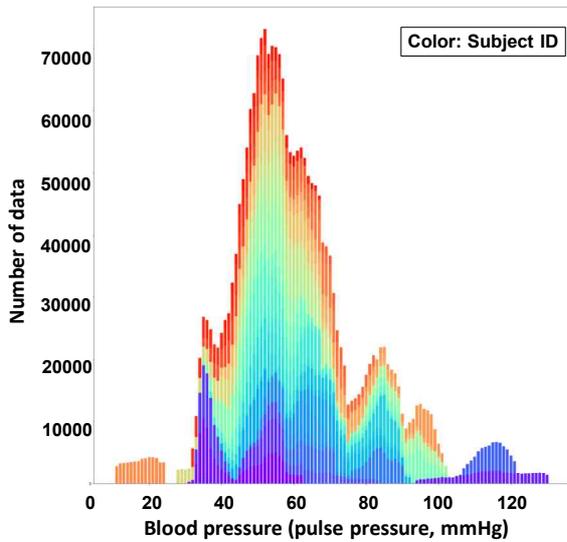


Fig. 7 Data Distribution

이터 패턴이 동적으로 변하여 선형 모델에서는 추정하기가 어려운 문제가 있다. 또한, 측정 오차로 인한 고주파 잡음 성분이 최고 혈압에 반영되거나 심박수가 불규칙적으로 변경될 때, 예측 오차는 최저혈압이 아닌 최고 혈압에 직접적인 영향을 미치기 때문에 잡음이 증가하는 경향이 있다.

Fig. 8은 큰 추정 오류가 발생할 때 원시 데이터 시퀀스의 예를 나타내고 있다. Fig. 7에서 회색 영역의 신호는 큰 최고혈압 및 최저혈압의 오차를 나타내는 구간을 표시하고 있다. 이 구간에서 측정된 혈압 값 자체는 정상이지만 ECG의 기준선이 손상되어 있으며, 이를 통해 신호 측정 중 신체의 움직임이 ECG에 영향을 미쳤을 가능성을 생각해 볼 수 있으며, PPG 신호의 경우에도 심장 박동에 따른 주기적인 패턴이 보이지 않는 상황임을 확인할 수 있다. 따라서 데이터 수집시 센서의 탈부착 상태 및 움직임 등에 의해 안정적으로 획득되지 않으면 큰 예측 오류를 나타낼 수 있음을 확인할 수 있다. 이를 통해 웨어러블 장비를 사용하여 측정 및 모니터링하는 경우에는 잡음에 강건한 안정적인 신호 수집이 가능하도록 하는 설계가 뒷받침되어야 한다.

마지막으로 제안된 혈압 예측 결과를 혈압계

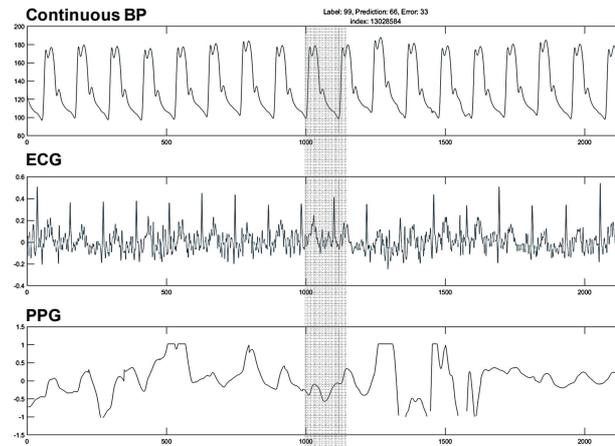


Fig. 8 Examples of Original Input Data with 22mmHg SBP Error and 33mmHg DBP Error

제품을 평가하는데 사용하는 BHS (British hypertension society) 표준을 적용하여 분석하였다. BHS 표준은 미국의 AAMI (US association for the advancement of medical instrumentation) 표준과 함께 평가 방법으로 널리 사용되고 있는 표준으로 다양한 연구 결과에서도 활용이 되고 있다 (Brien et al., 2001; Kachuee et al., 2016; Solà et al., 2013). 특히 BHS 표준은 AAMI에 비해 구간별 누적 오류를 평가할 수 있도록 되어 있어 구간별 오류에 대한 분석이 가능하여 본 논문에서 적용하였다. BHS 표준에 따라 분석한 결과 5mmHg 미만의 누적 오류 비율은 최저혈압에서 68%, 최고혈압에서 93%를 나타냄을 확인하였다. 이 결과는 영국 고혈압 협회의 Grade A 기준인 5 mmHg의 누적 오류가 60% 미만, 10 mmHg의 누적 오류를 갖는 데이터가 85% 미만, 15 mmHg의 누적 오류를 갖는 데이터가 90% 미만이어야 한다는 기준을 상회하는 결과로 ECG, PPG 신호를 기반으로 합성곱신경망 기반의 혈압 예측 방식이 일상생활에서 활용 가능한 유의미한 수준을 나타냄을 확인할 수 있다.

그러나 본 연구의 한계점은 입력 신호가 안정적으로 취득되지 않으면 분석 정확도에 영향을 받을 수 있으며, 입력으로 사용한 MIMIC 데이터베이스의 혈압 분포의 특성상 정상 범위의 혈

압에 대해서는 높은 정확도를 보이거나 저혈압과 고혈압 군의 데이터가 상대적으로 적어 이를 예측하는 정확도가 낮아질 수 있는 제약이 있다. 따라서 향후에는 누락된 데이터를 복원하는 방안을 고려하여 고른 분포의 데이터를 적용할 계획이다.

4. 결론

본 연구에서 합성곱신경망 방법을 기반으로 비가압방식의 혈압 추정 방법을 제안하였다. 혈압을 예측하기 위해서 주기적인 입력 신호를 생성하고, 잡음을 제거한 후 3개 레이어를 갖는 합성곱 신경망 모델을 제안하였다. MIMIC 데이터베이스를 활용한 실험 결과 평균 제공근 오차는 최고혈압의 경우 5.80 mmHg이고 최저혈압의 경우 2.78 mmHg을 나타냄을 확인할 수 있었다. 이 연구에서 우리는 제안된 딥러닝이 비침습적 혈압 모니터링 장치를 위한 고정 없는 혈압 추정에 적용될 수 있음을 확인하였다.

그러나 본 연구의 한계점은 입력 신호가 안정적으로 취득되지 않으면 분석 정확도에 영향을 받을 수 있으며, 혈압 분포의 특성상 정상 범위의 혈압에 대해서는 높은 정확도를 보이거나 저혈압과 고혈압 군의 데이터가 상대적으로 적어 이를 예측하는 정확도가 낮아질 수 있는 제약이 있다. 따라서 향후에는 ECG와 PPG 신호의 동 잡음을 제거하는 방식을 적용하고, 상대적으로 적은 분포의 데이터의 예측 정확도를 향상시키기 위한 방안에 대한 연구가 수행되어야 한다. 또한, 제안된 딥러닝 방식 이외 시계열 데이터에 적합한 딥러닝 모델을 통해 혈압 예측의 정확도를 향상하는 방안에 대한 연구가 필요하다.

이러한 후속 연구를 통해 향후에는 일상생활의 제약 없이 연속적으로 혈압 모니터링이 가능한 디바이스 개발이 된다면, 고혈압 환자의 모니터링 및 관리에 많은 도움이 될 것으로 기대한다.

References

- Allen, R., Schneider, J., Davidson, D., Winchester, M., and Taylor, C. (1981). The Covariation of Blood Pressure and Pulse Transit Time in Hypertensive Patients, *Psychophysiology*, 18(3), 301-306.
- Babbs, C. (2012). Oscillometric Measurement of Systolic and Diastolic Blood Pressures Validated in a Physiologic Mathematical Model, *BioMedical Engineering OnLine*, 11(56), 1-22.
- Baker, P. (1990). *Neural Network Processing of Oscillometric Waveforms and Blood Pressure Estimation from the Superficial Temporal Artery*, Ph. D. Thesis, Graduate School of University of Utah, USA.
- Brien, E., Waeber, B., Parati, G., Staessen, J., and Myers, G. (2001). Blood Pressure Measuring Devices: Recommendations of the European Society of Hypertension, *British Medical Journal*, 322(7285), 531-536.
- Chen, W., Kobayashi, T., Ichikawa, S., Takeuchi, Y., and Togawa, T. (2000). Continuous Estimation of Systolic Blood Pressure using the Pulse Arrival Time and Intermittent Calibration, *Medical and Biological Engineering and Computing*, 38(5), 569-574.
- Cho, Y., Kim, M., and Yoon, J. (2014). Comparison of Characteristics of P-Wave Detection in ECG with Wireless Patch Electrodes, *Korea Society of Industrial Information Systems*, 19(1), 43-52.
- Choi, S., Lee, K., Kim, K., and Kwak, S. (2019). Lane Departure Warning System using Deep Learning, *Journal of the Korea Industrial Information Systems Research*, 24(2), 25-31.
- Chung, M., and Lee, J. (2018). Systemic Analysis of Research Activities and Trends Related to Artificial Intelligence (A.I.)

- Technology based on Latent Dirichlet Allocation (LDA) Model, *Journal of the Korea Industrial Information Systems Research*, 23(3), 87-95.
- Choi, Y., Kim, K., Hong, W., and Ryu, J. (2009). Development of Blood Pressure Measuring System using Piezoelectric and Photo Sensor, *Korea Society of Industrial Information Systems*, 14(5), 149-154.
- Ding, X., Zhao, N., Yang, G., Pettigrew, R., Lo, B., Miao, F., Li, Y., Liu, J., and Zhang, Y. (2016). Continuous Blood Pressure Measurement from Invasive to Unobtrusive: Celebration of 200th Birth Anniversary of Carl Ludwig, *IEEE Journal of Biomedical and Health Informatics*, 20(6), 1455-1465.
- Ding, X., Yan, B., Zhang, Y., Liu, J., Zhao, N., and Tsang, H. (2017). Pulse Transit Time Based Continuous Cuffless Blood Pressure Estimation: A New Extension and A Comprehensive Evaluation, *Scientific Reports*, 7(11554), 1-11.
- Forouzanfar, M., Dajani, H., Groza, V., Bolic, M., and Rajan, S. (2011). Feature-based Neural Network Approach for Oscillometric Blood Pressure Estimation, *IEEE Transactions on Instrumentation and Measurement*, 60(8), 2786-2796.
- Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P., Mark, R., Mietus, J., Moody, G., Peng, C., and Stanley, H. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23), e215-e220.
- Kachuee, M., Kiani, M., Mohammadzade, H., and Shabany, M. (2016). Cuffless Blood Pressure Estimation Algorithms for Continuous Health-Care Monitoring, *IEEE Transactions on Biomedical Engineering*, 64(4), 859 - 869.
- Kim, M., Kim, Y., and Cho, Y. (2015). Electrocardiographic Characteristics of Significant Factors of Detected Atrial Fibrillation using WEMS, *Korea Society of Industrial Information Systems*, 20(6), 37-46.
- Lee, H., Lee, J., and Shin, M. (2019). Using Wearable ECG/PPG Sensors for Driver Drowsiness Detection Based on Distinguishable Pattern of Recurrence Plots, *Electronics*, 8(2), 192, 1-15.
- Lee, M., Nam, K., and Lee, C. (2019). Crack Detection on the Road in Aerial Image using Mask R-CNN, *Journal of the Korea Industrial Information Systems Research*, 24(3), 23-29.
- Lee, S., and Chang, J. (2017). Oscillometric Blood Pressure Estimation Based on Deep Learning, *IEEE Transactions on Industrial Informatics*, 13(2), 461-472.
- Moody, G., and Mark, R. (1996). A Database to Support Development and Evaluation of Intelligent Intensive Care Monitoring, *Computers in Cardiology*, 23, 657-660.
- Naschitz, J., Bezobchuk, S., Mussafia-Priselac, R., Sundick, S., Dreyfuss, D., Khorshidi, I., Karidis, A., Manor, H., Nagar M., Peck, E., Peck, S., Storch, S., Rosner, I., and Gaitini, L. (2004). Pulse Transit Time by R-wave-gated Infrared photoplethysmography: Review of the Literature and Personal Experience, *Journal of Clinical Monitoring and Computing*. 8(5), 333-342.
- Payne, R., Symeonides, C., Webb, D., and Maxwell, S. (2006). Pulse Transit Time Measured from the ECG: an Unreliable Marker of Beat-to-beat Blood Pressure, *Journal of Applied Physiology*, 100(1), 136 - 141.
- Ruiz-Rodríguez, J., Ruiz-Sanmartín, A., Ribas, A., Caballero, J., García-Roche, A., Riera, J., Nuvials, X., Nadal, M., SolaMorales, O., and Serra, J. (2013). Innovative Continuous

Cuffless Blood Pressure Estimation Based on a Convolutional Neural Network using PPG and ECG Signals for Portable or Wearable Blood Pressure Devices

- Non-invasive Cuffless Blood Pressure Monitoring based on Photoplethysmography Technology, *Intensive Care Medication*, 39(9), 1618-1625.
- Rundo F., Conoci, S., Ortis A., and Battiato, S. (2018). An Advanced Bio-Inspired PhotoPlethysmoGraphy(PPG) and ECG Pattern Recognition System for Medical Assessment, *Sensors*, 18(2), 405, 1-22.
- Solà, J., Proença, M., Ferrario, D., Porchet, J., Falhi, A., Grossenbacher, O., Allemann, Y., Rimoldi, S., and Sartori, C. (2013). Noninvasive and Nonocclusive Blood Pressure Estimation Via a Chest Sensor, *IEEE Transactions on Biomedical Engineering*, 60(12), 3505-3513.
- Sun, J., Reisner, A., and Mark, R. (2006). A Signal Abnormality Index for Arterial Blood Pressure Waveforms, *Proceedings on Computers in Cardiology*, Valencia, Spain, pp. 13-16.
- Teng, X., and Zhang, Y. (2013). Continuous and Noninvasive Estimation of Arterial Blood Pressure using a Photoplethysmographic Approach, *The 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Sep. 17-21, Cancun, Mexico, pp. 3153-3156.
- Wang, L., Zhou, W., Xing, Y., and Zhou, X. (2018). A Novel Neural Network Model for Blood Pressure Estimation using Photoplethysmography without Electrocardiogram, *Journal of Healthcare Engineering*, 2018(7804243), 1-9.
- Wippermann, C., Schranz, D., and Huth, R. (1995). Evaluation of the Pulse Wave Arrival Time as a Marker for Blood Pressure Changes in Critically Ill Infants and Children, *Journal of Clinical Monitoring*, 11(5), 324-328.
- Xing, X., and Sun, M. (2016). Optical Blood Pressure Estimation with Photoplethysmography and FFT-based Neural Networks, *Biomedical Optics Express*, 7(8), 3007-3020.
- Zhang, Q., Zeng, X., Hu, W., and Zhou, D. (2017). A Machine Learning-Empowered System for Long-Term Motion-Tolerant Wearable Monitoring of Blood Pressure and Heart Rate With Ear-ECG/PPG, *IEEE Access*, 5, 10547-10561.



조진우 (Jinwoo Cho)

- 가천대학교 소프트웨어학과 공학사
- 가천대학교 IT융합학과 공학석사
- (현재) 뷰노, 연구원
- 관심분야: 심전도, 심혈관 질환 예측, 딥러닝



최아영 (Ahyoung Choi)

- 광주과학기술원 정보통신학과 공학박사
- 삼성전자 무선사업부 책임 연구원
- (현재) 가천대학교 IT대학 소프트웨어학과 조교수
- 관심분야: 생체신호처리, 모바일 헬스케어, 머신러닝, 딥러닝