



공학석사학위논문

합성곱 신경망을 이용한 PPG 신호 기반 혈압 추정 모델의 환자 보정 기법

Calibrating PPG Based Blood Pressure Estimation Model Using Convolutional Neural Networks

2023 년 2 월

서울대학교 대학원 산업공학과

김해성

합성곱 신경망을 이용한 PPG 신호 기반 혈압 추정 모델의 환자 보정 기법

Calibrating PPG Based Blood Pressure Estimation Model Using Convolutional Neural Networks

지도교수 이경식

이 논문을 공학석사 학위논문으로 제출함 2022 년 12 월

서울대학교 대학원

산업공학과

김해성

김해성의 공학석사 학위논문을 인준함

2023 년 1 월

위 역	원장 _	조성준	(인)
부위	원장 _	이경식	(인)
위	원	박종헌	(인)

광용적맥파(photoplethysmography, 이하 PPG) 신호를 이용한 혈압 추정은 광학적 인 방법을 통해 비침습적으로 수집된 생체 신호로부터 혈압을 추정하는 연구 분야이다. 신호의 수집 및 분석이 용이하기 때문에 PPG 신호를 이용한 혈압 추정은 일상생활 속 에서 사용자의 불편함 없이 연속적으로 혈압을 추정할 수 있다는 장점이 있다. 최근에는 딥러닝 기법들을 활용하여 end-to-end 방식으로 PPG 신호로부터 혈압을 추정하는 연구 들이 제안되고 있는데, 서로 다른 환자를 구분할 수 있게 해주는 환자 보정(calibration) 이 혈압 추정 성능을 크게 개선하지만 이에 초점을 맞춘 연구는 많지 않은 상황이다.

본 논문에서는 환자 보정을 위한 데이터를 입력으로 함께 사용하는 합성곱 신경 망 모델을 제안한다. 보정을 위한 데이터로는 동일한 환자에게서 수집된 4초의 PPG 신호와 정답 혈압을 이용한다. 이 환자 보정 방법은 1) 보정을 위해 필요한 데이터가 적고, 2) 서로 다른 환자의 혈압을 단일 모델로 추정할 수 있으며, 3) 새로운 대상의 혈압을 추정할 때도 하나의 보정 데이터만을 필요로 한다는 장점이 있다. 나아가 합성곱 신경망 모델이 더 나은 보정 데이터 표현(representation)을 얻을 수 있도록 손실 함수를 개선했다. 동일한 환자에게서 수집된 PPG 신호를 긍정적인 관계로 정의하는 자기 지도 손실 함수를 도입했고, 도입한 손실 함수와 지도 손실 함수의 가중 합을 손실 함수로 이용했다. 그 결과, 혈압 추정 성능이 향상되는 것을 확인했다.

그뿐만 아니라, 합성곱 신경망 모델이 강건해질 수 있도록 PPG 신호에 적용할 수 있는 5가지 데이터 증강 기법들을 도입했다. 각 방법을 이용해 학습 데이터셋을 20% 늘려주었을 때 혈압 추정 성능이 어떻게 변화하는지 확인한 결과, 4가지 데이터 증강 기법에서 혈압 추정 성능이 향상되었다. 최종적으로, 개선된 손실함수를 활용하고 랜덤한

i

시간 영역을 마스킹하는 데이터 증강 기법을 이용하여 합성곱 신경망 모델을 학습했을 때, 수축기 혈압 평균 절대 오차 7.930mmHg, 이완기 혈압 평균 절대 오차 4.593mmHg 의 혈압 추정 성능을 보였다.

주요어: 혈압 추정, 광용적맥파, 합성곱 신경망, 환자 보정, 자기 지도 손실함수, 데 이터 증강

학번: 2021-23283

초록	i
목차	iv
표목차	v
그림 목차	vii
제 1 장 서론	1
1.1 연구 배경 및 동기	1
1.2 연구 목적	3
1.3 문제 정의	4
1.4 논문구성	6
제 2 장 배경 이론 및 관련 연구	7
2.1 배경이론	7
2.1.1 합성곱 신경망	7
2.1.2 Photoplethysmography	10
2.2 관련 연구	12
2.2.1 맥파 속도 기반의 연구	12
2.2.2 맥파 분석을 통한 연구	14
제 3 장 합성곱 신경망을 이용한 혈압 추정 기법	16

	3.1	데이터 전처리	16
	3.2	합성곱 신경망 모델 구조	20
	3.3	BYOL을 결합한 합성곱 신경망 모델 구조	23
	3.4	데이터 증강	25
제	4	장 실험 결과	28
	4.1	데이터셋	28
	4.2	실험 세팅	32
	4.3	실험 결과	33
		4.3.1 환자 보정 유무에 따른 성능 비교	33
		4.3.2 제안 모델 효과 검증	36
		4.3.3 데이터 증강	40
제	5	장 결론	41
	5.1	결론	41
	5.2	향후 연구	43
참.	고문한	<u>1</u>	45
Al	ostra	ct	51

표 목차

표 4.1	모델 차이에 따른 혈압 추정 성능	33
표 4.2	데이터 증강에 따른 혈압 추정 성능	40

그림 목차

그림	1.1	환자 보정이 없는 혈압 추정	4
그림	1.2	환자 보정이 있는 혈압 추정	4
그림	2.1	합성곱 계층과 완전 연결 계층 다이어그램[1]	7
그림	2.2	이차원 합성곱 신경망 모델의 예시[2]	8
그림	2.3	일차원 합성곱 신경망 모델의 예시[2]	9
그림	2.4	PPG 신호의 측정 방법과 신호 구성 성분[3]	10
그림	2.5	PPG 파형에서 추출하는 특징 예시[3]	14
그림	3.1	원본 ABP 신호에서 발견되는 평평한 신호 잡음[4]	16
그림	3.2	원본 ABP 신호에서 발견되는 평평한 마루 잡음[4]	16
그림	3.3	데이터 전처리 프로세스를 나타낸 다이어그램	17
그림	3.4	4초 구간의 ABP 신호의 마루와 골	18
그림	3.5	불안정한 PPG 슬롯 예시	19
그림	3.6	데이터 전처리 및 필터링을 완료한 PPG 슬롯 예시	19
그림	3.7	합성곱 신경망 모델 구조	20
그림	3.8	BYOL을 결합한 합성곱 신경망 모델 구조	24
그림	3.9	다섯 가지 데이터 증강 기법	25
그림	4.1	데이터셋 수축기 혈압의 분포	30
그림	4.2	환자 별 평균 수축기 혈압의 분포	30

그림 4.3	10명의 환자에 대한 수축기 혈압의 박스 그래프	31
그림 4.4	환자 보정이 없을 때 수축기 혈압의 정답 및 추정값 산점도	35
그림 4.5	환자 보정이 있을 때 수축기 혈압의 정답 및 추정값 산점도	35
그림 4.6	혈압 추정 성능이 우수한 환자 예시	38
그림 4.7	혈압 추정 성능이 저조한 환자 예시	39

제1장서론

1.1 연구 배경 및 동기

고혈압은 여러 원인들로 인하여 혈압이 정상보다 높아져 있는 상태로 심부전, 협심증, 뇌출혈 등과 같은 심혈관질환 합병증을 유발하는 질병이다. 한편, 심장질환과 혈관질환 은 2018년 국내 사망원인통계에서 국내 사망원인 2위와 4위를 각각 차지하고[5] 이 둘을 합친 심혈관질환은 전세계적으로도 주요 사망 원인 중 하나에 해당한다[6]. 고혈압은 이러한 심혈관질환의 가장 큰 원인으로 알려져 있으나 합병증을 유발하기 전까지는 아무런 증상이 없어 진단이 어렵다. 이러한 특징으로 인해 고혈압은 침묵의 살인자라고 불리기도 한다. 고혈압을 진단하는 유일한 방법은 혈압을 측정하는 것인데 진찰실에서 혈압을 측정하는 특수한 상황이 측정에 영향을 미쳐 평소 고혈압 증상이 있더라도 정상 수치가 나타나는 가면 고혈압에 의해 진단이 잘못될 수도 있다.

전문가들은 고혈압을 관리하는 방법 중 하나로 주기적인 가정 혈압 측정을 권고하고 있다[7]. 가정 혈압 측정은 가장 정확하게 혈압을 측정한다는 장점이 있으며 아침, 저녁 주기적인 혈압 측정을 통해 복용 중인 약의 효과, 생활요법의 혈압 감소 효과를 확인할 수 있어 혈압 관리에 도움을 준다. 그러나 해당 방법은 환자로 하여금 시간적, 경제적 비용을 발생시키고 적극적인 혈압 관리를 위한 노력을 필요로 하여 매일 꾸준하게 혈압을 측정하는 고혈압 환자의 비율은 낮은 상황이다. 이러한 실태를 개선하기 위해 환자가 보다 쉽고 편리하게 혈압을 측정할 수 있도록 하는 것이 중요한데, 최근 스마트워치와 같은 웨어러블 디바이스를 이용하여 일상생활 속에서 편리하게 혈압을 측정하려는 시 도가 행해지고 있다[8].

웨어러블 디바이스를 이용한 혈압 측정은 광용적맥파 (Photoplethysmography, 이하 PPG) 신호로부터 혈압을 추정하는 연구에 기반을 하고 있다. 과거로부터 PPG 신호와 심전도 (Electrocardiogram, 이하 ECG) 신호를 이용해 비침습적으로 혈압을 추정하려 는 연구가 존재했고 초기에는 생체 신호로부터 특징 (feature)을 추출한 후 선형 회귀 (Linear Regression) 모형 등을 이용하거나 맥파 속도 (Pulse Wave Velocity)를 이용 하여 혈압을 추정하는 연구들이 행해졌다[3]. 최근에는 딥러닝 기술이 발달하고 여러 도메인에서 우월한 성능을 보이면서[9] PPG 신호를 이용하여 혈압을 추정하는 문제에도 end-to-end 방식의 딥러닝 모델을 적용한 연구가 활발히 진행되고 있다. 딥러닝 모델을 이용한 연구에서 환자를 구분하여 모델을 학습하는 환자 보정 (calibration)이 있을 때 혈압 추정 정확도가 크게 높아지는 것으로 알려져 있다.

그러나 딥러닝을 활용한 선행 연구에서 환자 보정이 혈압 추정 성능에 미치는 영향이 높음에도 불구하고 환자 보정 방법에 초점을 맞춘 연구는 부족한 실정이다. 기존 연구에 서는 환자 별로 모델을 학습하는 방법을 주로 이용하는데, 해당 방법은 환자 별로 학습 데이터셋을 확보하는 과정을 필요로 하고 추정해야 하는 대상이 늘어남에 따라 학습에 필요한 시간과 저장 공간이 비례하여 늘어난다는 한계를 갖는다.

1.2 연구 목적

본 연구에서는 PPG 신호로부터 혈압을 추정하는 합성곱 신경망 (Convolutional Neural Network) 모델을 제안한다. 제안 모델은 한 쌍의 PPG 신호와 정답 혈압을 모델의 입력으로 함께 활용하여 환자 별 보정 효과를 달성한다. 오픈 데이터셋을 이용한 테스트를 진행하여 환자 보정 유무에 따른 혈압 추정 성능 변화를 확인한다. 동일한 환자 의 PPG 표현 (representation)을 같은 공간에 매핑하는 자기 지도 학습 (Self-supervised Learning)의 손실 함수를 도입했을 때 추가적인 성능 개선이 이루어지는 지 확인하고, 5 가지의 데이터 증강 (augmentation) 방법에 대해서 학습 데이터셋의 다양성을 증가시킨 효과를 검증한다. 이를 통해 적은 양의 데이터로 환자 별 보정 효과를 달성하고 서로 다른 환자의 혈압도 정확하게 추정할 수 있는 합성곱 신경망 모델을 제안하는 것을 목적으로 한다.

1.3 문제 정의

본 연구에서 풀고자 하는 문제는 end-to-end 방식의 딥러닝 기반 모델을 활용하여 PPG 신호로부터 혈압을 추정하는 것이다. PPG 신호는 연속적으로 수집되는 일차원 시계열 데이터이기 때문에 지도 학습(Supervised Learning)이 가능하도록 슬라이딩 윈도우를 이용해 일정한 길이를 갖는 데이터 형태를 만들어줄 필요가 있다. 본 연구에 서는 4초 크기의 윈도우를 이용해 PPG 슬롯들을 생성해서 사용한다. 윈도우는 4초의 간격으로 이동하여 PPG 슬롯들은 서로 겹치는 영역을 갖지 않는다. 합성곱 신경망 모델은 PPG 슬롯을 입력으로 받아 각 구간에 대응되는 수축기(systolic) 혈압과 이완기 (diastolic) 혈압을 동시에 추정한다. 이를 묘사한 그림이 그림 1.1에 나타나 있다.



Figure 1.1: 환자 보정이 없는 혈압 추정



Figure 1.2: 환자 보정이 있는 혈압 추정

딥러닝을 활용한 혈압 추정 연구에서 환자를 구분하여 혈압을 추정하는 보정 과정은 혈압 추정 성능을 크게 개선한다고 알려져 있다[10, 11]. 개별 환자에 대한 보정 효과를 얻는 간단한 방법은 환자 별로 학습 데이터셋을 확보하여 모델을 따로 학습시키는 것 이다. 이와 달리 본 연구에서는 보정을 위해 수집된 PPG 신호와 정답 혈압을 모델의 입력으로 함께 활용하여 환자 별 보정 효과를 달성한다. 이 때 추가적으로 사용하는 보정용 데이터로 다른 시점에 측정된 한 쌍의 PPG 슬롯과 정답 혈압을 필요로 한다. 본 연구에서 정의한 혈압 추정 문제를 묘사한 그림이 그림 1.2와 같다. 맞춰야 하는 PPG 슬롯 외에도 동일한 환자에게서 수집된 한 쌍의 PPG 슬롯과 혈압 데이터를 합성곱 신경망 모델의 입력으로 활용하여 혈압을 추정한다.

1.4 논문 구성

본 논문은 다음과 같이 총 5 장으로 구성된다. 제 2장에서는 본 연구에서 활용하는 합성곱 신경망과 PPG 신호를 소개하고, PPG 신호를 이용한 혈압 추정 관련 선행 연구 를 살펴 본다. 제 3장에서는 데이터를 전처리하는 과정을 서술하고 제안하는 기법들에 관해 설명한다. 제 4장에서는 연구에 사용한 데이터셋과 실험 세팅을 설명하고, 제안 기법의 효과를 비교 실험을 통해 확인한다. 마지막으로 제 5장에서는 결론과 한계점에 대해 논의한 후 향후 연구 방향을 제시한다.

제 2 장 배경 이론 및 관련 연구

2.1 배경 이론

2.1.1 합성곱 신경망

합성곱 신경망은 합성곱 구조를 통해 데이터로부터 특징을 추출하는 순방향 신경 망의 일종으로 이미지 분석, 자연어 처리 등을 포함한 다양한 분야에서 성공을 거두고 있는 딥러닝 모델이다. 합성곱 신경망의 강력한 학습 능력은 데이터로부터 벡터 표현을 자동적으로 학습할 수 있는 여러 층의 특징 추출 단계에 기반한다. 합성곱 신경망은 대뇌의 시각 피질 구조를 모방하여 만들어졌으며, 인공적인 뉴런은 생물학적인 뉴런에 대응된다. 커널(kernel)은 다양한 특징들에 반응할 수 있는 수용기 역할을 하고 활성 함수는 신경의 전기 신호가 특정 임계 값을 넘는 경우에만 그 다음 뉴런으로 전달될 수 있도록 한다.



Figure 2.1: 합성곱 계층과 완전 연결 계층 다이어그램[1]

합성곱 신경망은 완전 연결 계층 (Fully Connected Layers)과 대비하여 여러 이점을 갖는다. 1) 합성곱 신경망은 지역적인 연결 구조를 갖는데, 각각의 뉴런은 이전 층의 모든 뉴런과 연결되지 않고 일부 뉴런들과 연결되어 있다. 이러한 특징은 파라미터의 수를 줄이고 수렴 속도를 빠르게 하는 효과를 갖는다. 2) 합성곱 신경망은 동일한 파라 미터를 갖는 커널을 반복적으로 사용하여 필요한 파라미터의 수를 크게 줄인다. 3) 다운 샘플링을 통해 차원을 축소한다. 풀링 (pooling) 계층을 통해 유용한 정보를 유지한 채로 데이터의 크기를 축소하여 학습에 필요한 파라미터의 수를 줄이고 불필요한 정보들을 누락시켜 과적합을 방지할 수 있다.



Figure 2.2: 이차원 합성곱 신경망 모델의 예시[2]

합성곱 신경망은 합성곱 계층과 풀링 계층이 여러 번 반복되고 마지막에 완전 연결 계층이 연결되어 있는 구조가 일반적이다. 합성곱 계층은 입력 데이터에 커널과 합성곱 연산을 통해 특징을 추출하고 활성 함수를 적용한다. 커널은 스트라이드(stride)에 해당하는 일정 간격을 이동하며 연산을 진행한다. 이 과정에서 데이터의 가장자리의 정보들이 사라지는 문제점이 존재하기 때문에 미리 입력 데이터의 가장자리에 값을 채워 놓는 패딩 (padding)을 진행한다. 일반적으로 0 값을 채워넣는 제로 패딩을 사용한다. 풀링 계층은 합성곱 계층의 출력 데이터의 크기를 축소하는 계층이다. 일반적으로 최대 풀링 또는 평균 풀링을 사용한다. 데이터 축소는 이후 연산에 필요한 파라미터 수를 줄이는 효과와 과적합을 방지하는 효과를 갖는다. 여러 개의 합성곱 계층과 풀링 계층



이후에 얻어진 특징은 마지막으로 완전 연결 계층을 거쳐 정답을 예측한다.

Figure 2.3: 일차원 합성곱 신경망 모델의 예시[2]

합성곱 신경망은 이미지와 같은 이차원 데이터에만 적용되는 것이 아니라 일차원 신호 데이터에도 활발하게 사용된다. 일차원 신호 데이터에 이산 푸리에 변환 등을 적용하여 이차원 데이터로 변환한 후 이차원 합성곱 신경망을 적용할 수 있다. 그러나 해당 방법은 일차원 데이터에 별도의 이차원 변환 과정을 거쳐야 하고 이차원 합성곱 신경망이 필요 이상의 파라미터를 가질 수 있기 때문에 과적합에 취약하고 학습에 더 많은 데이터를 필요로 한다는 문제점이 있다. 이와 다르게 일차원 합성곱 신경망은 일차원 신호에 바로 적용할 수 있는 모델이고 위의 단점들을 방지할 수 있다. 일차원 합성곱 신경망은 이차원 합성곱 신경망과 매우 유사한 구조를 가지나 일차원 커널을 이용한다는 차이가 있다. 그림 2.3는 3개의 합성곱 계층과 2개의 선형 계층으로 이루어진 일차원 합성곱 신경망 구조 예시를 보여준다.

2.1.2 Photoplethysmography

PPG 신호는 광학적인 방법을 통해 비침습적으로 수집되는 생체 신호이다[12]. 피부 조직 미세 혈관의 혈류량 변화를 감지하는데 사용된다. PPG 신호 수집 기기는 광원과 광검출기로 구성되며, 광원에서 피부 조직 표면에 빛을 방출하고 조직에서 반사되거나 투과된 빛을 다시 광검출기로 감지해 신호를 측정한다. 심장 수축기에는 혈류량이 많아 져 피부 조직에서 흡수되는 빛이 증가하고 검출되는 빛의 세기와 양이 감소하여 PPG 신호가 낮아지고 이완기에는 이와 반대로 PPG 신호가 높아지는 양상을 보인다.



Figure 2.4: PPG 신호의 측정 방법과 신호 구성 성분[3]

PPG 신호는 교류(AC) 성분과 직류(DC) 성분으로 구성된다. 교류 성분은 심장 박동에 의한 성분으로 심장 박동과 동일한 주파수를 갖는다. 직류 성분은 피부 조직과 평균 혈류량을 나타내고 심장 박동과 상관 없이 일정한 값을 갖지만 호흡, 혈관 운동, 혈관 수축에 영향을 받는다. 그림 2.4은 발광 다이오드와 광검출기를 이용하여 PPG 신호를 수집하는 그림과 수집한 PPG 신호와 교류, 직류 성분을 매핑한 그래프를 나타 내고 있다.

미세혈관의 혈류량은 여러 생리학적 시스템에 의해 조절되기 때문에 PPG 신호는 심박수, 산소포화도, 혈압, 마취 깊이, 호흡 등을 모니터링하는 데 사용될 수 있다. 과거 에는 주로 병원에서 환자의 산소포화도 및 심박수를 측정하는 데 사용되었다. 따라서 손가락에 착용하는 집게 형태의 기기로부터 신호가 수집되는 경우가 많았다. 그러나 최근에는 웨어러블 기기의 발달과 관련 시장의 성장으로 PPG 신호를 수집하는 기기의 종류와 형태가 다양해졌고 스마트 워치, 웨어러블 의료기기 등에 PPG 신호 센서가 탑재되어 일상 생활 속에서 보다 편리하게 PPG 신호를 수집할 수 있게 되었다.

2.2 관련 연구

2.2.1 맥파 속도 기반의 연구

PPG 신호를 이용하여 혈압을 추정하는 초기 연구로 맥파 속도를 이용한 방법이 있다. 혈액을 탄성 파이프 내의 유체로 가정하고 파동 전파 이론을 기반으로 혈압을 계산하는 방법이다. 심장 박동에 따라서 혈액은 중심 동맥에서부터 말단의 동맥으로 이동하며 혈관을 확장 및 수축시킨다[13]. 이 과정에서 혈관의 탄성 변화가 발생하는데 탄성과 혈압 사이에는 다음과 같은 식 2.1이 성립한다[14].

$$E = E_0 e^{\alpha P} \tag{2.1}$$

$$PWV = \sqrt{\frac{hE}{\rho d}} \tag{2.2}$$

식 2.1에서 *E*₀와 α는 중심 동맥에 대한 파라미터로 사람마다 다른 값을 가지는 파라미 터이며, *P*는 혈압을 의미한다. 동맥을 혈액이 흐르는 탄성 파이프로 가정할 때, 혈관의 탄성과 맥파 속도 간에는 식 2.2가 성립한다. 식 2.2에서 *h*와 *d*는 각각 동맥의 두께와 지름을 나타내고 ρ는 혈액의 밀도를 의미한다.

$$PWV = \sqrt{\frac{hE_0e^{\alpha P}}{\rho d}} \tag{2.3}$$

$$PWV = \frac{D}{TravelTime} \tag{2.4}$$

식 2.1과 식 2.2를 결합하면 혈압과 맥파 속도 간에 성립하는 식 2.3을 얻을 수 있고 식 2.4를 이용하여 맥파 속도를 계산할 수 있다[15]. 식 2.4에서 *D*는 동맥의 길이를 의미하고 *TravelTime*은 맥파가 해당 동맥 구간을 이동하는데 걸린 시간을 의미하는데, 동맥의 길이를 이동 시간으로 나누면 맥파 속도를 계산할 수 있다. 이를 위해 서로 다른 신체 부위에서 수집한 생체 신호를 필요로 하는데, 신호를 수집하는 곳은 동일한 동맥 줄기에 위치해 있어야 하며 수집 위치 사이의 동맥의 길이를 알 수 있어야 하는 제약 을 갖는다. *TravelTime*을 나타내는 지표로는 Pulse Transit Time(PTT) 또는 Pulse Arrival Time(PAT)이 이용된다. PTT는 동맥의 두 위치 사이를 맥파가 이동하는데 걸리는 시간으로 ECG 신호와 PPG 신호를 이용하여 ECG의 R Peak와 PPG 신호의 맥파의 도착 시점 사이의 간격으로 측정되는 값이며 두 PPG 신호를 측정하여 추정할 수도 있다[15, 16].

위와 같은 이론에 기반하여 맥박 속도를 이용해 혈압을 추정한 연구들이 진행되었다. Hassan, Mashor, Nasir, 그리고 Mohamed[17]는 동맥의 맥파가 대동맥 판막에서 말초 부위까지 이동하는데 걸린 시간을 측정하여 혈압을 연속적으로 추정하는 방법이 제안되 었고 해당 연구는 혈압의 급격한 증가가 이동 시간을 단축시킨다는 것을 보였다. Wong, Poon, 그리고 Zhang[18]은 운동 전과 후의 신체 상태 하에서 PTT를 이용해 혈압을 추정하였는데, 운동 후 혈압이 증가하고 PTT는 감소하여 PTT와 수축기 혈압 사이에 높은 상관관계가 있음을 보였다. 앉아 있는 상태, 걷고 있는 상태 등 다양한 활동 하에서 혈압을 추정하는 연구도 진행되었다[19]. 이외에도 PTT를 메인으로 혈압을 추정하는 연구들이 다수 존재한다[20, 21].

그러나 맥파 속도를 이용한 혈압 추정 방법은 커프 기반의 혈압 추정을 대체할 수 있는 대안으로는 거리가 멀다. 일단 두 개의 센서로부터 신호 수집이 필요하기 때문에 측정 대상의 불편함을 유발한다. 그리고 두 신호 모두 정밀하게 측정되어야하기 때문에 움직임 등이 제한되어 일상생활 속에서 적용이 어렵다. 뿐만 아니라 사람마다 혈관의 기본 탄성 및 동맥 길이 등의 파라미터가 다르기 때문에 개인별 보정 과정이 필수적이 라는 한계도 존재한다.

2.2.2 맥파 분석을 통한 연구

맥파로부터 사전 정의된 특징을 추출하여 혈압을 추정하려는 맥파 분석(Pulse Wave Analysis) 기반의 연구 흐름도 존재한다[22]. 신호의 파형으로부터 특정한 너비, 높이 등의 성질들을 특징으로 추출하고 머신 러닝을 이용하여 혈압을 추정하는 방법이다. 이 방법은 맥파 속도 기반의 방법과 달리 한 곳에서 수집된 생체 신호만을 필요로 하기 때문에 비교적 간단하게 혈압을 추정할 수 있는 장점이 있다.



Figure 2.5: PPG 파형에서 추출하는 특징 예시[3]

Teng과 Zhang[23]은 PPG 신호로부터 진폭의 1/2, 1/3 지점 사이의 너비와 수 축기 상승 시간 및 이완기 시간의 네 가지 특징들을 추출하고 회귀 모형을 이용하여 혈압을 추정하는 방법을 제안했다. Suzuki와 Oguri[24]는 PW, TW, Dn, DW의 특 징들을 PPG 신호로부터 계산하였고 이후 Suzuki와 Ryu[25]는 일곱 가지 Signal-to-Noise Ratio(SNR) 특징들을 계산하여 수축기 혈압을 추정하는데 이용했다. Kachuee, Kiani, Mohammadzade, 그리고 Shabany[26]는 환자 보정 과정 없이 PPG로부터 추출 한 특징들을 이용해 혈압을 추정하는 연구도 제안하였는데 이 과정에서 Augmentation Index(AI), Large Artery Stiffness Index(LASI), Inflection Point Area Ratio(IPA) 특징들을 이용했다. 비교적 최근에는 PPG 파형의 이계도 함수를 계산하여 특징으로 사용한 연구도 존재한다[27] 측정 대상의 불편함을 줄이는 방법으로, 스마트폰 카메라를 이용하여 PPG 신호를 추출하고 맥파 분석을 이용하여 혈압을 추정하는 방법도 제안되 었다[28].

맥파 분석을 통해 추출한 특징들을 이용한 연구와 맥파 속도 기반의 연구를 결합한 연구들도 다수 진행되었다[27]. 이 방법은 두 개의 센서에서 수집한 신호를 필요로 하고 PTT를 함께 활용하여 혈압을 추정한다. 최근에는 딥러닝 모델이 여러 도메인의 문제 에서 좋은 성능을 보이면서 혈압 추정 문제에 합성곱 신경망, 순환 신경망 (Recurrent Neural Network)을 이용한 연구도 진행되었다[4, 29]. 사전 정의된 특징을 추출하는 과정 없이 end-to-end 방식으로 신호 자체로부터 혈압을 추정하는 연구들이 제안되었 다[11].

제 3 장 합성곱 신경망을 이용한 혈압 추정 기법

3.1 데이터 전처리

본 연구에서는 PhysioNet에서 제공하는 공개 데이터셋인 MIMIC-III Waveform Database Matched Subset v1.0[30]을 사용했다. 해당 데이터셋은 환자 별로 서로 다른 길이의 시간만큼 PPG 신호와 ABP 신호가 연속적으로 수집되어 있기 때문에 문제 정 의에 맞춰서 데이터 가공이 필요하다. 뿐만 아니라 평평한 신호, 평평한 마루, 불안정한 신호 등의 잡음을 포함하고 있어서[4] 해당 잡음들을 제거하기 위한 데이터 전처리 및 필터링 과정이 필수적이다.



Figure 3.1: 원본 ABP 신호에서 발견되는 평평한 신호 잡음[4]



Figure 3.2: 원본 ABP 신호에서 발견되는 평평한 마루 잡음[4]



Figure 3.3: 데이터 전처리 프로세스를 나타낸 다이어그램

본 연구에서 사용한 전처리 과정을 다이어그램으로 나타내면 그림 3.3과 같다. 먼저 PPG 신호와 ABP 신호에 0.5 Hz와 8 Hz 의 주파수를 기준으로 butterworth bandpass filter를 적용했다. 8 Hz 이상은 고주파 잡음이고 0.5 Hz 미만의 저주파 잡음은 기저선 변동으로 여길 수 있기 때문이다. 이후 PPG 신호를 4초 간격으로 분리하여 슬롯들을 생성했다. PPG 신호는 125 Hz의 샘플링 주파수를 갖기 때문에 하나의 슬롯은 500의 길이를 갖는다. 각각의 PPG 슬롯에 대응되는 ABP 신호 구간에서 마루들의 평균과 골들의 평균을 구해 수축기 혈압과 이완기 혈압으로 사용한다.

이 과정에서 ABP 신호에 결측치가 존재하거나 평평한 신호 잡음이 존재하는 경우는 제외했다. 또한 수축기 혈압과 이완기 혈압이 너무 크거나 작은 경우도 이상치로 제외 했다. 본 연구에서는 80mmHg 이상 180mmHg 이하의 수축기 혈압을 갖고 50mmHg 이상 130mmHg 이하의 이완기 혈압을 갖는 슬롯만 사용한다. 이후 PPG 슬롯 별로 Z-점수 정규화를 진행했다.

불안정한 PPG 슬롯을 제거하기 위해 추가적인 전처리 과정을 거친다. PPG 슬 롯에서 마루가 2개 이하인 경우는 비정상적인 맥박을 갖는 것으로 볼 수 있기 때문에



Figure 3.4: 4초 구간의 ABP 신호의 마루와 골

이상치로 판단해서 제외했다. 마루들의 표준편차가 크거나 마루 사이의 시간 간격의 표준편차가 큰 경우도 불안정한 신호로 간주하여 제외해 주었다. 본 연구에서는 마루의 표준편차에는 0.3의 기준을 마루 사이의 시간 간격에는 20을 기준으로 적용하여 신호의 불안정 여부를 판단했다. 마지막으로 마루와 골의 값의 차이가 1보다 작은 구간이 존재 하는 경우 불안정한 신호로 판단하여 제외했다.



Figure 3.6: 데이터 전처리 및 필터링을 완료한 PPG 슬롯 예시

3.2 합성곱 신경망 모델 구조

본 연구에서 사용한 모델은 Mobilenet[31]을 변형한 합성곱 신경망 모델로, 깊이 분할 합성곱을 통해 적은 수의 파라미터로도 높은 성능을 낼 수 있는 모델이다. PPG 신호로부터 혈압을 추정하는 연산은 스마트 워치나 모바일 기기 등 저성능 환경에서 이루어지게 될 가능성이 있기 때문에 성능 자체보다 효율성에 초점을 맞춘 경량화된 모델을 사용했다.



Figure 3.7: 합성곱 신경망 모델 구조

모델은 혈압을 추정할 PPG뿐만 아니라 보정을 위해 사용할 한 쌍의 PPG 슬롯과

혈압 데이터를 입력으로 갖는다. 보정용 데이터는 같은 환자의 데이터 중 하나를 임의로 선택한다. 보정용 데이터 입력으로부터 모델은 혈압을 추정할 PPG 슬롯에 대한 추가적 인 유형 정보를 얻는다. PPG 슬롯과 보정용 데이터가 결합된 입력 형태는 선행연구에서 개별 환자의 데이터만을 사용하여 학습한 모델을 얻는 것과 유사하게 환자의 추가적인 데이터를 이용하여 혈압을 보다 정확하게 추정한다는 공통점이 있다. 그러나 기존의 방법과 크게 두 가지 측면에서 차이점을 갖는다.

첫째로, 제안하는 모델은 환자의 추가적인 데이터로 하나의 PPG 슬롯과 혈압 쌍만 필요로 한다. 이는 기존 연구에서 특정 환자를 잘 맞추는 모델을 학습하기 위해 해당 환자의 데이터로 이루어진 학습 데이터셋을 필요로 하는 것과 대비된다. 학습 데이 터셋은 여러 쌍의 PPG 슬롯과 혈압으로 이루어져야 하지만 실생활에서 특정 개인에 대해서 여러 쌍의 PPG 슬롯과 혈압을 확보하는 것은 많은 비용을 야기시킨다. 따라서 추가적으로 사용하는 환자의 데이터를 최소화할 필요가 있고 본 연구에서는 하나의 보정용 PPG 슬롯과 혈압 쌍을 입력으로 사용한 합성곱 신경망 모델을 이용해 각 환자의 혈압을 보다 정확하게 추정한다.

둘째로, 서로 다른 환자의 혈압을 하나의 합성곱 신경망 모델로 추정한다. 환자 별로 서로 다른 모델을 필요로 하지 않는다. 기존 연구에서는 새롭게 맞춰야 할 대상이 추가될 때마다 학습 시간과 모델의 저장 공간이 비례하여 증가한다. 뿐만 아니라 특정 환자의 데이터셋으로 모델을 학습시키기 때문에 본 연구에서 제안하는 방법보다 더 적은 수의 데이터를 이용해 과적합에 취약하다. 반면에 제안하는 합성곱 신경망 모델은 서로 다른 환자의 데이터를 단일 모델로 추정하기 때문에 학습 시간 및 저장 공간이 적게 필요할 뿐만 아니라 과적합을 피할 수 있고 강건하다는 특징을 갖는다. 이전에 학습하지 못한 새로운 환자의 데이터가 들어왔을 때에도 추론이 가능한 일반화된 모델이다.

모델 구조는 크게 PPG로부터 특징을 추출하는 메인 모듈과 보정용 데이터로부터

특징을 추출하는 보정 모듈로 나누어진다. PPG 슬롯은 합성곱 신경망 PPG 특징 추출기를 통과하고 혈압을 추정할 PPG에 대한 정보가 담겨있는 벡터 표현을 얻는다. 보정용 모듈에서 보정용 PPG 슬롯은 합성곱 신경망 보정용 PPG 특징 추출기를 통 과하여 보정용 PPG 슬롯에 대한 벡터 표현을 얻는다. 보정용 이완기 혈압과 수축기 혈압은 보정용 PPG 슬롯의 벡터 표현에 연결한 후 하나의 선형 레이어를 통과하여 보정 데이터에 대한 벡터 표현을 얻는다. 보정 데이터의 벡터 표현은 혈압을 추정할 PPG 에 대해서 추가적인 유형 정보를 담고 있다. PPG의 벡터 표현과 보정 데이터의 벡터 표현을 연결한 벡터가 두 개의 선형 레이어를 통과하여 수축기 혈압과 이완기 혈압을 추정한다.

보정용 모듈과 메인 모듈에 있는 특징 추출기는 서로 동일한 모델 구조를 갖지만 파라미터를 공유하지 않는다. 두 특징 추출기가 동일하게 PPG 슬롯을 입력으로 받지만 수행하도록 기대되는 역할이 서로 다르기 때문이다. 메인 모듈의 특징 추출기는 맞춰야 할 혈압에 대한 직접적인 정보를 PPG 슬롯으로부터 도출해야하는 반면에 보정용 모듈 의 특징 추출기는 혈압을 추정할 PPG 슬롯의 유형에 대한 정보를 얻어야 한다. 이후 PPG 슬롯의 유형 정보는 간접적으로 혈압 추정 정확도를 높이는데 기여하는 역할을 한다. 특징 추출기의 모델 구조는 다음과 같다.

3.3 BYOL을 결합한 합성곱 신경망 모델 구조

본 연구에서는 동일한 환자의 데이터를 긍정적인 관계로 사용한 BYOL 모델[32] 을 합성곱 신경망 모델에 추가로 도입했다. 보정용 데이터는 맞춰야 할 PPG 슬롯에 대한 유형 정보를 제공하는데 같은 환자의 데이터는 동일한 유형 정보를 담고 있을 가능성이 높다. 특히 본 연구에서 사용한 데이터셋은 중환자실에서 한정적인 시간 동안 연속적으로 수집되었기 때문에 일 단위, 주 단위의 주기 별로 데이터가 수집된 경우에 비해서 동일 환자 데이터 내에서 환자의 PPG 슬롯 유형이 변화하는 정도가 작은 편이다. 따라서 유형 정보를 학습하기 위한 추가적인 정보로 동일 환자의 데이터를 긍정적인 관계로 활용할 수 있다.

BYOL 모델을 결합한 합성곱 신경망 모델의 구조는 그림 3.8와 같다. BYOL 모델은 보정 모듈의 합성곱 신경망에 적용된다. 보정용 PPG 슬롯이 주어질 때 동일한 환자의 PPG 슬롯을 하나 추출한다. 두 PPG 슬롯은 온라인 네트워크와 타켓 네트워크를 번 같아 통과하고 온라인 네트워크를 통과한 벡터와 타켓 네트워크를 통과한 벡터의 차에 대해 평균 제곱 오차 손실 함수를 계산한다. 온라인 네트워크는 해당 손실 함수를 이용 해 업데이트하고 타켓 네트워크는 온라인 네트워크의 파라미터와의 이동 평균 값으로 천천히 업데이트한다.

BYOL 모델의 자기 지도 학습은 혈압을 추정하는 지도 학습과 동시에 진행된다. 학습을 두 단계로 나누어 BYOL 모델의 자기 지도 학습을 진행한 후에 혈압을 추정하는 지도 학습을 진행할 수도 있지만 이 방법은 사후 학습 과정에서 사전 학습된 파라미터 정보를 잃어버릴 위험이 존재한다. 따라서 본 연구에서는 한 번에 학습을 진행했고 지도 학습 손실 함수와 자기 지도 학습 손실 함수의 가중 합을 최종적인 손실 함수로 사용했다. 두 손실 함수 모두 평균제곱오차 손실 함수를 이용했다.





3.4 데이터 중강



Figure 3.9: 다섯 가지 데이터 증강 기법

모델의 입력 데이터로 활용하는 PPG 슬롯과 혈압 데이터를 수집하는 일은 여타 데이터 수집과 마찬가지로 상당한 비용을 야기한다. 특히 혈압 추정 문제에서 양질의 다양한 데이터를 얻기 위해서는 짧은 시간 동안의 연속적인 수집보다 긴 시간 간격의 주기적인 수집이 필요하고 이는 환자의 데이터를 수집하는데 더 많은 시간과 노력을 필요로 한다. 일 단위 또는 주 단위의 주기적인 데이터 수집은 데이터를 수집하는데 필연적으로 긴 시간을 필요로 하며 짧은 시간 동안 수집할 수 있는 데이터 유형은 비교적 한정적이다. 충분한 데이터를 수집하지 못한 상황에서 모델을 학습할 경우 과적합에 취 약하고 강건하지 않은 모델이 학습되어 학습 데이터와 상이한 유형의 데이터가 입력으로 들어왔을 때 혈압 추정 정확도가 크게 떨어질 수 있다. 이와 같은 상황에서 데이터 증강 방법은 적은 데이터로부터 다양한 상태의 데이터를 확보하여 데이터 수집 비용을 줄일 수 있다. 본 연구에서는 이미지 도메인에서 자주 사용되는 5가지 데이터 증강 방법을 PPG 슬롯에 도입하고 효과를 검증한다.

PPG 신호는 일변량 시계열 데이터라는 점에서 2차원의 이미지 도메인과 차이를

갖는다. 이미지 도메인은 상하좌우로 뒤집어도 대상에 대한 정보 손상이 적은 반면에 PPG 신호는 시간 축이 존재하기 때문에 정보가 비대칭적이고 신호를 좌우 대칭 시키면 신호가 갖는 정보가 크게 변화한다. 또한 이미지의 경우 빨강, 초록, 파랑의 3개의 채널이 존재하는 반면에 PPG 신호는 오직 하나의 채널만 존재한다. 이러한 PPG 도메인의 특성을 반영하면 이미지 도메인에서 사용하는 일부 데이터 증강 기법들은 적용이 어렵고 적용 가능한 방법들도 약간의 변형이 필요한 경우가 있다. 본 연구에서는 PPG 슬롯과 혈압 데이터에 적용 가능한 다섯 가지 데이터 증강 방법을 도입하고 그에 따른 성능 변화를 확인했다. 도입한 데이터 증강 방법은 그림 3.9와 같다.

첫번째 데이터 증강 방법은 시간 축에 대하여 랜덤한 길이만큼 원본 PPG 슬롯을 회전시키는 것이다. PPG 슬롯에 대응되는 혈압은 ABP 신호의 골과 마루의 평균값으로 계산된다. 평균을 사용하기 때문에 시간 축을 기준으로 앞에 있는 골과 뒤에 있는 골의 값이 혈압 값을 계산할 때 동일하게 사용된다. PPG 슬롯의 각 시점의 값들은 해당 시점의 ABP 신호에 대응되므로 PPG 슬롯의 모든 시점의 값 또한 혈압을 추정하는데 있어 동일한 중요도를 갖는다. 따라서 시간 축을 기준으로 PPG 슬롯을 회전시켜도 변형된 슬롯은 동일한 혈압 값을 가져야 한다. 시간 축 회전 데이터 증강 기법을 적용할 때, 회전하는 길이는 균일(uniform) 분포에서 추출한 값을 사용했다.

추가적으로 랜덤한 시간 영역에 마스킹을 하는 것과 잡음을 추가하는 데이터 증강 기법을 도입했다. 모델은 PPG 슬롯의 데이터가 일부 손상된 경우와 신호 전반에 잡음 이 존재하는 경우에도 혈압을 추정할 수 있어야 한다. 본 연구에서는 길이 50의 제로 마스킹을 원본 PPG 슬롯의 랜덤한 시점에 적용했다. 마스킹 시작 시점은 균일 분포에서 랜덤 추출한 값을 사용했다. 잡음을 추가하는 데이터 증강 기법의 경우는 잡음의 종류에 따라 크게 두 가지 방법을 적용했다. 하나는 신호 전반에 걸쳐 동일한 값의 잡음을 추가 하여 해당 잡음만큼 원본 PPG 슬롯의 값을 동일하게 증가하거나 감소하는 방법이다.

잡음은 0.05의 표준편차를 갖는 정규분포로부터 추출한 값을 이용했다. 다른 하나는 PPG 슬롯 길이의 백색 잡음(White Noise)을 원본 PPG 슬롯에 더해주는 방법이다. 0.02의 표준편차를 갖는 가우시안 잡음을 백색 잡음으로 이용했다.

마지막 데이터 증강 기법은 PPG 슬롯의 진동수를 변화시키는 방법이다. PPG 슬롯 에서 진동수는 맥박을 의미하고 높은 맥박은 혈류 속도를 증가시키기 때문에 일반적인 상황에서 맥박과 혈압은 양의 상관관계를 갖는다. 따라서 앞의 데이터 증강 기법들 과 달리 PPG 슬롯의 진동수를 변화시키는 경우에는 대응되는 혈압 값 또한 변형이 필요하다. 본 연구에서는 맥박의 변화율에 해당하는 만큼 혈압의 값을 동일한 비율로 늘이거나 높여주었다. 진동수를 변화시키는 비율은 0.9에서 1.1까지의 값을 갖는 균일 분포에서 추출하여 사용했다. 이 방법은 맥박의 변화에 대해서 양의 상관관계로 혈압을 변화시키는 단순한 방법이기 때문에 추후 유체 역학에 기반한 방정식을 적용하여 맥박의

제 4 장 실험 결과

4.1 데이터셋

모델의 학습, 검증 및 테스트를 위해 MIMIC-III Waveform Database Matched Subset v1.0을 데이터셋으로 사용했다. 해당 데이터셋은 PhysioNet에서 제공하는 공개 데이터셋이며 https://physionet.org/content/mimic3wdb-matched/1.0/ 주소에서 다 운로드 받을 수 있다. 데이터셋은 중환자실에 있는 10,282명의 환자로부터 수집되었고 파형 신호들을 기록한 22,317개의 레코드 파일들과 수치 정보들을 기록한 22,247개의 레코드 파일들을 포함하고 있다. 파형 신호로는 ECG 신호, ABP 신호, PPG 신호 및 호흡 파형 신호 등이 기록되어 있고 수치 정보로는 심박수, 산소 포화도, 수축기 혈압과 이완기 혈압 등의 정보들이 레코드 파일에 기록되어 있다.

PPG 신호를 이용한 혈압 추정 모델을 학습하기 위해서는 파형 신호들 중에서도 PPG 신호와 ABP 신호가 필요하다. 10,282명의 환자 중에서 3,664명의 환자가 PPG 신호와 ABP 신호를 둘 다 포함하고 있다. 두 신호를 모두 포함하고 있는 환자들의 데이터에 대해서 3.3의 데이터 전처리 및 필터링 과정을 수행했다. 환자마다 기록된 레코드 파일의 개수와 길이가 서로 다르기 때문에 전처리를 완료한 후에도 환자 별로 서로 다른 크기의 데이터셋이 생성되었다. 실험 과정에서 특정한 환자의 데이터가 더 많이 포함되는 상황을 방지하기 위해 환자 별로 사용하는 데이터의 크기를 100개로 통일했다. 100개 미만의 크기를 갖는 환자의 데이터셋은 사용하지 않았으며 최종적으로 2,497명의 환자로 이루어진 데이터셋이 생성되었다.

최종 데이터셋에서 수축기 혈압의 분포는 그림 4.1와 같다. 그림 4.2와 그림 4.3를

보면 환자 별로 혈압의 분포가 서로 상이한 것을 확인할 수 있다. 그림 4.2은 환자 별로 수축기 혈압의 평균을 계산하여 분포를 히스토그램으로 나타낸 것이다. 환자마다 평균 수축기 혈압이 서로 상이한 것을 알 수 있다. 그리고 그림 4.3는 10명의 환자의 수축기 혈압에 대한 박스 그래프를 그린 것인데, 수축기 혈압의 평균만 서로 다른 값을 갖는 것이 아니라 데이터가 흩어진 정도도 환자 별로 상이한 것을 확인할 수 있다. 최종 데이터셋 을 학습, 검증 및 테스트 과정에서 80%, 10%, 10%의 비율로 나누어 사용했다. 동일한 환자의 데이터가 학습 및 검증 과정에 동시에 사용되면 모델이 해당 환자의 혈압을 더 잘 추정할 수 있는 문제가 있기 때문에, 본 실험에서는 환자를 기준으로 데이터셋을 나 누어 동일한 환자의 데이터가 학습, 검증, 테스트 데이터셋에 중복되어 포함되지 않도록 하였다.



Figure 4.1: 데이터셋 수축기 혈압의 분포



Figure 4.2: 환자 별 평균 수축기 혈압의 분포





4.2 실험세팅

본 연구에서는 PPG 슬롯과 단일 보정용 데이터를 통해 수축기 혈압과 이완기 혈압을 추정하는 모델을 학습시킨다. 단일 보정용 데이터의 유무가 추정 성능에 미치는 영향을 확인하고, 보정용 데이터를 그대로 추정 값으로 이용하는 베이스라인 모델과 제안하는 합성곱 신경망 모델의 성능을 비교한다. 다음으로 BYOL 모델을 결합하고 자기 지도 손실 함수를 기존 손실 함수에 추가했을 때 성능이 어떻게 나타나는지 확인한다. 그뿐만 아니라 PPG 슬롯에 대한 데이터 증강 기법 다섯 가지를 추가하여 각각의 방법을 이용해 학습 데이터셋을 20 퍼센트 증가시켰을 때 성능의 변화를 확인하고 데이터 증강 효과를 검증한다.

합성곱 신경망 모델 학습 시 배치 사이즈(batch size)는 256으로 설정하였고 10 에폭(epoch)동안 진행하였으며 옵티마이저(optimizer)로는 Adam[33]을 사용하여 모 델 파라미터 값을 최적화하였다. 학습률(learning rate)은 1e-3, 5e-4 두 가지 값에서 시작하여 학습을 진행했고, 학습률 스케쥴링을 통해 학습 속도를 줄이고 미세조정을 통해 더 정교하게 성능이 수렴할 수 있도록 하였다. 스켈줄링 방식으로는 검증 손실 값이 3에폭(epoch)동안 개선되지 않으면 학습률을 0.9배로 축소하도록 해주었다.

혈압 추정 성능 평가 지표로 3가지를 사용하였는데, 첫 번째로 평균 절대 오차 (Mean Absolute Error)를 사용하였고 추가적으로 국내 식품의약품안전 평가원에서 제시하는 전자식 혈압계의 정확성 평가기준인 오차의 표준 편차 (Error Standard Deviation), 오차의 평균 (Error Mean)을 함께 확인하였다. 오차의 평균과 오차의 표준 편차의 경우 하나의 지표만을 이용하여 모델의 성능을 비교하기 어렵기 때문에 모델 간의 성능 비교는 주로 평균 절대 오차를 이용하였다.

4.3 실험 결과

			수축기 혈	갑	이완기 혈압			
model	환자 보정	MAE	EM	ESD	MAE	EM	ESD	
CNN	Х	15.516	-0.229	19.335	8.030	-0.922	10.280	
baseline	Ο	8.974	-1.067	12.563	5.145	-0.362	7.453	
CNN(ours)	Ο	8.292	-0.595	11.123	4.763	-0.113	6.698	
CNN+BYOL(ours)	Ο	8.114	-0.019	10.933	4.752	0.117	6.668	

Table 4.1: 모델 차이에 따른 혈압 추정 성능

합성곱 신경망 모델을 이용한 모든 실험은 5번씩 반복 실험하였고 반복 실험의 평균 성능을 이용하여 비교를 진행했다. 평가 지표 별 가장 좋은 성능은 굵은 글씨로 표시하 였다.

4.3.1 환자 보정 유무에 따른 성능 비교

환자 보정이 혈압 추정 성능에 미치는 영향을 확인하기 위해, 보정용 데이터를 입력 으로 사용하지 않는 합성곱 신경망 모델의 성능을 확인했다. 그림 3.7에서 보정 모듈이 제거된 구조를 가지며 그림 1.1과 같이 PPG 슬롯 만을 입력으로 받아 혈압을 추정하는 모델이다. 실험 결과, 보정용 데이터를 사용하지 않으면 수축기 혈압과 이완기 혈압 모두 성능이 크게 감소하는 것을 확인할 수 있었다. 환자 보정이 있는 합성곱 신경망 모델과 비교했을 때, 수축기 혈압과 이완기 혈압의 평균 절대 오차가 각각 87.1%, 68.6% 증가했다. 그리고 베이스라인 모델과 비교했을 때에도, 수축기 혈압과 이완기 혈압의 평균 절대 오차가 각각 72.9%, 56.1% 크게 증가했다. 베이스라인 모델이 보정용 데이 터의 혈압을 그대로 추정치로 사용하는 단순한 모델임을 고려하면, 단 한 쌍의 PPG 슬롯과 정답 혈압에도 환자에 대한 유용한 정보가 크게 포함되어 있음을 알 수 있다. 정답 혈압 값이 환자의 혈압 추정 성능 향상에 크게 기여한다는 사실을 확인할 수 있다. 그림 4.4와 그림 4.5는 환자 유무에 따라서 수축기 혈압에 대한 정답 및 추정치의 산점도이다. 환자 보정이 없을 때에는 혈압이 낮거나 높을 때에도 모두 평균 혈압에 가깝도록 추정하는 경향을 확인된다. 170 이상으로 추정하는 경우가 하나도 없으며 100 이하의 혈압으로 추정하는 경우도 굉장히 적다. 반면에 환자 보정이 있을 때는 상대적으 로 평균 혈압으로 추정하는 경향이 줄어들고 혈압이 낮거나 높을 때에도 정답에 가까운 혈압을 추정한다. 다만 환자 보정이 있을 때에는 평균 혈압 근처의 정답 혈압에서도 혈압을 아주 높게 추정하거나 낮게 추정하는 경우도 발생하는 것을 확인할 수 있다. 이는 모델이 보정용 데이터의 혈압을 적극적으로 추정에 활용한 결과로 추정할 수 있으며, 혈압의 추정 범위가 넓어지고 성능이 향상되었지만 정답 혈압과 입력으로 들어온 보정용 혈압과 차이가 클 경우 오차도 크게 증가하는 문제가 존재하는 것을 알 수 있다.



Figure 4.4: 환자 보정이 없을 때 수축기 혈압의 정답 및 추정값 산점도



Figure 4.5: 환자 보정이 있을 때 수축기 혈압의 정답 및 추정값 산점도

4.3.2 제안 모델 효과 검증

베이스라인 모델과 비교했을 때, 제안하는 합성곱 신경망 모델의 수축기 혈압과 이완기 혈압의 추정 성능이 모두 개선되었다. 수축기와 이완기의 평균 절대 오차가 각각 7.6%, 7.4% 낮아졌다. 베이스라인과 달리 합성곱 신경망 모델은 혈압을 추정하는데 PPG 슬롯을 사용하므로, 더 높은 추정 성능을 보이는 것으로부터 PPG 신호에 혈압 추정에 도움이 되는 정보가 포함되어 있으며 합성곱 신경망 모델이 해당 정보를 혈압 추정에 사용하고 있음을 추론할 수 있었다. 제안 합성곱 신경망 모델의 성능을 기준으로, 환자 보정이 있지만 단순하게 혈압을 추정하는 베이스라인 모델의 성능 하락 폭보다 환자 보정이 없는 합성곱 신경망 모델의 성능 하락 폭이 훨씬 컸다. 이를 통해 환자 보정이 혈압 추정 정확도 향상에 중요하다는 것을 다시 확인할 수 있었다.

동일한 유형의 PPG 슬롯이 동일한 벡터 표현에 대응될 수 있도록 BYOL을 결합한 합성곱 신경망 모델을 추가로 제안하고 혈압 추정 성능을 확인했다. 데이터셋에서 동 일한 유형의 PPG 슬롯을 직접적으로 찾는 것은 불가능하고 그 기준을 결정하는 것도 모호하다. 그러나 동일한 환자의 PPG 슬롯들이 동일한 유형의 PPG 슬롯으로 이루어져 있을 것이라 가정할 수 있고 동일한 환자의 PPG 슬롯을 긍정적인 관계로 설정한 자기 지도 손실 함수를 도입했다. 그 결과, 합성곱 신경망 모델의 성능은 BYOL을 결합했을 때 추가적으로 개선되어 수축기 혈압과 이완기 혈압의 평균 절대 오차가 2.1% 0.2% 낮아졌다. 이완기 혈압의 추정 성능은 변화가 거의 없었지만 수축기 혈압의 추정 성능은 소폭의 개선이 된 것을 확인할 수 있었고, 동일 환자의 PPG 슬롯의 표현을 동일한 공간 에 매핑되도록 학습시키는 자기 지도 손실 함수의 도입이 더 나은 PPG 슬롯의 표현을 얻는데 기여했다고 추론할 수 있었다.

최종적으로, BYOL을 결합한 합성곱 신경망 모델이 이완기 혈압의 평균 오차 외의 모든 지표에서 제일 좋은 성능은 보였다. 수축기 혈압의 평균 절대 오차가 8.114로 제일

낮았고 오차의 표준편차 또한 10.933으로 제일 낮았다. 그림 4.6과 그림 4.7에는 혈압 추정을 잘한 경우와 못한 환자의 슬롯 번호에 따른 정답 혈압과 혈압 추정치의 라인 그래프가 나타나 있다. 슬롯 번호는 측정 시간 순서로 정렬되어 있지만 인접한 슬롯 간에 시간 간격이 일정하지는 않다. 추정을 잘하지 못한 사례들을 살펴보면 환자의 혈압 변동이 큰 경우 추정 성능이 저조해지는 것을 확인할 수 있다. 그림 4.7의 p094669 환자를 보면 정답 혈압이 중간에 110mmHg대로 크게 떨어지는데 혈압 추정치는 해당 변화를 따라가지 못하는 것을 볼 수 있다. 그리고 p053015 환자의 경우에는 정답 혈압이 처음에는 170mmHg대이지만 시간이 지남에 따라 감소하여 마지막에는 120mmHg대가 되는데 혈압 추정치는 그러한 변화를 따라가지 못한다. 반면에 혈압을 잘 추정한 환자의 경우에는 처음부터 끝까지 비교적 일정한 혈압 수치를 유지하며 작은 감소와 증가는 혈압 추정치도 잘 따라가는 모습을 보인다. 이는 같은 환자의 혈압이어도 시간이 지남에 따라 분포가 크게 변화하면 환자 보정 효과가 떨어져 혈압을 잘 추정하지 못하는 것으로 해석할 수 있다.











4.3.3 데이터 중강

	수축기 혈압			이완기 혈압			
증강 기법	MAE	$\mathbf{E}\mathbf{M}$	ESD	MAE	$\mathbf{E}\mathbf{M}$	ESD	
none	8.114	-0.019	10.933	4.752	0.117	6.668	
$time \ shift$	7.985	0.385	10.767	4.592	-0.190	6.527	
time mask	7.930	-0.042	10.696	4.595	-0.133	6.525	
gaussian noise	8.037	-0.251	10.820	4.619	-0.423	6.551	
value shift	8.032	-0.315	10.761	4.613	-0.075	6.540	
frequency aug	8.129	-0.301	10.878	4.636	-0.279	6.545	

Table 4.2: 데이터 증강에 따른 혈압 추정 성능

다섯 가지 데이터 증강 기법을 이용하여 각각에 대해 학습 데이터셋을 20% 증가시킨 후 추가적인 성능 개선이 이루어지는 지 확인했다. 모델은 앞의 실험에서 가장 좋은 성능을 보였던 BYOL을 결합한 합성곱 신경망 모델을 이용했다. 실험 결과, 진동수 변동 데이터 증강 기법 외의 4가지 기법에서 수축기 혈압과 이완기 혈압 모두 추정 성능이 개선되는 것을 확인할 수 있었다. 진동수를 변동시켰을 때에도 수축기 혈압의 MAE 값이 저하되는 크기보다 이완기 혈압의 MAE 값이 개선된 크기가 더 컸다. 다섯 가지 데이터 증강 기법들 중에서도 특히 시간 마스킹을 해주었을 때, 표준 절대 오차를 기준으로 수축기 혈압과 이완기 혈압의 추정 성능이 2.3%, 3.3% 향상되어 가장 큰 성능 향상을 확인할 수 있었다. 이렇게 성능이 향상될 수 있었던 원인은 데이터 증강 기법 들이 데이터를 변형시켜도 정보의 손상의 부정적인 효과보다 학습 데이터의 다양성을 증가시키는 긍정적인 효과가 더 크게 작용해 모델이 좀 더 강건한 성능을 보인 결과로 해석된다.

제 5 장 결론

5.1 결론

본 논문에서는 합성곱 신경망 모델을 활용해 PPG 신호로부터 혈압을 추정하는 방법을 제시하였다. PPG 슬롯과 정답 혈압으로 이루어진 보정용 데이터를 입력으로 활용하여 환자 보정 효과를 달성했고, 환자 보정을 해주었을 때 보정용 데이터의 크기가 하나임에도 불구하고 혈압 추정 성능이 크게 향상되는 것을 확인했다.

보정용 데이터의 정보를 더 활용하고 보정용 PPG 슬롯에 대한 더 나은 표현을 얻기 위해 BYOL 모델 구조를 결합하고 자기 지도 손실 함수를 도입했다. 자기 지도 학습을 위해 PPG 슬롯의 동일 환자 여부를 긍정적인 관계로 활용했다. 자기 지도 손실 함수와 지도 손실 함수의 가중 합을 손실 함수로 이용하여 학습을 진행한 결과 혈압 추정 성능이 더 개선되는 것을 알 수 있었다. 이를 통해, 동일한 환자의 PPG 슬롯이 동일한 유형의 PPG 슬롯으로 구성되어 있는 경우가 많고 이들의 벡터 표현을 동일한 공간으로 매핑시 켜주는 것이 성능 향상에 기여하였다고 추론할 수 있었다. 생체 신호 정보는 수집 대상 정보가 함께 기록되어 있는 경우가 많기 때문에, 본 연구에서 사용한 자기 지도 손실 함수의 도입은 생체 신호 도메인의 다른 문제에도 적용될 수 있을 것으로 기대된다.

PPG 신호에 적용할 수 있는 다섯 가지 데이터 증강 방법에 대해서 각 방법을 이용해 학습 데이터셋을 10% 증가시켜주었을 때 혈압 추정 성능이 어떻게 변화하는지 비교했 다. 그 결과, 다섯 가지 방법 중 네 가지 방법에 대해서 혈압 추정 성능이 향상되는 것을 확인할 수 있었다. 시간 축을 기준으로 PPG 슬롯을 회전시키기, 랜덤한 시간 범위 제로 마스킹, 가우시안 노이즈 추가 및 전체 영역 동일한 노이즈 추가의 변형을 가해주었을 때

데이터의 정보가 유실됨에도 불구하고 데이터의 다양성을 증가시켜 혈압 추정 성능을 향상시켰다.

최종적으로, 랜덤한 시간 범위에 제로 마스킹을 해주는 방법으로 데이터를 증강시키 고 BYOL을 결합하여 자기 지도 손실 함수를 사용한 합성곱 신경망 모델을 학습시켰을 때, 수축기 혈압 평균 절대 오차 7.930mmHg, 이완기 혈압 평균 절대 오차 4.593mmHg 의 성능을 확보할 수 있었다.

5.2 향후 연구

본 연구에서는 환자 보정에 초점을 맞추어 한 쌍의 PPG 슬롯과 정답 혈압을 보정을 위한 입력으로 활용한 합성곱 신경망 모델을 제안하였고 자기 지도 손실 함수와 데이터 증강을 추가로 도입하여 해당 구조에서의 혈압 추정 성능을 향상시킬 수 있음을 보였다. 그러나 이 과정에서 문제 상황과 실험의 설계를 단순화한 부분도 있기 때문에, 향후 연구를 통해 개선할 지점들이 존재한다.

본 연구에서는 보정용 데이터가 하나만 가용한 상황으로 문제 상황을 제한하였다. 일상 생활에서 보정을 위한 혈압 정보를 얻는 것이 사용자의 불편함과 번거로움으로 인하여 어렵다는 것을 고려할 때, 해당 가정은 사용할 수 있는 보정용 데이터를 최소화한 것으로 볼 수 있다. 그러나 더 많은 수의 보정용 데이터가 가용한 상황이 있을 수 있으며, 그런 문제 상황 하에서는 여러 개의 보정용 데이터를 어떻게 활용하여야 효과적으로 혈압 추정 성능을 향상시킬 수 있는지가 중요한 문제가 된다. 가장 간단하게는 앙상블 방법을 적용해볼 수 있으며, 가용한 보정용 데이터 중에서 성능 향상에 가장 도움이 되는 일부 데이터만을 선택하는 기준 등을 연구해볼 수도 있을 것이다. 뿐만 아니라 보정을 위해 사용하는 데이터의 크기가 늘어남에 따라 혈압 추정 성능이 어떻게 변화하는지 또한 확인해볼 가치가 있다.

본 연구에서 도입한 자기 지도 학습 손실 함수도 개선의 여지가 있다. 특히, 동일한 유형의 PPG 슬롯에 대한 수도 레이블로 동일한 환자의 PPG 슬롯을 활용하였는데, 같은 환자의 PPG 슬롯이더라도 다양한 요인에 의하여 더 이상 같은 유형의 PPG 슬롯이 아닌 경우가 존재한다. 그러나 가까운 시기에 수집된 PPG 신호일수록 비슷한 PPG 유형일 가능성이 높다는 사실을 이용하면 해당 문제를 완화할 수가 있다. 예를 들어, 생체 신호가 수집된 시간 정보를 이용하여 비슷한 수집 시점의 데이터만을 활용하거나 수집 시점의 차이를 클수록 더 작은 중요도를 갖도록 손실 함수의 가중치를 도입한다면

성능 개선을 기대해 볼 수 있다. 또한, 본 연구에서는 데이터 증강 기법이 성능 향상에 기여하는 지 확인하기 위해 각각의 방법들을 따로 따로 사용했다. 만약 성능 향상이 확인된 데이터 증강 기법들을 동시에 사용하여 모델을 학습한다면 성능이 향상될 수 있다.

참고 문헌

- [1] Zewen Li, Fan Liu, Wenjie Yang, Shouheng Peng, and Jun Zhou. A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE* transactions on neural networks and learning systems, 2021.
- [2] Serkan Kiranyaz, Onur Avci, Osama Abdeljaber, Turker Ince, Moncef Gabbouj, and Daniel J Inman. 1d convolutional neural networks and applications: A survey. *Mechanical systems and signal processing*, 151:107398, 2021.
- [3] Sumbal Maqsood, Shuxiang Xu, Son Tran, Saurabh Garg, Matthew Springer, Mohan Karunanithi, and Rami Mohawesh. A survey: From shallow to deep machine learning approaches for blood pressure estimation using biosensors. *Expert Systems with Applications*, page 116788, 2022.
- [4] Gašper Slapničar, Nejc Mlakar, and Mitja Luštrek. Blood pressure estimation from photoplethysmogram using a spectro-temporal deep neural network. Sensors, 19(15):3420, 2019.
- [5] 통계청, 신현영, et al. 2018 년 사망원인통계. 대한의사협회지, 63(5):286-297, 2020.
- [6] Gregory A Roth, Degu Abate, Kalkidan Hassen Abate, Solomon M Abay, Cristiana Abbafati, Nooshin Abbasi, Hedayat Abbastabar, Foad Abd-Allah, Jemal Abdela, Ahmed Abdelalim, et al. Global, regional, and national age-sex-specific

mortality for 282 causes of death in 195 countries and territories, 1980–2017: a systematic analysis for the global burden of disease study 2017. *The Lancet*, 392(10159):1736–1788, 2018.

- [7] Satoshi Umemura, Hisatomi Arima, Shuji Arima, Kei Asayama, Yasuaki Dohi, Yoshitaka Hirooka, Takeshi Horio, Satoshi Hoshide, Shunya Ikeda, Toshihiko Ishimitsu, et al. The japanese society of hypertension guidelines for the management of hypertension (jsh 2019). *Hypertension Research*, 42(9):1235–1481, 2019.
- [8] Remo Lazazzera, Yassir Belhaj, and Guy Carrault. A new wearable device for blood pressure estimation using photoplethysmogram. Sensors, 19(11):2557, 2019.
- [9] Yann LeCun, Yoshua Bengio, and Geoffrey Hinton. Deep learning. nature, 521(7553):436–444, 2015.
- [10] Mohammad Kachuee, Mohammad Mahdi Kiani, Hoda Mohammadzade, and Mahdi Shabany. Cuffless blood pressure estimation algorithms for continuous health-care monitoring. *IEEE Transactions on Biomedical Engineering*, 64(4):859–869, 2016.
- [11] Sanghyun Baek, Jiyong Jang, and Sungroh Yoon. End-to-end blood pressure prediction via fully convolutional networks. *IEEE Access*, 7:185458–185468, 2019.
- [12] Kirk Shelley, Stacey Shelley, and Carol Lake. Pulse oximeter waveform: photoelectric plethysmography. *Clinical monitoring*, 2, 2001.

- [13] Jessica E Wagenseil and Robert P Mecham. Elastin in large artery stiffness and hypertension. Journal of cardiovascular translational research, 5(3):264– 273, 2012.
- [14] Manuja Sharma, Karinne Barbosa, Victor Ho, Devon Griggs, Tadesse Ghirmai, Sandeep K Krishnan, Tzung K Hsiai, Jung-Chih Chiao, and Hung Cao. Cuff-less and continuous blood pressure monitoring: a methodological review. *Technologies*, 5(2):21, 2017.
- [15] Charalambos Vlachopoulos, Michael O'Rourke, and Wilmer W Nichols. Mc-Donald's blood flow in arteries: theoretical, experimental and clinical principles. CRC press, 2011.
- [16] J Crighton Bramwell and Archibald Vivian Hill. The velocity of pulse wave in man. Proceedings of the Royal Society of London. Series B, Containing Papers of a Biological Character, 93(652):298–306, 1922.
- [17] Muhamad Khairul Bin Ali Hassan, MY Mashor, NF Nasir, and S Mohamed. Measuring blood pressure using a photoplethysmography approach. In 4th Kuala Lumpur International Conference on Biomedical Engineering 2008, pages 591–594. Springer, 2008.
- [18] Mico Yee-Man Wong, Carmen Chung-Yan Poon, and Yuan-Ting Zhang. An evaluation of the cuffless blood pressure estimation based on pulse transit time technique: a half year study on normotensive subjects. *Cardiovascular Engineering*, 9(1):32–38, 2009.

- [19] Shrimanti Ghosh, Ankur Banerjee, Nilanjan Ray, Peter W Wood, Pierre Boulanger, and Raj Padwal. Continuous blood pressure prediction from pulse transit time using ecg and ppg signals. In 2016 IEEE Healthcare Innovation Point-Of-Care Technologies Conference (HI-POCT), pages 188–191. IEEE, 2016.
- [20] Yi-Yen Hsieh, Ching-Da Wu, Shey-Shi Lu, and Yu Tsao. A linear regression model with dynamic pulse transit time features for noninvasive blood pressure prediction. In 2016 IEEE Biomedical Circuits and Systems Conference (Bio-CAS), pages 604–607. IEEE, 2016.
- [21] Bing Zhang, Zhiyao Wei, Jiadong Ren, Yongqiang Cheng, and Zhangqi Zheng. An empirical study on predicting blood pressure using classification and regression trees. *IEEE access*, 6:21758–21768, 2018.
- [22] Paul C-P Chao, Chih-Cheng Wu, Duc Huy Nguyen, Ba-Sy Nguyen, Pin-Chia Huang, and Van-Hung Le. The machine learnings leading the cuffless ppg blood pressure sensors into the next stage. *IEEE Sensors Journal*, 21(11):12498– 12510, 2021.
- [23] XF Teng and YT Zhang. Continuous and noninvasive estimation of arterial blood pressure using a photoplethysmographic approach. In *Proceedings of the* 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (IEEE Cat. No. 03CH37439), volume 4, pages 3153–3156. IEEE, 2003.

- [24] Satomi Suzuki and Koji Oguri. Cuffless blood pressure estimation by errorcorrecting output coding method based on an aggregation of adaboost with a photoplethysmograph sensor. In 2009 Annual international conference of the IEEE engineering in medicine and biology society, pages 6765–6768. IEEE, 2009.
- [25] Arata Suzuki and Kazuteru Ryu. Feature selection method for estimating systolic blood pressure using the taguchi method. *IEEE Transactions on Industrial Informatics*, 10(2):1077–1085, 2013.
- [26] Mohamad Kachuee, Mohammad Mahdi Kiani, Hoda Mohammadzade, and Mahdi Shabany. Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time. In 2015 IEEE international symposium on circuits and systems (ISCAS), pages 1006–1009. IEEE, 2015.
- [27] Daisuke Fujita, Arata Suzuki, and Kazuteru Ryu. Ppg-based systolic blood pressure estimation method using pls and level-crossing feature. Applied Sciences, 9(2):304, 2019.
- [28] Francesco Lamonaca, Kurt Barbe, Yuriy Kurylyak, Domenico Grimaldi, Wendy Van Moer, Angelo Furfaro, and Vitaliano Spagnuolo. Application of the artificial neural network for blood pressure evaluation with smartphones. In 2013 IEEE 7th International Conference on Intelligent Data Acquisition and Advanced Computing Systems (IDAACS), volume 1, pages 408–412. IEEE, 2013.
- [29] Shrimanti Ghosh, Ankur Banerjee, Nilanjan Ray, Peter W Wood, Pierre Boulanger, and Raj Padwal. Using accelerometric and gyroscopic data to im-

prove blood pressure prediction from pulse transit time using recurrent neural network. In 2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pages 935–939. IEEE, 2018.

- [30] B Moody, G Moody, M Villarroel, G Clifford, and I Silva. Mimic-iii waveform database matched subset (version1. 0). physionet, 2020.
- [31] Mark Sandler, Andrew Howard, Menglong Zhu, Andrey Zhmoginov, and Liang-Chieh Chen. Mobilenetv2: Inverted residuals and linear bottlenecks. In Proceedings of the IEEE conference on computer vision and pattern recognition, pages 4510–4520, 2018.
- [32] Jean-Bastien Grill, Florian Strub, Florent Altché, Corentin Tallec, Pierre Richemond, Elena Buchatskaya, Carl Doersch, Bernardo Avila Pires, Zhaohan Guo, Mohammad Gheshlaghi Azar, et al. Bootstrap your own latent-a new approach to self-supervised learning. Advances in neural information processing systems, 33:21271–21284, 2020.
- [33] Diederik P Kingma and Jimmy Ba. Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980, 2014.

Abstract

Calibrating PPG Based Blood Pressure Estimation Model Using Convolutional Neural Networks

Haesung Kim Department of Industrial Engineering The Graduate School Seoul National University

Blood pressure estimation using PPG signals is a research field that estimates blood pressure from PPG signals collected non-invasively through optical methods. Unlike existing blood pressure estimation methods, it can estimate blood pressure continuously without user inconvenience in daily life. Recently, using deep learning techniques, studies to estimate blood pressure from the PPG signal itself in an end-to-end manner have been proposed. Although patient calibration, which allows different patients to be distinguished, has significantly improved blood pressure estimation performance, there are not many studies focusing on this.

In this paper, we propose a convolutional neural network model that uses patient calibration data as input. Calibration data consist of a PPG signal of 4 seconds and blood pressure collected from the same patient. This patient calibration method has the advantage of 1) less data needed for calibration, 2) can estimate different patient's blood pressure with a single model, and 3) require only one calibration data to estimate unseen patient's blood pressure. Furthermore, we modified the loss function so that convolutional neural network models can obtain better calibration data representation. We introduced a self-supervised loss function that defines PPG signals collected from the same patient as positive relation and it improved the blood pressure estimation performance.

In addition, we introduced five data augmentation techniques applicable to PPG signals to make more robust convolutional neural network model. We increased the train dataset by 20% using each method and the blood pressure estimation performance is improved in four data augmentation techniques. Finally, when we trained the convolutional neural network model using the modified loss function and time masking augmentation technique, it achieved mean absolute error in the systolic and diastolic blood pressure of 7.930 mmHg and 4.593 mmHg respectively.

Keywords: Blood pressure estimation, Photoplethysmography, Convolutional neural network, Calibration, Self-supervised loss, Data augmentationStudent Number: 2021-23283