



저작자표시-비영리-변경금지 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.



비영리. 귀하는 이 저작물을 영리 목적으로 이용할 수 없습니다.



변경금지. 귀하는 이 저작물을 개작, 변형 또는 가공할 수 없습니다.

- 귀하는, 이 저작물의 재이용이나 배포의 경우, 이 저작물에 적용된 이용허락조건을 명확하게 나타내어야 합니다.
- 저작권자로부터 별도의 허가를 받으면 이러한 조건들은 적용되지 않습니다.

저작권법에 따른 이용자의 권리는 위의 내용에 의하여 영향을 받지 않습니다.

이것은 [이용허락규약\(Legal Code\)](#)을 이해하기 쉽게 요약한 것입니다.

[Disclaimer](#)

공학석사 학위논문

딥러닝 기반의

동맥 혈압 측정 모델 개발

Estimation of Arterial Blood Pressure
using Deep Learning Methods

울산대학교 대학원

의과학과

윤홍균

딥러닝 기반의
동맥 혈압 측정 모델 개발

지도교수 주세경

이 논문을 공학석사학위 논문으로 제출함

2024년 02월

울산대학교 대학원
의과학과
윤홍균

윤홍균의 공학석사학위 논문을 인준함

심사위원 남기병 인

심사위원 주세경 인

심사위원 김준기 인

울산대학교 대학원

2024년 02월

국문 요약

혈압은 남녀노소, 질병유무와 상관없이 지속적인 건강관리를 위한 주요한 활력 징후 중 하나이다. 특히 환자를 대상으로 하는 혈압 측정의 경우, 환자의 예후를 확인할 수 있는 핵심적인 지표 중 하나이며, 중환자에게는 지속적으로 정확한 혈압을 재기 위해 동맥 혈압 측정 방법이 사용된다. 동맥혈압 측정 방법은 연속적으로 정확한 혈압의 수치를 제공하지만, 침습적인 방법이라는 점이 한계점으로 남아있다.

고전적인 혈압 측정 방법부터 가장 최근의 딥러닝을 통한 혈압 예측 방식까지, 혈압 측정기기의 다양한 한계점을 극복하기 위한 많은 연구들이 이루어지고 있다. 본 연구에서는 환자로부터 비침습적으로 수집할 수 있는 심전도 파형과 광전용적맥파형을 활용하여 동맥 혈압을 예측하는 딥러닝 모델을 생성하였으며, 보정을 통하여 더 정확한 혈압 수치를 예측하였다.

연구에서 활용된 데이터는 서울아산병원 중환자실 환자 191명의 환자로부터 추출되었으며, 추출된 데이터의 기간의 분리를 통하여 딥러닝 모델 학습 데이터 셋과 검증 데이터 셋을 구분하였다. 신호에 대한 분할, 다운샘플링 외에 별도의 신호처리 과정 없이 원 신호에 대한 제외 처리와 오토인코더를 활용한 데이터 클리닝을 통해 생성된 데이터 셋을 기반으로 많은 연구에서 활용되어지는 합성곱신경망 기반의 ResNet 모델을 성공적으로 학습시켰다. 본 연구는 환자 모니터 기기로부터 수집된 수축기, 확장기, 평균 동맥 혈압 모두에 대한 광범위한 혈압의 예측을 진행하였다. 오토인코더 클리닝 과정을 통하여, 기존의 수작업으로 진행되는 데이터 제외처리의 과중한 작업량을 줄일 수 있었으며, 저품질의 신호와 정상적인 신호의 분류에 대한 주관적인 판단을 딥러닝 모델을 활용함으로써 객관화할 수 있었다.

의료기기의 측정 성능에 있어 보정방법의 적용은 의료기기의 활용과정에서 사용자에게 보다 더 정확하고 정밀한 값을 제시할 수 있게 해준다. 본 연구에서 생성된 ResNet 딥러닝 모델은 BHS 국제 표준 기준으로 각 동맥 혈압 별 모델 모두 A등급을 부여 받았으며, AAMI 국제 표준의 기준 또한 통과하였다. 보정 전 예측 혈압 값과 실제 혈압 값 간 오차의 평균과 표준편차 값은 수축기: 0.028 ± 6.81 , 확장기: 0.03 ± 4.32 , 평균

동맥 혈압: 0.69 ± 4.52 로 높은 성능을 보였으며, 보정 후에는 수축기: 0.004 ± 4.36 , 확장기: 0.003 ± 3.08 , 평균 동맥 혈압: 0.003 ± 2.78 로 예측 성능이 향상됨을 확인하였다. 보정의 적용 후에 예측 성능이 향상되는 만큼, 생성된 딥러닝 모델이 다양한 환자 군에 적용 될 수 있을 것으로 기대한다.

본 연구는 단일기관, 단일인종의 집단에 한정되어 있으며, 개발된 딥러닝 모델이 실제에 적용되기 위해서는 외부기관 및 다수의 국가에 대한 외부검증이 필수적이다. 또한, 최근 연구에서 더 적은 개수의 센서를 활용한 혈압 측정 방식이 제시 되는 만큼, 딥러닝 방법의 간편성과 예측 성능의 안정성에 대한 비교 검증이 필요하다.

종합하면, 이번 연구를 통해 오토인코더의 품질 분류 방법, ResNet 딥러닝 모델, 그리고 보정 방법을 활용하는 비교적 간단한 방법을 통하여 보다 더 실용적인 연구 방법론을 제시하였다. 본 연구는 침습적인 동맥혈압측정 대신 심전도와 광전용적맥파형을 활용하여 비침습적인 방법으로, 연속적으로 동맥혈압을 예측할 수 있으며, 보정을 통하여 높은 정확도로 혈압을 예측할 수 있다는 측면에서, 다양한 환자군에 대한 적용 가능성을 제시함으로써 임상적으로 의의가 있는 것으로 판단된다.

목 차

국문요약	I
표 목차	VI
그림 목차	VII
서론	1
1. 연구배경	1
2. 인공지능, 머신러닝 그리고 딥러닝	4
3. 딥러닝의 필수 요소	8
4. 심전도, 광전용적맥파를 활용한 선행연구	14
연구 방법	18
1. 활용된 데이터	18
1.1 데이터의 개요 및 특성	18
1.2 데이터 추출, 분할 및 제외처리 기준	20
2. Time Distributed Auto Encoder 모델	28
2.1 모델의 개요 및 구조	28
3. Auto Encoder를 활용한 데이터 클리닝	29
3.1 파형 품질의 분류	29
3.2 Auto Encoder 모델용 데이터 셋	30
3.3 Auto Encoder 모델 학습	32
3.4 Auto Encoder 파형 품질 임계값 결정	33
3.5 ResNet 학습 및 검증용 데이터 클리닝	35

4. ResNet 딥러닝 모델	38
4.1 ResNet 모델의 개요 및 구조	38
4.2 ResNet 모델 학습	39
5. 동맥 혈압 유형별 모델 적용	40
5.1 동맥혈압 예측용 모델 학습	40
6. 보정이 적용된 동맥혈압 예측 모델	41
6.1 보정의 방법	41
6.2 보정을 위한 참고 혈압 값 개수 결정	42
7. 혈압 예측 결과 평가 방법	44
7.1 회귀 목적의 동맥혈압 예측 모델 평가 지표	44
7.2 국제 표준에 따른 혈압 예측 성능 평가	44
7.3 Correlation 분석법 및 Bland-Altman 분석법	45
7.4 예측 오차 분포 분석	45
시험 및 결과	46
1. 혈압 예측 모델 성능 평가	46
1.1 동맥 혈압 예측 모델의 평가 지표에 따른 평가 결과	46
1.2 국제 표준에 따른 예측 성능 평가 결과	47
1.3 Correlation 분석 결과	48
1.4 Bland-Altman 분석 결과	49
1.5 예측 오차 분포 분석 결과	50
2. 보정된 예측 결과의 성능 평가	51
2.1 동맥 혈압 예측 모델의 평가 지표에 따른 평가 결과	51
2.2 국제 표준에 따른 예측 성능 평가 결과	51
2.3 Correlation 분석 결과	52
2.4 Bland-Altman 분석 결과	53

2.5 예측 오차 분포 분석 결과	54
고찰	55
결론	56
참고문헌	57
영문요약 (Abstract)	67

표 목차

- 표 1 대표적 회귀 손실 함수
- 표 2 대표적 분류 손실 함수
- 표 3 대표적 활성화 함수
- 표 4 선행 연구와의 딥러닝 성능 비교 표 [1-2]
- 표 5 보정을 위해 참고된 동맥 혈압 값 개수 결정
- 표 6 BHS에 따른 혈압 측정 장치 등급 기준 프로토콜
- 표 7 AAMI에 따른 혈압 측정 장치 표준 프로토콜
- 표 8 모델 성능의 평가 지표
- 표 9 BHS 표준에 따른 모델의 혈압 예측 성능 평가
- 표 10 AAMI 표준에 따른 모델의 혈압 예측 성능 평가
- 표 11 보정 후 모델 성능의 평가 지표
- 표 12 보정 후 BHS 표준에 따른 모델의 혈압 예측 성능 평가
- 표 13 보정 후 AAMI 표준에 따른 모델의 혈압 예측 성능 평가
- 표 14 PPG, ECG, ML, DL을 활용하여 혈압을 예측한 모델 성능 비교 표

그림 목차

- 그림 1 심혈관 질환과 혈압과의 관계
- 그림 2 튜링 테스트
- 그림 3 단층 퍼셉트론의 예시 및 입력과 출력의 관계 방정식
- 그림 4 다층 퍼셉트론의 예시
- 그림 5 머신 러닝에서 딥러닝으로의 전환
- 그림 6 인공지능과 하위 집합의 벤 다이어그램
- 그림 7 데이터의 양에 따른 학습형 알고리즘의 성능
- 그림 8 인공지능의 역사
- 그림 9 Down Sampling 전 ECG와 PPG의 2초 세그먼트
- 그림 10 Down Sampling 후 ECG와 PPG의 2초 세그먼트
- 그림 11 데이터 추출 알고리즘 개요도
- 그림 12-14 동맥 혈압 별 분포도와 데이터 제외 임계선
- 그림 15 수축기 확장기 평균 동맥압의 분산 분포도와 제외 임계선
- 그림 16 2초 단위로 분할된 심전도 파형 내 분산의 분포도와 제외 임계선
- 그림 17 2초 단위로 분할된 광전용적맥파형 내 분산 분포도와 제외 임계선
- 그림 18 탐지된 파고점의 파형별 개수 비율 분포도와 제외 임계선
- 그림 19 2초 단위로 분할된 광전용적맥파형 내 최대치와 최소치 분포도와 제외 임계선
- 그림 20 2초 단위로 분할된 심전도 파형 내 최대치와 최소치 분포도와 제외 임계선
- 그림 21 본 연구에서 활용된 Time Distributed Auto Encoder의 구조
- 그림 22 파형 품질 분류를 위한 GUI
- 그림 23 GUI 상 선택된(파란 배경) 정상 파형의 신호
- 그림 24 정상파형과 저 품질로 분류된 오토인코더의 학습/검증용 데이터 셋
- 그림 25 오토인코더 모델의 학습 과정 개요도
- 그림 26 오토인코더 모델의 학습, 검증 손실 그래프

- 그림 27-28 정상 파형 및 저 품질 파형의 MSE 분포도
- 그림 29 중첩된 정상 파형과 저품질 파형의 MSE 분포도와 임계선
- 그림 30-31 ResNet 학습 및 검증용 데이터 셋의 MSE 분포도와 임계선
- 그림 32 데이터 셋에 대한 제외 처리 및 클리닝 과정
- 그림 33-34 Plain Layers와 Residual Block의 구조 차이
- 그림 35-38 각 모델 별 손실 곡선
- 그림 39-40 선형 회귀 방법을 통한 보정 방법
- 그림 41-48 보정을 위한 샘플 개수 별 예측 추이와 평균 절대 오차 값
- 그림 49-51 딥러닝 모델의 동맥 혈압 별 Correlation Plot
- 그림 52-54 딥러닝 모델의 동맥 혈압 별 Bland-Altman Plot
- 그림 55-57 딥러닝 모델의 예측 오차 분포도
- 그림 58-60 보정 후 딥러닝 모델의 동맥 혈압 별 Correlation Plot
- 그림 61-63 보정 후 딥러닝 모델의 동맥 혈압 별 Bland-Altman Plot
- 그림 64-66 보정 후 딥러닝 모델의 예측 오차 분포도

서론

1. 연구배경

혈압은 남녀노소, 병환의 유무와 관계없이, 지속적인 건강관리를 위한 주요 활력 징후 중 하나이다. 혈압이 정상적인 범주에서 벗어나 높은 상태 혹은 낮은 상태를 유지하는 것을 뜻하는 고혈압 혹은 저혈압은, 다양한 원인에 수반되어 합병증을 유발한다. 고혈압의 경우, 심부전, 협심증, 심근경색, 신부전, 요독증, 시력 저하, 뇌출혈 혹은 뇌졸중처럼 심장, 신장, 안구, 뇌 등 인체의 다양한 기관에 치명적인 손상을 일으키는 만큼 지속적인 관리가 중요하다.[1],[2] 저혈압의 경우 호흡곤란, 실신, 창백 어지러움 등 뇌 신경과 관련된 증상들을 호소하는 것이 대부분이며, 급성 저혈압의 경우 출혈, 실혈, 그리고 화상, 구토 설사 등에 의한 체액 감소, 쇼크 등으로 나타난다. 비정상적 혈압이 다양한 부작용 및 질환과 관련된 만큼 혈압은 임상에서 활용되는 주요한 활력 징후 중 하나이다.

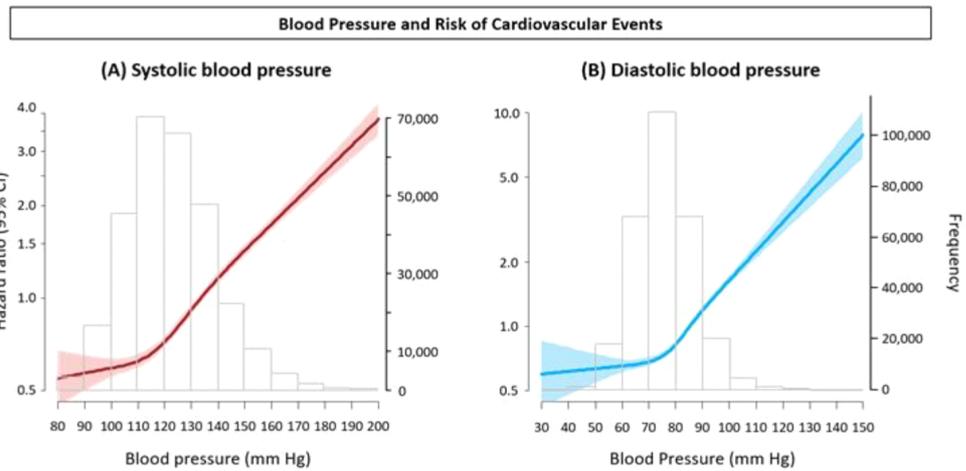


그림 1 혈압과 심혈관 질환의 관계

*The 2017 American College of Cardiology/American Heart Association (ACC/AHA) hypertension guideline. Scientific report, (2018)

비정상적 혈압 증상 중에서도, 고혈압은 세계적으로 유병률이 높은 질환에 속하는데, 국내에서도 고혈압으로 진단된 환자의 수는 1100만 명에 이른다.[3] 다양한 연구에 따르면 심혈관계 질환이 혈압과 관련이 있음을 보이고 있다. 그 중에서도 중환자 혹은 수술이 예정, 진행, 그리고 완료되어 관리 중인 환자의 경우, 치명률, 사망률 그리고 회복률과 관련하여 지속적인 혈압 관리가 필요하며, 혈압은 환자의 상태를 파악할 수 있는 중요한 지표이기 때문에 지속적인 혈압 측정 등 다양한 환자 모니터링이 필요하다.[4]

혈압의 측정 방법과 관련하여, 1733년, S. Hales의 말을 활용한 동물 실험에서 최초의 침습적 혈류역학적 혈관 압력의 변화가 발견되었다.[5] 그 후 J.L.M. Poiseuille에 의해 수은 압력계 등의 비침습적 압력 관찰 방법이 제시 되었고 압력계에 활용되는 재료, 압력을 재기 위한 방법, 압력 측정의 빈도를 개선 시켜 다양하고 발전된 혈압측정 방법이 개발되었다. 1855년, Vierodt에 의해 혈압이 정량화 되었고, 1876년, Marey에 의해 Oscillometric 방법이 처음 시연되었으며, 1905년에는 N. Korotkoff에 의해 개발된 청진 방법을 통한 수축기 및 확장기 압력 측정이론은 심장의 수축기에만 초점을 두던 기존의 비침습적 방법들에 비해 확장기까지 압력을 측정할 수 있게 함으로써 개선을 이루었다. 근대에는 기술의 개발과 함께 이러한 Auscultatory 및 Oscillometric 방법을 커프와 함께 복합적으로 활용하여 자동화한 장치들이 개발되었다. 이후, 초음파를 활용한 방법, 손가락 커프 등 다양하게 세분화된 기술들을 활용한 장치들 또한 개발 되었지만, 여전히 의료 현장에서는 자동화된 커프를 활용한 Oscillometric 방법이 임상에서 비침습적 혈압 측정 방법의 표준으로 사용되어지고 있다.[6]

앞서 언급된 혈압의 다양한 측정 방식은 크게 침습적 혹은 비침습적 방법으로 분류될 수 있다.[7] 비침습적 혈압 측정 방식은 Oscillometric 방법을 활용한 커프 혈압 측정방식이 표준으로 채택되며, 침습적 혈압 측정 방식은 요골 동맥에 삽입 관과 튜브가 연결되어져 압력 센서로 혈압을 직접 측정하는 동맥 혈압 측정 방식이 표준으로 채택되어진다.[8] 두 측정 방법 사이에는 상호적으로 대립하는 장단점들이 존재한다. 비침습적 혈압 측정 방식의 경우, 커프와 기계만으로도 간단하게 혈압을 측정할 수 있는 간편성이 장점이다. 그러나 간접적인 측정 방식인 만큼, 혈압 수치에 대한 신뢰도는 침습적 방법에 비해 떨어지며, 간헐적으로 측정한다는 점과, 커프

를 적용하지 못하는 환자군도 존재한다는 점은 단점으로 작용하게 된다.[9] 침습적인 방법의 장점으로는, 혈류의 연속적인 흐름에 반응하여 혈압을 연속적으로 측정할 수 있다는 점과, 혈류와 직접 접촉하여 얻는 수치만큼 혈압에 대한 높은 신뢰도를 가지고 있다는 것이 장점이다.[8] 그러나 혈관에 카테터를 직접 삽입하여 혈액과 직접 접촉해야하는 매우 침습적인 방법이라는 점과, 통증, 감염 혹은 출혈과 같은 침습적인 방법의 대표적인 부작용들이 동반된다는 것이 단점이다.[10],[11] 이러한 장단점을 감안하여, 환자 상태의 경중에 따라서 혈압을 측정하기 위해 비침습적인 혹은 침습적인 방법을 적용하게 된다.

현대 의학에서는 이러한 혈압 측정 방식의 장단점과 한계점을 극복하기 위해 다양한 연구가 이루어지고 있다. 이러한 한계점을 극복하기 위한 초기 연구의 발단으로, A.I. Moens와 D.J. Kortweg에 의해 원통형 탄성 관의 유체에 대하여 유체의 속도와 압력 간 상관관계가 방정식화 된 이후로 C. Bramwell과 A.V. Hill에 의해 맥파 전달 속도(PWV)와 맥파 전달 시간(PTT) 그리고 맥파 측정 거리간 비례방정식이 정립되면서 비침습적으로 혈압을 계산할 수 있는 방법들이 파생되어졌다.[12],[13],[14],[15] 이후, 맥파와 관련된 Pulse Transit Time, Pulse Wave Velocity, Pulse Arrival Time, Pre-Ejection Period 등 다양한 혈압과 관련된 다양한 지표도 제시되어졌다.[16] 맥박을 추출하기 위한 측정 도구와 관련하여서도 SCG, ECG, PPG, IPG, BCG 등 맥박 신호를 다양하게 그리고 정확하게 측정할 수 있는 다양한 생체신호가 개발, 발전되어 가면서 다양한 맥박을 매개변수화 하며 비침습적 혈압 측정에 활용할수 있는 지표가 지속적으로 개발되어졌다.

최근에는 이러한 신호들을 효율적으로 저장/처리할수 있는 컴퓨터 하드웨어와 소프트웨어의 발전으로 다양한 생체신호 및 활력 지수 그리고 환자의 정보들이 저장되어졌다. 이러한 데이터는 점차 쌓여 빅 데이터가 되었으며, Fen Mio et al.[Num], Back et al.[Num] Kachuee et al.[Num] 등 수많은 저자들에 의한 연구를 배경으로 파형의 주파수, 시계열 분석 및 특성추출을 활용하여, 다변량 선형 회귀 혹은 서포터 벡터 회귀 방법, 가우시안 프로세스 회귀 등과 같은 방법들을 활용해 신호로부터 혈압을 예측할 수 있는 다양한 분석 방법론과 결과를 제시할 수 있게 해주었다.

2. 인공지능, 머신러닝 그리고 딥러닝

인공지능은 예로부터 공상과학 소설에도 자주 등장하며, 많은 수학자와 과학자들에 의해 검증, 실험되어져 왔다. 인공지능의 초기 이론과 관련하여, 학계에서는 1943년 W. McCulloch과 W. Pitts가 발표한 연구에서 스위치로 인간의 뉴런 네트워크를 모방하여 논리적 문제를 해결할 수 있음을 제시한 내용이 물리적 논리 회로를 이용하여 인공지능을 구현한 초기 모델로 여겨진다.[17] 이후 1950년 에니그마 해독머신을 개발하여 큰 공로를 세운 앨런튜링은 그의 저서 "Computer Machinery and Intelligence"에서 기계의 지능을 판단하기 위한 실험인 "Imitation Game"을 제시한다.[18] 튜링 테스트라고도 불리는 이 실험은 기계와 인간의 상호작용을 인간과 인간의 상호작용과 비교함으로써 기계와 인간의 구별 가능 여부에 따라 시험의 통과 여부를 결정하는 실험이다. 1952년에는 Arthur Samuel에 의해 인간과 체커스게임을 독립적으로 수행할 수 있는 프로그램을 설계하며, 기계의 상호작용이 독립적으로 이루어지게 된 상징적인 계기가 되게 되었다.[19] 1955년에는 수학자 및 인공지능 분야에 권위자였던 J. McCarthy가 Dartmouth, New Hampshire에서 주최한 Workshop에서 Artificial Intelligence라는 개념을 처음 도입하면서 인공지능(AI)이라는 개념이 처음으로 대중화 되게 되었다.[20] 1959년에는 프로그래머 Arthur Samuel이 체스 자동 대국 프로그램을 제작하며 기계가 기계의 설계자에게 가르침을 받으며 종국에는 설계자의 실력보다 나아지는 것을 '머신러닝'이라 부르며 머신러닝의 개념이 도입되게 되었다.

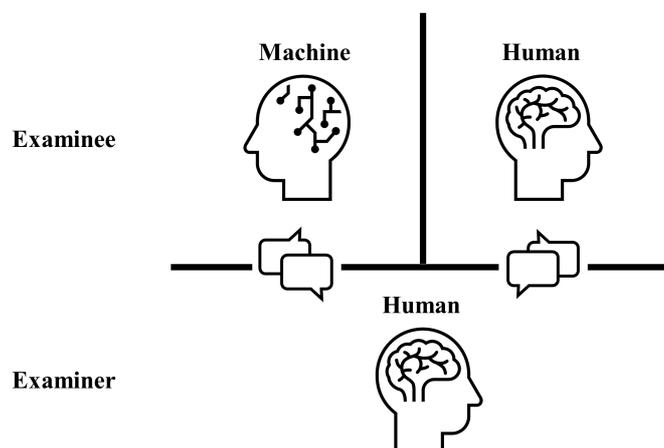
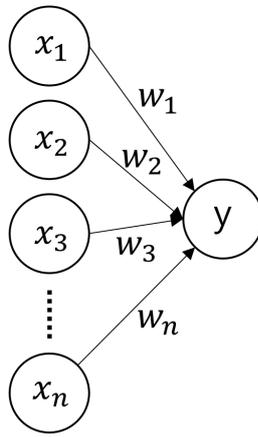


그림 2 튜링 테스트(Turing's Test)

1957년, F. Rosenblatt에 의해 Perceptron 이론이 등장하였다.[21] Perceptron이란, 인간의 신경을 이루는 기초가 되는 신경 뉴런의 위상적 구조를 모방하여 만든 알고리즘이다. 퍼셉트론은 다수의 입력을 받아 활성 (1) 혹은 비활성(0)이 되는 구조인데, 이때 입력을 받는 각 신호에 대하여 가중치를 조절해 감으로써 활성이 되는 임계값을 결정하게 되며 이는 인간 신경의 뉴런이 활성 임계에 도달하면 다음 뉴런에 신호를 전달하게 되는 원리와 비슷하다.



$$y = \begin{cases} 0, & w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n \leq \theta \\ 1, & w_1x_1 + w_2x_2 + w_3x_3 + \dots + w_nx_n > \theta \end{cases}$$

그림 3 단층 퍼셉트론의 예시 및 입력과 출력의 관계 방정식

그러나 이와 같은 Perceptron 구조는, 단층 단일 구조라는 한계점을 가지고 있었다. 1986년, G. Hinton과 그의 동료들은 단층 Perceptron이 가지는 한계를 극복하기 위해 단층 Perceptron을 여러 겹 쌓은 다층 Perceptron 구조를 제시하게 된다.[22] 이러한 다층 Perceptron구조는 인공지능망 분석 방법론의 기초이며, 딥러닝 방법의 기원이 된다. 그러나 이러한 인공지능망 구조는 당시의 기술력과 장비로는 연산을 감당할 수 없었으며, 인공지능 관련 분야는 일명 ‘인공지능 흑한기’를 맞게 된다. 그러나 인공지능은 흑한기를 맞이했음에도 꾸준히 다양한 인공지능 관련 연구가 지속되어져 왔으며, 그 기간 동안 연산처리 기술과 장비의 발전, 특히 병렬 연산에 특화된 Graphical Processing Unit(GPU)의 발전으로 인공지능망 연산에 필수적인 병렬 연산을 높은 속도로 처리할 수 있는 기술들이 고도로 발전하면서, 매우 다양하고 전문적인 분야에서 인공지능 기술

들이 각광을 받게 되며, 매우 높은 성능을 가진 인공지능 기술들이 세분화 되어 인공지능망의 구조, 훈련 방법론, 빅 데이터, 평가 방법론, 가중치 조절 방법론 등의 인공지능의 독립적인 분야가 탄생하게 된다.

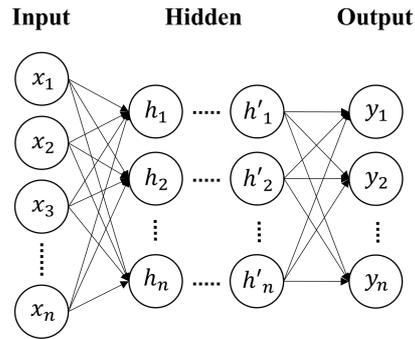


그림 4 다층 퍼셉트론의 예시

2012년, 구글의 Jeff Dean과 Andrew Ng에 의해 인공지능망이 별다른 정보 혹은 Label(인공지능망이 가중치를 조절하게 될 참고 출력 값)없이도 고양이를 인식하게 하는 인공지능망을 설계하며, 딥러닝이라는 머신러닝의 인공지능망 분야 중에서도 더 세분화된 개념을 제시하게 된다.[23] 기존의 앙상블(Ensemble method), 서포트 벡터머신(SVM; Support Vector Machine), 랜덤 포레스트(Random Forest)와 같은 머신러닝 기반 기술과 인공지능망(Neural Network) 기술은 머신러닝으로 분류되는데, 기존의 머신러닝 방법에는 원시 데이터(Raw Data)의 입력만으로는 높은 성능을 도출해 낼 수 없었기에 특징 추출(Feature Engineering), 전처리(Preprocessing)가 필요했다.

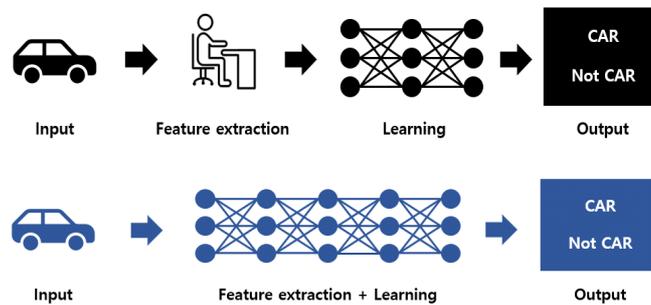


그림 5 머신 러닝에서 딥러닝으로의 전환

이러한 머신러닝 방법론은 성능이 입력과 출력의 통계에 민감하게 반응한다는 한계점이 있었다. 그러나 딥러닝의 필수 요소 중 하나인 데이터를 대용량으로 수집, 보관하는 기술 또한 많은 발전을 이루며 빅 데이터만으로도 별도의 전처리 및 특징 추출 없이도 성능이 높아지는 것을 발견했다. 인공지능경망의 경우 데이터의 양이 많을수록 인공지능경망이 데이터의 통계를 자동으로 반영하기에 기존의 머신러닝 방법에서 딥러닝 방법으로 인공지능 분야의 추세가 전환되게 되었다.

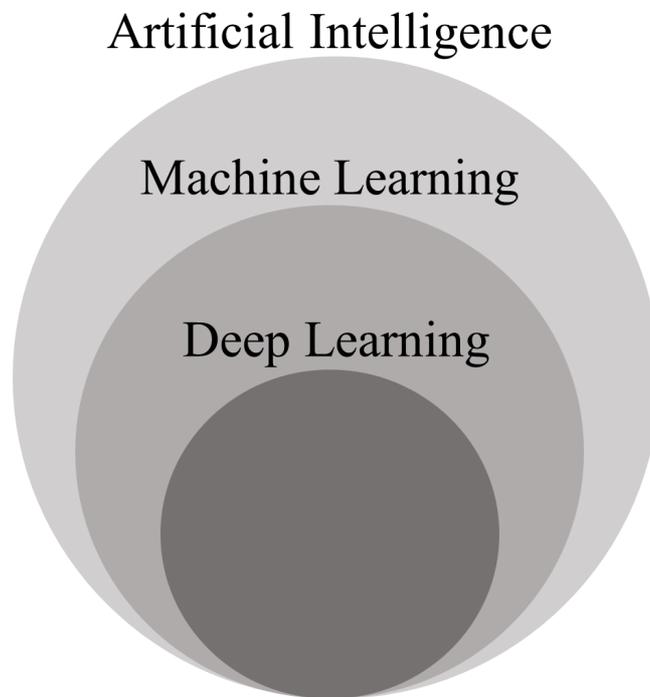


그림 6 인공지능과 하위집합의 벤 다이어그램

3. 딥러닝의 필수 요소

딥러닝이 기존의 방법론으로부터 차별 점을 가지기 위한 필수요소에는 데이터(Dataset), 모델(Model)의 구조, 손실 함수(Loss Function), 활성화 함수(Activation Function) 그리고 최적화(Optimization) 알고리즘이 있다.

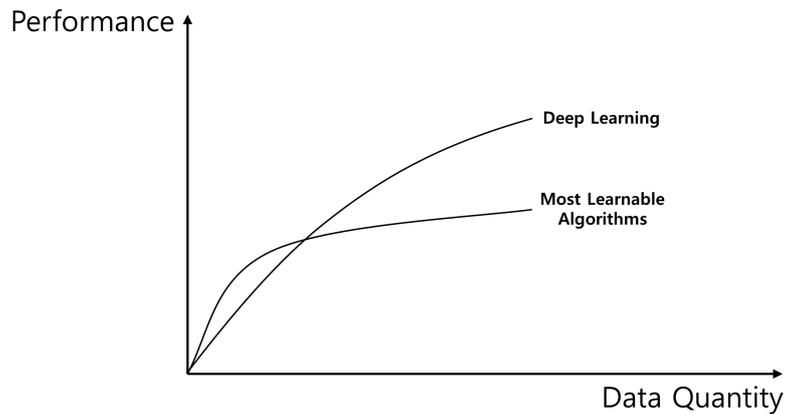


그림 7 데이터의 양에 따른 학습형 알고리즘의 성능

딥러닝 모델이 학습하기 위한 데이터의 양은 많을수록 좋으며, 일부 연구에서는 인공지능망에 필요한 데이터의 양은 인공지능망을 훈련시키기 위한 파라미터(딥러닝 모델에서 변경할 수 있는 가중치와 편향치의 개수)의 10배에서 50배 정도의 데이터가 필요하다는 보고도 있다.[24] 데이터의 양이 부족한 경우에는 데이터 증강법(Data Augmentation) 혹은 데이터의 합성법(Synthetic Data Generation)을 통하여 데이터의 양을 늘리는 방법 등이 존재한다.

딥러닝 모델의 경우, 1943년 Walter Pitt와 Warren McCulloch의 인공신경망을 모사한 컴퓨터부터, 1970년 Kunihiko Fukushima의 합성곱 신경망, 1989년 Yann LeCun의 역전파를 탑재한 합성곱 신경망, 1997년 S. Hochreiter과 J. Schmidhuber에 의해 개발된 장단기 기억 신경망(RNN의 일종, 순환신경망) 등의 매우 다양한 딥러닝 모델들이 존재한다.[25],[26],[27] 특히 합성곱 신경망의 경우, 2차원으로 이루어진 이미지 데이터의 분석에 활용되는 목적으로 설계되어, 매우 높은 성능과 가시적인 활용 방법들이 제시되면서 컴퓨터 비전, 의학, 산업 등 다양한 분야로 파생되었다. 이후, 2000년 초반, GPU 등 하드웨어의 발전과 더불어 2009년

Fei-Fei Li에 의해 14,000,000장의 이미지가 학습된 상태의 ImageNet 모델이 대중에게 공유되었다.[28] ImageNet을 시작으로 각종 딥러닝 성능 비교 대회에서 ImageNet의 경량 모델인 AlexNet, AlexNet을 최적화한 ZFNet, 그리고 VGGNet, GoogLeNet(InceptionNet), Skip Connection 개념으로 성능을 개선한 ResNet, 그리고 GoogLeNet을 개선한 Inception v2/v3/v4 모델이 등장하게 되었다.[29],[30],[31],[32],[33] 생성형 모델의 기반이 되는 AutoEncoder 모델 또한 Skip Connection의 개념이 적용되어 U-net이 개발 되었다.[34] 2014년에는 Ian GoodFellow에 의해 분류형 모델과 생성형 모델의 개념이 합쳐진 GAN(Generative Adversarial Network, 적대적 생성 신경망)이 등장하고 뛰어난 성능을 보이며 기존의 회귀/분류, 비지도/지도 목적으로 설계된 딥러닝 모델들은 생성형 딥러닝 모델이라는 새로운 국면을 맞이하게 되었다.[35] 현재까지는 자연어 모델(Language Models; 자연적으로 존재하는 언어를 처리하기 위한 목적으로 만들어진 딥러닝 모델), 트랜스포머(Transformer; LSTM, GRU 등 순환신경망을 Attention 기법으로 개선시킨 딥러닝 모델) 등 기존 다양한 목적의 모델을 수정, 개선, 보완, 병합한 수많은 기법의 모델이 등장했다.[36] 그 중, 인공지능을 가장 대중화 시킨 Google사의 PaLM, BERT, XLNet, OpenAI사의 GPT, DALL-E는 Transformer 기반 Large Language Model로써, 사전 훈련된 초 거대형 자연어 데이터와 파라미터를 기반으로 답변 생성, 이미지 생성 등의 기능을 실현할 수 있게 해주었으며 현재까지도 인공지능 분야의 새로운 가능성들이 제시되어지고 있다.

The grid contains 60 cards, each representing a significant event in the history of AI. The cards are arranged in a grid and include the following information:

- Year:** Located in a blue box at the top of each card.
- Title:** The name of the event or milestone.
- Description:** A brief summary of the event.
- Image/Diagram:** A small visual representation related to the event.
- Category:** Indicated by a colored box at the bottom of the card: blue for 'AI Winter' and red for 'Events Leading to AI Winter'.

Legend:

- AI Winter (Blue box)
- Events Leading to AI Winter (Red box)

Parisa Rashidi, January 2023. CC BY 4.0

그림 8 인공지능의 역사 [37]

다양한 인공지능 기반 딥러닝 모델을 학습 시키는 과정 중, 인공지능의 한 노드(가중치와 편향에 따라 활성화 및 비활성 되는 인공지능의 최소 단위)의 각 가중치와 편향 값을 조정해 나가는 것에 있어서 모든 딥러닝 모델은 각 모델의 목적에 따른 손실 함수를 활용하여 가중치를 조절해 나가게 된다. 입력 층에서 출력 층 방향으로 가중치를 조절해 나가는 것은 순전파, 출력층에서 입력층 방향으로 가중치를 조절해 나가는 것은 역전파라 한다. 이때 실제 값과 예측 값의 오차를 손실(Loss)이라 하며, 손실의 계산 방법에 따라 순전파, 역전파 모두 영향을 받게 되어 손실함수의 적절한 선정은 최상의 성능을 결정하는데 필수적인 요소이다.

회귀 목적의 손실 함수에는 예측 값과 실제 값의 차이를 이용한 오차를 기준으로 손실함수가 계산되며, 평균 절대 오차(MAE: Mean Absolute Error), 평균 제곱 오차(MSE: Mean Squared Error), 평균 제곱근 오차(RMSE: Root Mean Squared Error), 평균 절대 백분율 오차(MAPE: Mean Absolute Probabilistic Error) 등이 있다.

손실 함수	계산 식
평균 절대 오차 (MAE)	$\frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
평균 제곱 오차 (MSE)	$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
평균 제곱근 오차 (RMSE)	$\frac{1}{n} \sum_{i=1}^n \sqrt{(y_i - \hat{y}_i)^2}$
평균 백분율 오차 (MAPE)	$\frac{1}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $

표 1 대표적 회귀 손실 함수

분류 목적의 손실 함수는, 이진 교차 엔트로피 오차(BCE: Binary Cross entropy), 단정적 교차 엔트로피 오차(CCE: Categorical Cross Entropy), 힙지 손실(Hinge Loss)함수, 포컬 손실(Focal Loss) 손실함수 등이 있다.

손실 함수	계산 식
이진 교차 엔트로피 (BCE)	$-\sum_{i=1}^2 t_i \log(s_i)$
단정적 교차 엔트로피 (CCE)	$-\sum_{j=0}^M \sum_{i=0}^N (y_{ij} \times \log(y'_{ij}))$
Hinge 손실 함수	$\sum_{j \neq y_i} \max(0, s_j - s_{y_i} + 1)$
Focal 손실 함수	$-\sum_{i=1}^2 (1 - s_i)^\gamma t_i \log(s_i)$

표 2 대표적 분류 손실 함수

인공 신경망의 가장 기본적인 단위가 되는 Perceptron이 처음 제시되었을 때는 이진 계단함수 형태의 활성화 함수가 적용되었다. 그러나 이진 계단 함수만으로는 비선형적인 문제는 해결할 수 없는 한계점이 있었다. 이러한 문제를 해결하기 위해 Sigmoid, Softmax, Tanh, ReLU, Leaky ReLU, Parametric ReLU 등의 활성화 함수가 활용되고 있다. 일반적으로 회귀 문제일 경우, 선형성을 반영하기 위해 ReLU 계열의 활성화 함수를 사용하며, 가장 마지막 출력층에 ReLU 계열의 활성화 함수를 씌으로써 MAE 등의 회귀 손실함수와 함께 회귀 문제를 해결한다.

활성화 함수	계산 식	활성화 함수	계산 식
이진 계단 함수	$\sigma(x) = \begin{cases} 0, & x \leq 0 \\ 1, & x > 0 \end{cases}$	ReLU 함수	$f(x) = \max(0, x)$
시그모이드 함수	$\sigma(x) = \frac{1}{1 + \exp(-x)}$	ELU 함수	$f(x) = \begin{cases} x, & x \leq 0 \\ \alpha(e^x - 1), & x > 0 \end{cases}$
Tanh 함수	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	LeakyReLU 함수	$f(x) = \max(0.01x, x)$
소프트맥스 함수	$y_k = \frac{\exp(a_k)}{\sum_{j=1}^n \exp(a_j)}$	PReLU 함수	$f(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & otherwise \end{cases}$

표 3 대표적 활성화 함수

인공신경망의 데이터, 모델, 손실함수와 활성화 함수가 상호작용 하며 예측 값의 손실에 따라 전파를 진행 할 때, 최적화 알고리즘은 초반에 무작위로 설정된 가중치들을 순전파-예측 손실 계산-역전파-가중치 조정 과정을 반복해간다. 이러한 최적화 알고리즘은 학습률(Learning Rate)라는 중요한 초매개변수(Hyper Parameter)를 입력 받아 가중치를 조절하는 속도를 늘리거나 늦춘다. 최적화 알고리즘은 Gradient Descent, Stochastic Gradient Descent, Adam, Adagrad, RMS Prop 등 다양한 함수들이 있다.

4. 심전도, 광전용적맥파를 활용한 선행연구

의료, 자율주행, 금융, 언어, 로봇 등 다양한 분야에서 딥러닝 분야의 적용 성공 사례를 발표하며, 현재까지도 딥러닝 분야는 계속 발전 중이다. 의료 분야 중에서도 딥러닝을 사용하여 혈압을 예측하기 위한 연구 방법은 다양한 연구자들에 의해 현재까지도 활발하게 제시되어진다.[38] 본 연구는 딥러닝 방법, 심전도, 광전용적맥파를 활용하여 동맥혈압을 예측한 연구이며, 딥러닝 방법과 같은 신호를 활용하여 혈압을 예측한 연구는 아래와 같다.

2006년, Kim et al.은 심전도 및 광전용적맥파로부터 맥파 전달 시간을 계산하기 위한 각종 매개변수를 추출하여 인공신경망을 훈련시켰으며, 인공신경망의 성능을 선형회귀 모델과 비교하기 위해 머신 러닝인 다중 선형 회귀 모델과 다중 비선형 회귀 모델을 추가로 훈련 시켰다.[39] 결과는 오차의 평균과 분산 기준, 수축기 혈압에 대하여 다중 선형 회귀 모델: 6.31 ± 3.89 [mmHg], 다중 비선형 회귀 모델: 5.67 ± 3.71 [mmHg] 그리고 인공신경망 모델: 4.53 ± 3.71 [mmHg]를 달성하여 인공신경망의 예측력이 다중선형회귀 모델보다 우월함을 증명하였다.

2013년, Mohamed Kachuee et al.은 심전도와 광전용적맥파로부터 맥파 전달시간, 심박수, 광전용적맥파를 추출하여 인공신경망과 Support Vector Machine(SVM: 서포트벡터 머신, 머신러닝의 일종)을 훈련하였으며, 오차의 평균 및 분산을 기준으로 수축기: 12.38 ± 16.17 [mmHg], 확장기: 6.34 ± 8.45 [mmHg], 그리고 평균 동맥압: 7.52 ± 9.54 [mmHg]를 달성하였다.[40]

2018년 중순, Ümit Şentürk et al.은 심전도와 광전용적맥파로부터 22개의 시계열 특성을 추출하여 인공신경망을 훈련하였고, 평균 및 분산을 기준으로 수축기 -0.14 ± 2.55 [mmHg], 확장기 -0.004 ± 1.6 을 달성하였다. 2018년 말, 같은 저자는 심전도 및 광전용적맥파로부터 시계열 영역 특성을 추출하여 Bi-LSTM 모델을 훈련시켜 평균 제곱근 오차(RMSE)를 수축기 기준 3.63 [mmHg], 확장기 기준 1.48 [mmHg]를 달성하였다.

2018년도에 또 다른 저자 Su et al.은 심전도 및 광전용적맥파로부터 맥파 전달속도(PTT), 심박수(HR), 그리고 맥파(Pulse Wave)를 추출하여 LSTM 모델에 훈련 시켜 평균 제곱근 오차를 수축기 기준 3.90 [mmHg], 확장기 기준 2.66 [mmHg]를 달성하였다.[41]

2019년, Tanveer & Hasan et al.은 각 두 개씩의 심전도와 광전용적맥파로부터 위상적인(파형의 형태) 특성을 추출하여 ANN(기본 인공신경망)과 LSTM을 훈련시켜 오차의 평균과 분산을 수축기 기준 0.01 ± 1.26 [mmHg], 확장기 기준 0.001 ± 0.72 [mmHg]를 달성하였다.[42]

2019년 Ripoll과 Vellido는 심전도와 광전용적맥파의 맥파 전달 시간을 추출하여, Restricted Boltzmann machine artificial neural network를 훈련시켜 오차의 평균 절대 편차를 수축기 기준 4.76[mmHg], 확장기 기준 3.41[mmHg]을 달성하였다. 이 연구의 경우, 보정이 없으면 임상에 활용되기 어렵다는 단점이 있었다.[43]

2019년, Wang et al.은 심전도와 광전용적맥파의 맥파를 활용하여 선형 회귀, 서포트 벡터 머신(SVM), 그리고 인공신경망을 훈련시켜 오차의 평균과 분산 기준 수축기: 6.53 ± 2.21 [mmHg], 확장기: 3.17 ± 1.18 [mmHg]를 달성하였다.[44]

2020년, Ümit Şentürk et al.은 심전도와 광전용적맥파로부터 시계열 영역과 주파수 영역의 Chaotic 특성을 추출하여 NARX-NN (Non linear Autoregressive Network with Exogenous Inputs Neural Networks), 순환신경망(RNN), 그리고 LSTM으로 이루어진 신경망을(LSTM-NN) 훈련하여 오차의 평균과 분산을 수축기 기준 0.022 ± 2.21 [mmHg], 그리고 확장기 기준 0.041 ± 1.21 [mmHg]을 달성하였다.[45]

Year	Authors	Utilized sensors	Methods	Filtering/Exclusion	Extracted Features / Waves	Error evaluation Metrics	Error Results [mmHg]		
							SBP	MAP	DBP
2006	Kim et al.	PPG, ECG	Multiple Regressions(LLR)	N/A	Pulse Transit Time Parameters	MAE and Std	6.31±3.89	N/A	N/A
			Multiple Regressions(NLR)				5.67±3.71	N/A	N/A
			Artificial Neural Network				4.53±3.71	N/A	N/A
2015	Kachuee et al.	PPG, ECG	Support Vector Machine(SVM)	Daubechies 8 Wavelet Denoising, Manual Removement of Unacceptable Heart Rate, Blood Pressure Values etc.	Pulse Transit Time, Heart Rate, PPG Pulse Waves	MAE and Std	12.38±16.17	7.52±9.54	6.34±8.45
			Artificial Neural Network				13.78±17.46	8.84±11.24	6.86±8.96
2016	He et al.	ECG, PPG	Random Forest	WFDB toolbox for peak/onset detection for ABP and ECG	RRI, PTT, RBW, etc.	MAE and Std	8.29±5.84	N/A	4.44±3.72
2016	Gao et al.	PPG	Discrete wavelet transform, Supervised Learning	Wavelet Transformation	PPG waveform from phone	MAE	5.10	N/A	4.6
2017	Kauchee et al.	PPG	AdaBoost	Wavelet Denoising, Dimensionality Reduction	Pulse Transit Time	MAE and Std	11.17±10.09	N/A	5.32±6.14
2018	Ümit Şentürk et al.	PPG, ECG	Artificial Neural Network	Discrete Wavelet Transform	22 Time Domain Features from ECG and PPG	*ME and Std	-0.14±2.55	N/A	-0.004±1.6
2018	Dey et al.	PPG	Combined model (Lasso Regression / Machine learning Models etc.)	Wavelet smoothing, Trend removal, manual exclusion etc.	PPG morphological Features, VPG, APG, etc.	MAE and Std	6.9±9.0	N/A	5.0±6.1
2018	Simjanoska et al.	ECG	Complexity Analysis, ML	Butterworth Bandpass filter	Complexity Analysis Features	MAE and Std	7.72±10.22	9.45±10.03	8.13±8.84
2019	Tanveer et al.	PPG, ECG (2 each)	Artificial Neural Network	Tunable-Q wavelet transform	Morphological Features	*ME and Std	0.01±1.26	N/A	0.001±0.72
			LSTM						
2019	Wang et al.	PPG, ECG	Linear Regression	Daubechies 8 Wavelet Denoising	Pulse Waves	MAE and Std	14.67±16.94	N/A	9.38±17.33
			Support Vector Regression				7.09±1.80	N/A	3.98±1.21
			Artificial Neural Network				6.53±2.21	N/A	3.17±1.18

표 4-1 딥러닝 방법 및 PPG, ECG 센서를 활용하여 혈압을 예측한 선행 연구와의 성능 비교 표

Year	Authors	Utilized sensors	Methods	Filtering/Exclusion	Extracted Features / Waves	Error evaluation Metrics	Error Results [mmHg]		
							SBP	MAP	DBP
2020	Ümit Şentürk et al.	PPG, ECG	Nonlinear Autoregressive Network with Exogenous Inputs Neural Networks (NARXS-NN), Recurrent Neural Network, LSTM Neural Network(LSTM-NN)	5-40 Hz IIR filter, Median filter, Moving Average Beat Calculation	Chaotic Time and Frequency Domain Features	*ME and Std	0.022±2.21	N/A	0.041±1.21
2020	Liu et al.	ECG, PPG	Random Forest	Poor PPG signal quality exclusion	15 Features from ECG, PPG Waveform	*ME and Std	-0.04±6.11	N/A	-0.18±4.13
						MAE	5.89	N/A	2.59
2020	Eom et al.	ECG, PPG, BCG	CNN, Bi-GRU	2nd order butterworth filter, Outlier Exclusion	Segmented ECG, PPG, BCG waveform	*ME and Std	-0.20±5.83	N/A	-0.02±4.91
						MAE and Std	4.06±4.04	N/A	3.33±3.42
2020	El-Hajj et al.	PPG	Bi-GRU,GRU,Attention	Savitzky-Golay filter	22 Features from 7-second segment window of PPG waveform	*ME and Std	-0.52±4.22	N/A	-0.66±2.07
						MAE and Std	2.58±3.35	N/A	1.26±1.63
2020	Fen Miao et al.	ECG	Resnet, LSTM	Wavelet Denoising	Segmented ECG waveform	*ME and Std	-0.11±9.99	-0.01±6.29	-0.03±6.36
						MAE and Std	7.10±9.99	4.66±6.36	4.61±6.29
2021	Athaya et al.	PPG	U-net	Equiripple FIR filter, Noise/Artifact segments removal, Phase matching	Segmented PPG waveform	MAE and Std	3.68±4.42	2.17±3.06	1.97±2.92
2021	Yang et al.	PPG, ECG	Hybrid Model with 3 CNN Blocks	Chebyshev II bandpass filter (0.5-10Hz) , Butterworth(0.5-40), Neighboring Peaks	12 Morphological features from PPG, 7 Morphological features from ECG, Physical characteristics	MAE and Std	4.43±6.09	N/A	3.23±4.75
2023	Zhang et al.	PPG	CFR	High Pass filtering with 40Hz	BPM, SDNN, RMSSD, IBI, etc.	MAE	2.9	N/A	1.76
						*ME and Std	0.028±6.81	0.69±4.52	0.03±4.32
						*ME and Std (After Calibration)	0.017±4.09	0.009±2.62	0.003±3.01
2023	Our Work	PPG, ECG	ResNet	Outlier Exclusion, Auto Encoder Anomaly Threshold Exclusion	Segmented ECG,PPG Waves	MAE	4.64	3.18	2.96
						*ME and Std	0.017±4.09	0.009±2.62	0.003±3.01
						MAE (After Calibration)	2.54	1.52	1.71

표 4-2 딥러닝 방법 및 PPG, ECG 센서를 활용하여 혈압을 예측한 선행 연구와의 성능 비교 표

연구 방법

1. 활용된 데이터

본 연구에서 활용된 데이터는 서울 아산 병원 ICU에 입원한 환자의 상태를 모니터링(상시 관찰)하는 GE사 Carescape-B650 환자 모니터기로부터 추출된 2018년 4월부터 2019년 5월까지 추출된 원시 데이터 중, 2018년 4월부터 2019년 03월까지의 191명의 환자로부터 추출 되었다. 원시 데이터는 두 가지 범주로 수집되었으며, 간헐적으로 수집된 22개 종류의 생체 활력 수치 데이터와 연속적으로 수집된 10개의 생체 신호 파형 데이터로 구성되어있다. 수치 데이터는 신호로부터 측정된 심박, 산소포화도, 동맥혈압(수축기, 확장기, 평균), 호흡수 외 16개 데이터로 구성되어 있으며, 생체 신호 파형 형태의 데이터는 7개의 심전도, 동맥혈압, 산소포화도 파형 데이터로 구성 되어 있다. 딥러닝 모델 학습용 데이터는 2018년 4월부터 2018년 9월까지의 98명의 약 5063시간 길이의 시간 동기화된 데이터로 이루어져 있다. 환자 모니터의 기록 시작 시간부터 종료 시간까지 시간 동기화된 기록을 기준으로 제외 없이 순차적으로 데이터를 수집하였다. 딥러닝 모델 검증용 데이터는 2018년 10월부터 2019년 3월까지의 93명에 대한 10분 길이의 레코드 80개로, 총 7740개의 연속 기록 데이터로 이루어져 있다. 데이터의 추출, 분할, 전처리는 MATLAB 프로그램으로 추출하였으며, 딥러닝 모델 설계, 학습, 결과 분석은 Python의 Tensorflow 및 Keras 라이브러리를 활용하였다.[46][47][48]

1.1 데이터의 개요 및 특성

연속 생체 신호 파형 데이터와 수치형 데이터 중, 본 연구에 활용된 데이터는 심전도 파형, 광전용적맥파형, 수축기/확장기/평균 동맥 혈압 수치이다. 모든 데이터는 측정 빈도에 맞추어 측정 시각(Time Stamp)이 포함되어 있다. 심전도 파형의 경우, V2 ECG Lead 파형이 240Hz의 측정 빈도로 수집 되었으며, 광전용적맥파형은 60Hz로 수집 되었다. 데이터 상에는 광전용적맥파형이 연속 생체 신호 파형 기록상 제일 높은 측정 빈도인 240Hz에 맞추어 리샘플링(Resampling; 파형의 측정 빈도를 재조정 하는 기법)되어 있었기 때문에, 심전도 파형을 다운샘플링(높은 측정 빈도를 낮은 측정 빈도에 맞추어 측정 빈도를 의도적으로 낮추는 기법)하여 파형을 60Hz로 통일하였다. 수축기/확장기/평균 동맥 혈압 수치 데이터의 경우, 0.5Hz의 측정 빈도로 수집 되었다.

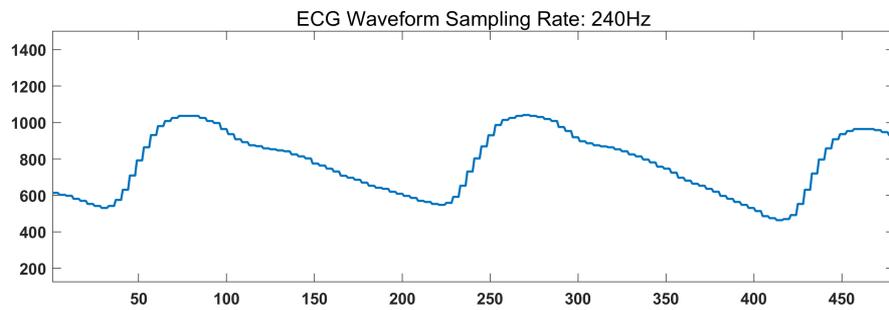
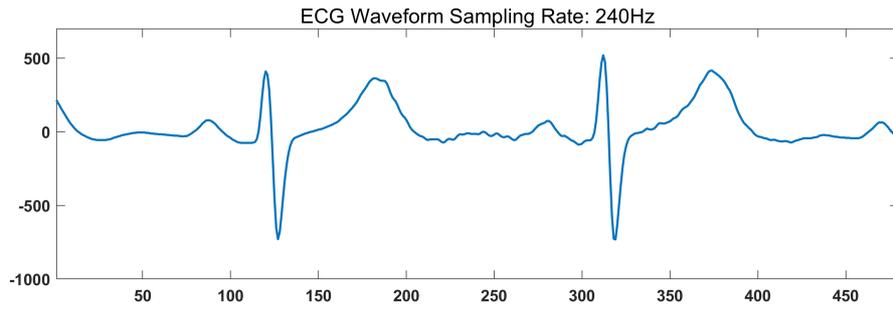


그림 9 Down Sampling 전 ECG와 PPG의 2초 Segment

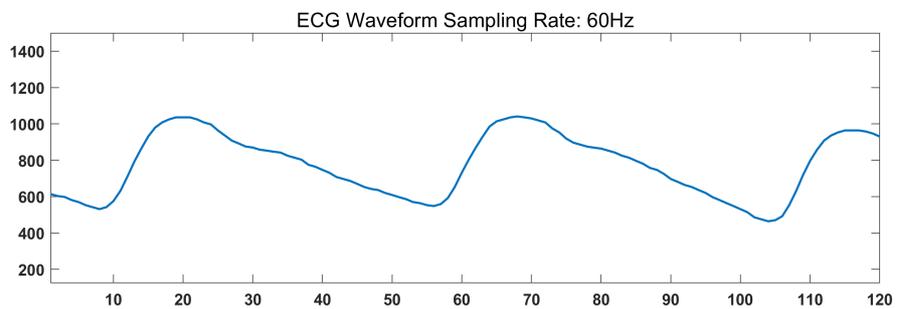
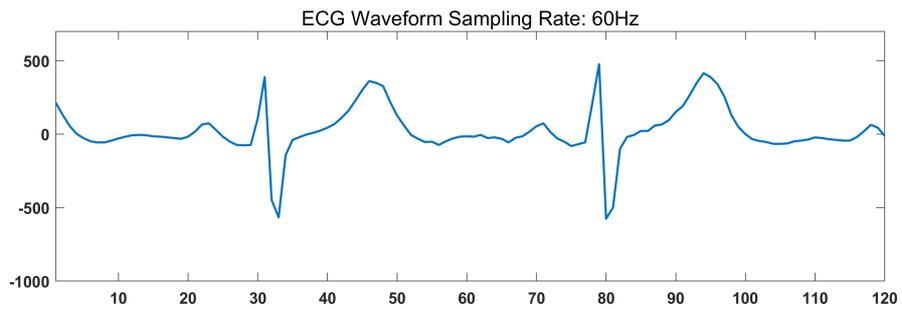


그림 10 Down Sampling 후 ECG와 PPG의 2초 Segment

1.2 데이터의 추출, 분할 및 제외처리 기준

데이터는 MATLAB(Mathworks Inc., USA) 프로그램을 이용하여 추출하였다. 알고리즘 내에서 결측값(NaN, Empty Cells)이 발견 되면 자동으로 제외처리가 되도록 하였으며, 파일에 이상이 없음을 확인 후, 심전도와 광전용적맥파를 추출하여 수치형 데이터의 측정 빈도에 해당하는 2초(120 샘플) 길이로 분할하였다. 이후, 각 분할된 심전도와 광전용적맥파의 마지막 샘플에 해당하는 측정 시각의 ± 1 초 범위 내의 시간에 해당하는 수축/확장/평균 동맥혈압 수치를 찾아 연속 파형 데이터와 결합하였다. 연속 생체 신호 파형에 별도의 고주파/저주파 필터는 적용 하지 않았으며, 원 신호(Raw Data)의 형태로 딥러닝 분석을 위한 데이터 셋을 만들었다.

딥러닝 모델을 학습시키기 위한 데이터 셋을 추출하는 과정에서 원시 신호 데이터에는 다양한 이상치가 존재하며, 이는 모델의 학습과정에 영향을 준다. 따라서, 추출된 데이터 셋에서 이상치에 해당하는 데이터를 제거하기 위해 다양한 기준을 적용하였다. 수치 형태의 동맥 혈압에 포함된 이상치의 경우 동맥혈압 수축기 기준 최소 -82의 값부터 , 최대 349의 값을 포함한다. 이러한 이상치는 소수의 데이터임에도 불구하고 모델학습과 모델의 표준화와 성능에 영향을 주기 때문에 기준을 정하여 이상치를 제외했다. 수축기는 최소 40 최대 200의 기준을 적용하였다.[49],[50] 평균 동맥 혈압과 확장기 동맥혈압은 최소 0, 최대 200 기준으로 잡았으며, 이 범위를 벗어나는 동맥혈압은 이상 값으로 간주하여 제거하였다.[그림12],[그림13],[그림14] 또한, 2초의 심전도와 광전용적맥파형의 시간에 동기화된 동맥혈압 수치는 수축기, 확장기, 평균 총 3가지가 제공된다. 정상적인 경우, 3가지의 혈압 별 분포가 다르다는 것을 간주하여 3개의 수치의 분산을 기준으로 이상치를 제외하였으며, 데이터를 최대한 보존하기 위해 95%의 신뢰 수준을 정하여 $\mu(\text{평균}) \pm 1.96 * \sigma(\text{분산})$ 을 기준으로 3개의 동맥혈압 수치 별 분산 값에 적용하여 이상치를 제외 하였다. 2초 연속 심전도와 광전용적맥파형의 경우, 측정 환경의 영향에 의해 신호가 비접촉 상태가 되어 파형의 변화가 없거나, 과도하게 요동(Fluctuation)치는 신호가 있다. 특히, 광전용적맥파형의 경우, 빛을 활용한 측정 방법이라는 특성 때문에 노이즈(Noise: 원하는 측정 신호 외에 다른 간섭이 개입되는 현상)가 많이 발생한다. 이러한 점을 극복하기 위해 본 연구에서는 심전도와 광전용 적맥파형의 2초 분할 신호에 대하여 분산을 기준으로 이상치를 제거하였다. 심전도 분할 파형의 분산 값의 경우, 95%신뢰 수준을 고려하여 $\mu(\text{평균}) \pm 1.96 * \sigma(\text{분산})$ 을 적용하였다. 분할 광전용적맥파형의 분산 값의

경우, 좌측으로 치우친 형태의 분포의 비대칭적 특성상 95%의 신뢰수준으로 제외 임계값을 적용할 수 없었기 때문에 $\mu(\text{평균}) - \sigma(\text{분산})$ 을 적용하여 2초 내의 광전용적맥파형의 분산 값이 85.06 미만인 값을 이상 값으로 간주, 제외하였다. 다음 이상치 제외 기준으로는, 수집된 연속 파형 신호, 그리고 수치형 신호는 같은 시간 간격을 기준으로 수치형 신호와 ± 1 초 오차 이내로 데이터 셋이 구성 되었으며, 동일 시간대의 맥박이 같다는 점을 가정하여, 각 2초 분할 연속 파형 심전도와 광전용적맥파형에 파고점 탐지(Peak Detection) 알고리즘을 적용하여, 발견된 파고점 개수의 비율로 이상 값 제외를 진행하였다. 95%신뢰 수준을 고려하여 $\mu(\text{평균}) \pm 1.96 * \sigma(\text{분산})$ 을 적용, 데이터를 제외 하였다. 마지막으로, 딥러닝 모델의 학습을 위한 데이터의 표준화를 적용을 위한 방법으로 최대-최소 표준화 방법(Min-Max Normalization)을 사용하였다. 최대-최소 표준화 방법의 경우, 소유한 데이터 셋의 최대치와, 최소치를 기준으로 데이터의 척도를 재조정하는 기법이다. 광전용적맥파형의 경우 앞서 언급한 바와 같이, 동적 간섭에 의해 2초의 분할 연속 파형 내 최대치와 최소치에 대한 이상치가 특이적으로 존재했으며, 최대한 데이터를 보존하며 이상치를 제거하기 위해 최소치의 임계값은 125, 최대치의 임계값은 1500을 적용하여 이 임계값 범위를 벗어나는 2초 분할 연속 파형은 데이터 셋에서 제외하였다. 심전도의 경우, 최소치의 임계값에는 $\mu(\text{평균}) - 1.96\sigma(\text{분산})$, 최대치의 임계값에는 $\mu(\text{평균}) + 1.96\sigma(\text{분산})$ 을 적용하여 이 임계값 범위를 벗어나는 2초 분할 연속 파형은 데이터 셋에서 제외하였다.

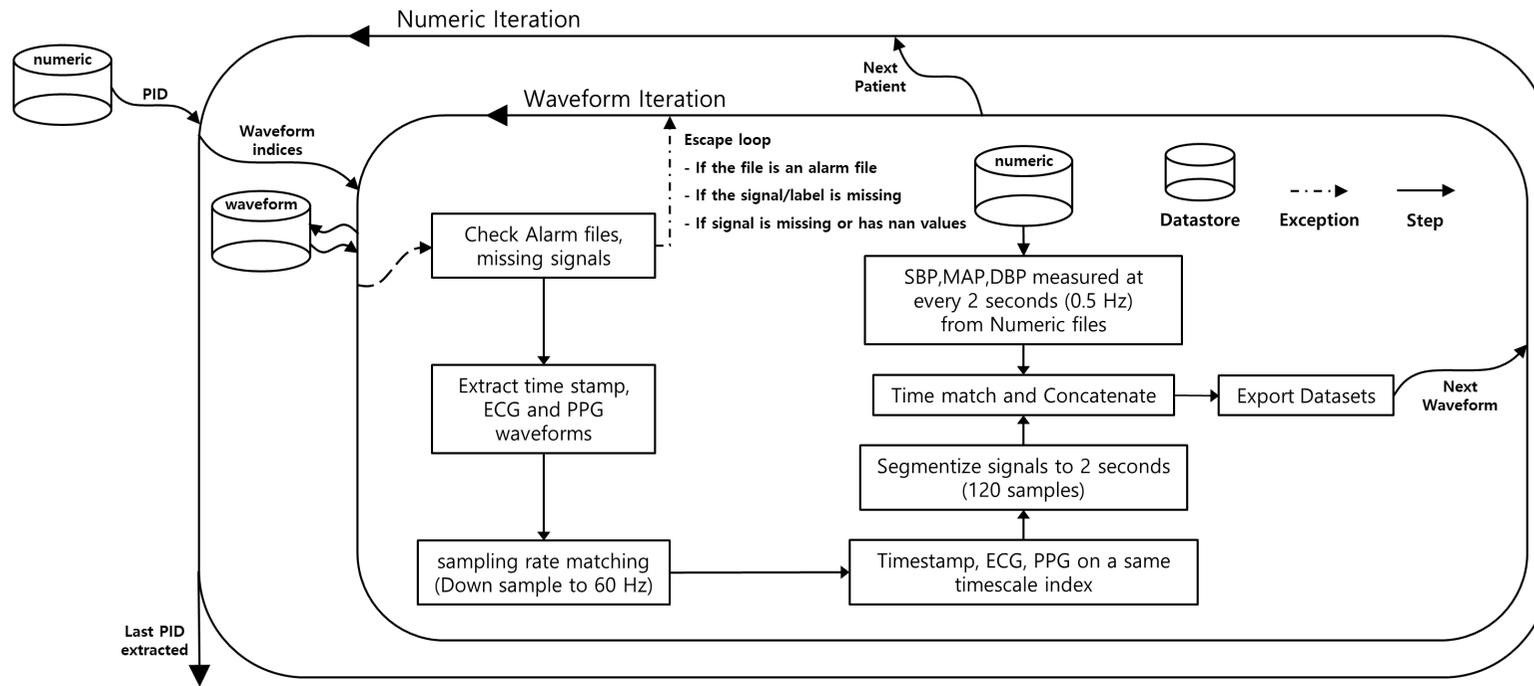


그림 11 데이터 추출 알고리즘 개요도

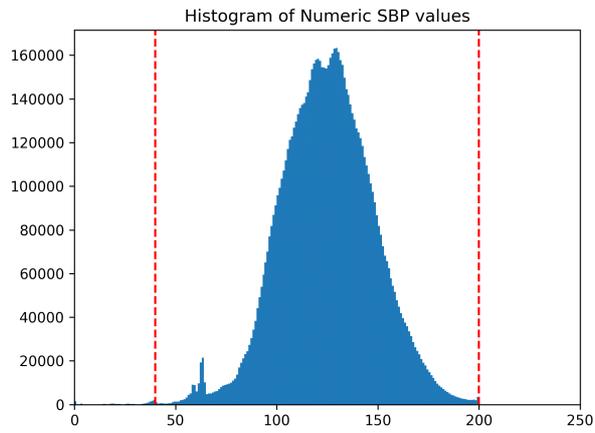


그림 12 수축기 동맥 혈압의 분포도와 제외 임계선

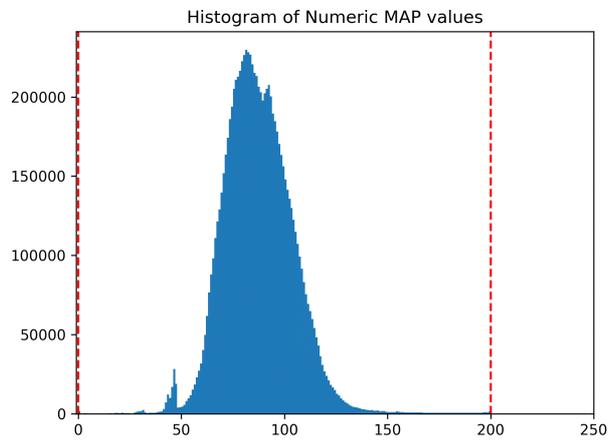


그림 13 평균 동맥압의 분포도와 제외 임계선

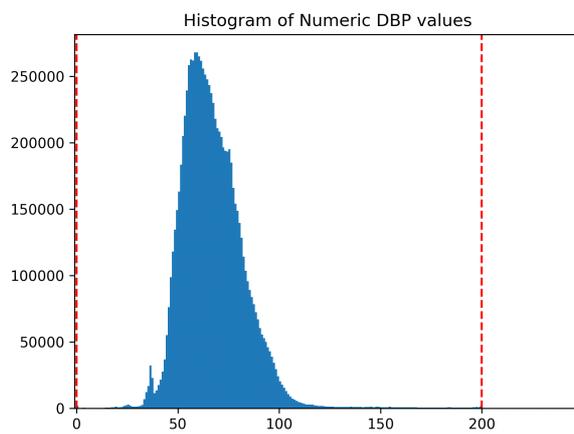


그림 14 확장기 동맥 혈압의 분포도와 제외 임계선

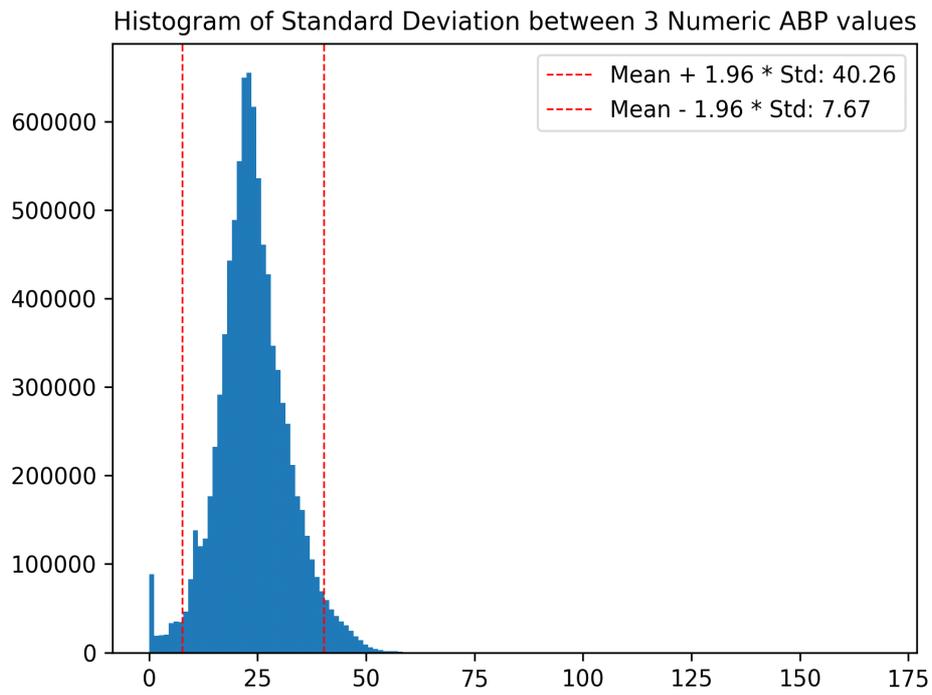


그림 15 수축기, 확장기, 평균 동맥압의 분산 분포도와 제외 임계선

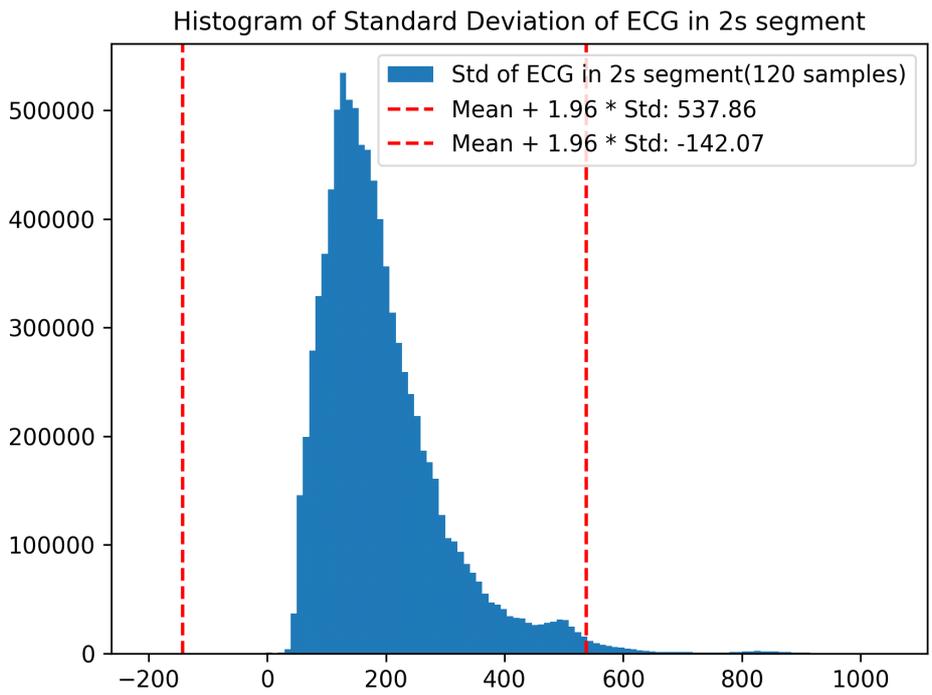


그림 16 2초 단위로 분할된 심전도 파형 내 분산 분포도와 제외 임계선

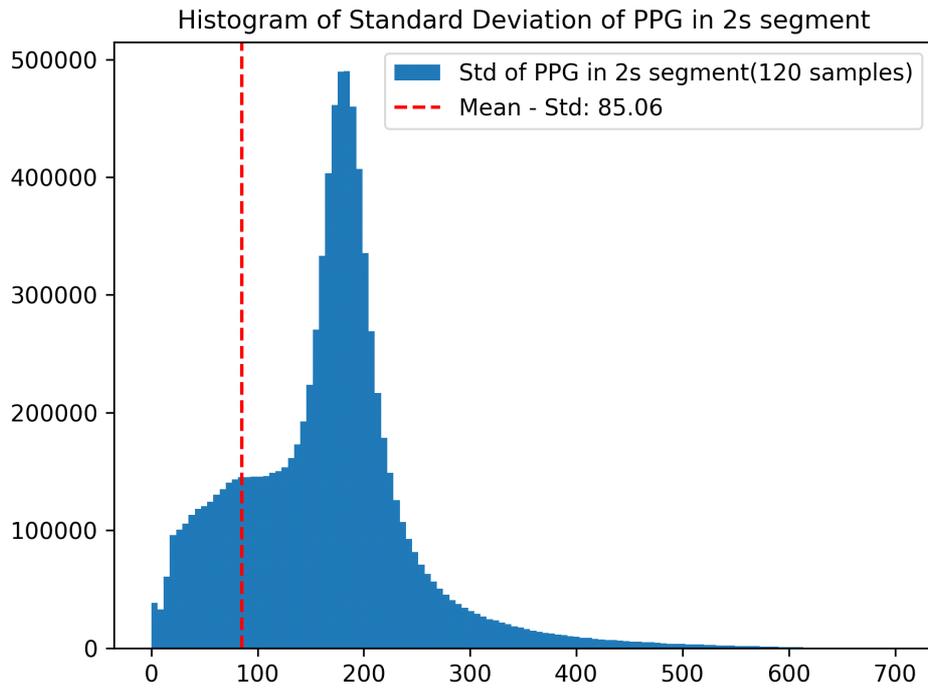


그림 17 2초 단위로 분할된 광전용적맥파형 내 분산 분포도와 제외 임계선

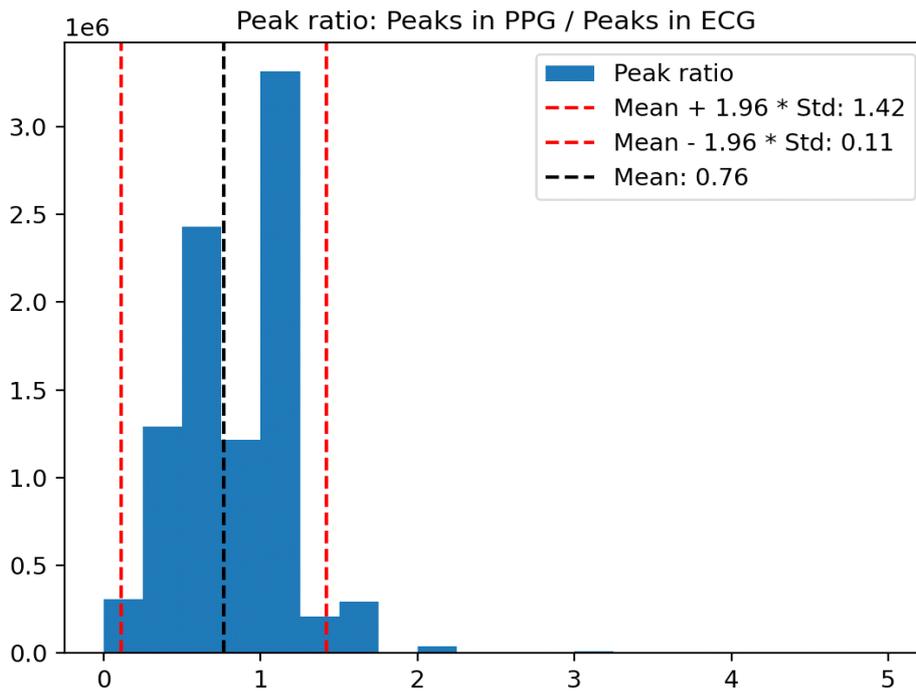


그림 18 탐지된 파고점의 파형별 개수 비율 분포도와 제외 임계선

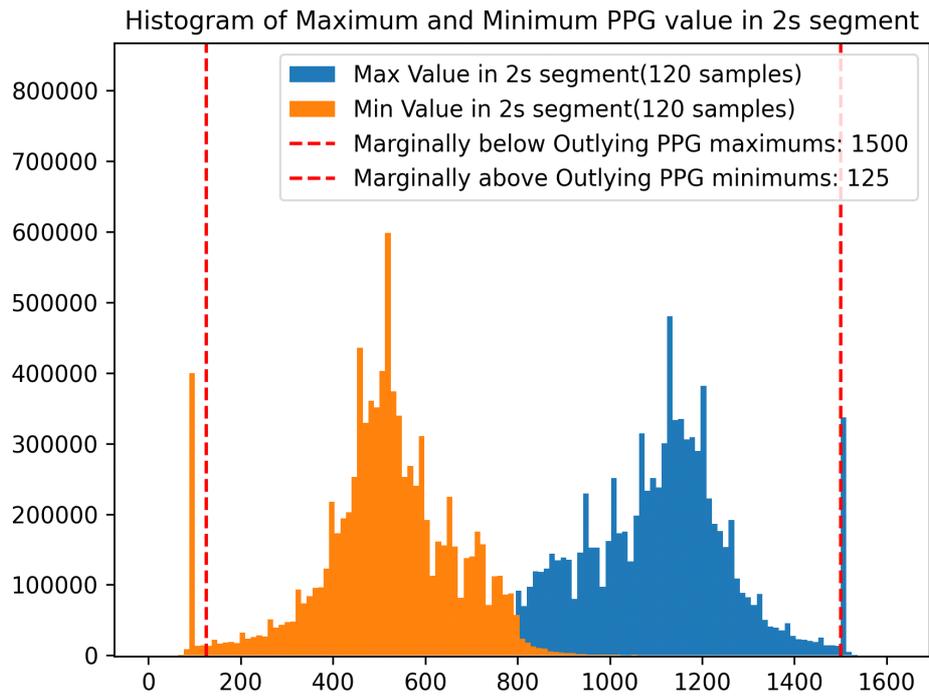


그림 19 2초 단위로 분할된 광전용적맥파형 내 최대치와 최소치 분포도와 제외 임계선

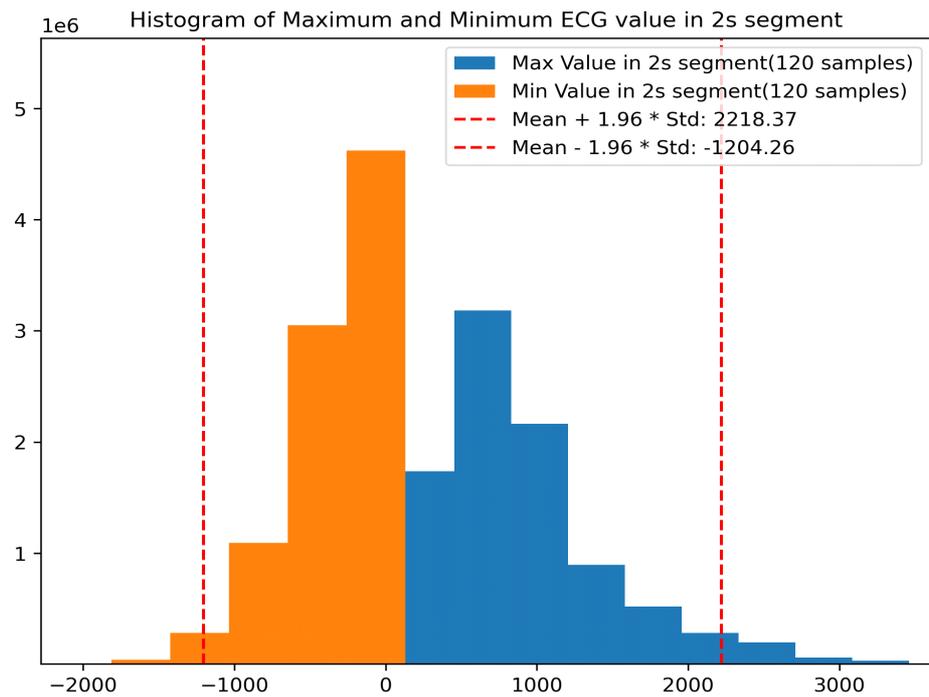


그림 20 2초 단위로 분할된 심전도 파형 내 최대치와 최소치 분포도와 제외 임계선

따라서, 98명으로부터 추출된 2초 길이의 심전도 광전용적맥파형과 3개의 수축기, 확장기, 평균 동맥혈압으로 이루어진 데이터 세그먼트(Segment: 조각)는 총 9,113,927 세그먼트로 이루어졌으며, 딥러닝 학습에서 제외될 데이터는 6가지 제외처리 기준에 의하여 4,312,905 조각이 제외되었다.

2. Time Distributed Auto Encoder 모델

2.1 모델의 개요 및 구조

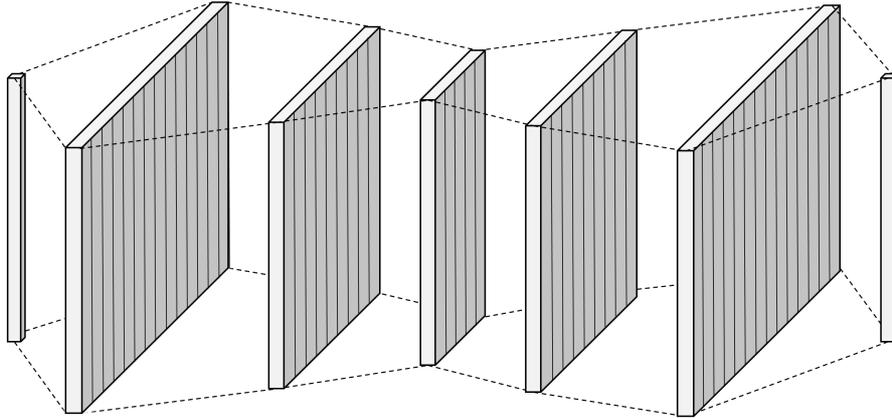


그림 21 본 연구에서 활용된 Time Distributed Auto Encoder의 구조

본 연구에서 활용된 오토인코더 모델은 딥러닝의 다양한 모델 중에서 비지도 학습 모델에 속하며, 많은 수의 샘플에서 데이터의 특징을 자동으로 학습하는 특징을 가지고 있다. 오토인코더의 주요한 특징으로는 Encoding Path와 Decoding Path로 이루어져 Encoding Path에서 입력 데이터를 압축하고 인코딩하여 특징을 추출, 원본데이터를 다른 Representation 공간으로 변환하고, Representation 공간에서 Decoding Path를 통해 변환된 데이터를 원래의 표현공간으로 복원하는 것이 특징이다. 입력과 출력 간 오류가 적을수록 성공적인 복원이 이루어졌음을 의미한다.

본 연구에서 활용한 오토인코더의 특징을 활용한 Time Distributed 오토인코더는, Time Distributed Convolution layer과 Dense layer 그리고 각 Layer의 활성화 함수로 Parametric ReLU를 사용하였으며 마지막 Layer에 Linear 활성화 함수를 사용하여 활용하여 입력의 형태는 유지한 채, Depth차원에서 Encoding Path와 Decoding Path의 원리를 적용한 오토인코더이다. 본 연구에서는 2초의 심전도와 광전용적맥파형에 이러한 오토인코더의 원리를 적용하여, 소수의 고품질로 라벨링된 데이터로 오토인코더를 학습시켜 ResNet 동맥혈압 추정용 학습 및 검증 데이터 셋에 데이터 클리닝을 적용해보고자 하였다.

3. Auto Encoder를 활용한 데이터 클리닝

3.1 파형 품질의 분류

간섭 혹은 노이즈의 성분이 포함된 저 품질의 파형과 정상적인 파형의 분류를 위해서, GUI(Graphical User Interface)를 설계하여 시각적으로 신호를 직접 확인 하여 분류를 진행하였다.



그림 22 파형 품질 분류를 위한 GUI

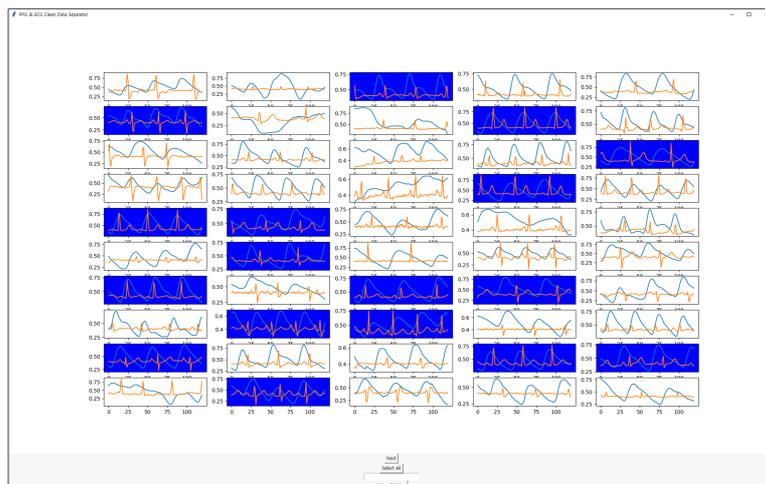


그림 23 GUI 상 선택된(파란 배경) 정상 파형의 신호

3.2 Auto Encoder 모델 용 데이터 셋

오토인코더용 데이터 셋은 제외 처리 작업 이후 남은 세그먼트 중, 무작위로 뽑은 2000개의 세그먼트에 대하여 분류를 진행하였다. 2000개의 세그먼트 중, 1250개는 오토인코더의 학습을 위한 데이터였으며, 나머지 750개는 학습된 오토인코더의 검증 및 정상적인 파형과 저 품질의 파형을 분리하기 위한 임계값을 정하기 위해 분류 되었다. 오토인코더의 학습용 1250개의 샘플 중 300개의 세그먼트는 정상적인 파형으로 분류되었으며, 950개의 세그먼트는 저 품질로 분류 되었다. 나머지 750개의 세그먼트에 대해서는 정상적인 파형이 100개, 저 품질의 파형이 650개로 분류되었다.

오토인코더의 학습용 데이터의 경우, 300개의 정상 파형 데이터는 모델의 학습에 활용 되었으며, 나머지 950개의 학습용 데이터는 분류 후 제외 되었다. 이후, 750개의 검증용 데이터는 정상 파형, 저품질 파형으로 분류 되어 100개의 정상 파형과 650개의 저 품질 파형으로 오토인코더의 손실 함수인 평균 제곱 오차 함수의 결과 값을 기준으로 임계값을 정하였다.

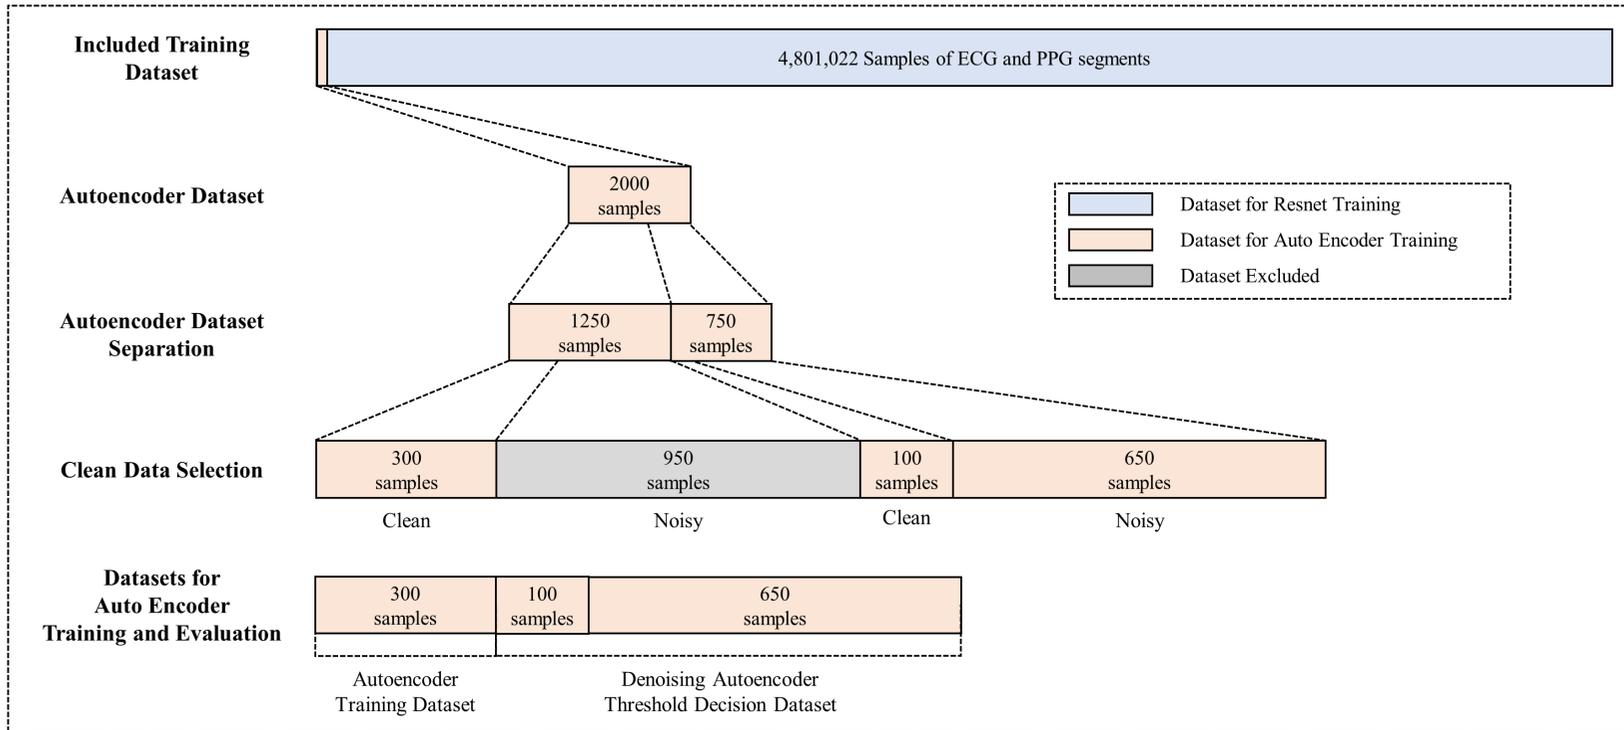


그림 38 그림 24 정상파형과 저 품질로 분류된 오토인코더의 학습/검증용 데이터 셋

3.3 Auto Encoder 모델 학습

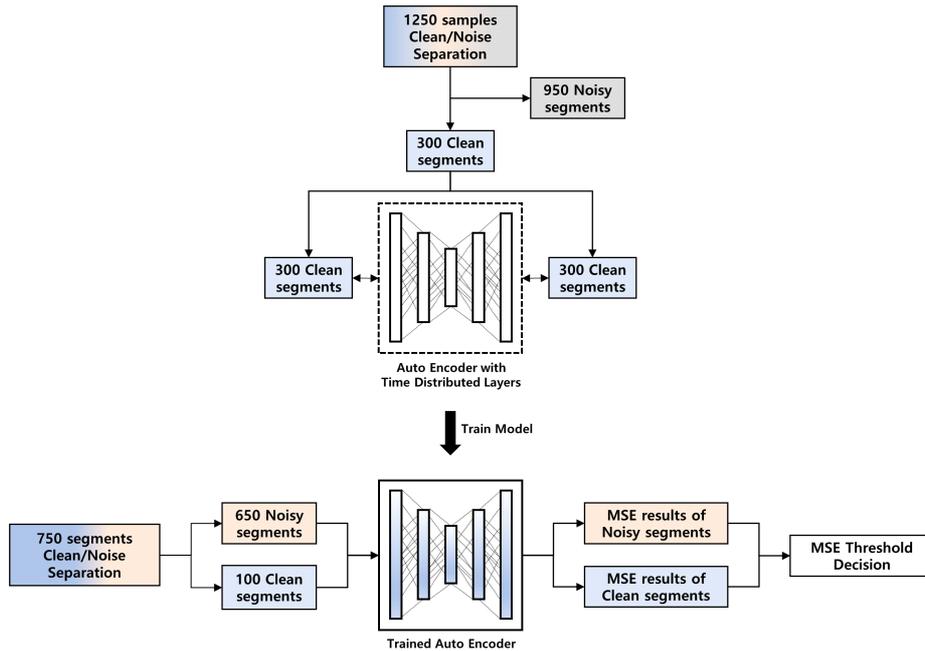


그림 25 오토인코더 모델의 학습 과정 개요도 (상단: 학습 과정, 하단: 검증 과정)

오토인코더의 학습용 데이터 셋 중, 정상파형으로 분류된 심전도, 광전용적맥파형은 2초(120,1)의 연속적인 세그먼트를 이어 붙인 2*2초(240,1)의 크기로 훈련되었다. 오토인코더에 입력하기 전, 심전도 파형의 경우 최소: -1205, 최대: 2215로 표준화 되었으며, 광전용적맥파형의 경우 최소:125, 최대: 1800로 표준화 되었다. 손실함수는 평균 제곱 오차를 사용하였으며, 최적화 함수는 Adam최적화 함수를 사용하였다. Tensorflow의 내장 Callback (모델 학습 시 파라미터를 유동적으로 변경해주는 기능) 중, Reduce Learning Rate on Plateau 와 Early Stopping을 사용하여, 모델 학습률을 0.0001에서 성능이 개선이 없을 때마다 학습률을 0.5배로 줄였으며, 20 에폭(Epoch: 모델 학습 반복회수)회 이상 모델의 예측 성능의 개선이 없을 시 성능이 제일 좋은(평균 제곱 오차가 제일 적음) 모델이 저장 되도록 하였다. 모델의 학습 과정 내에서 Validation set은 입력의 20%의 비율로 무작위 학습 되도록 하였으며, 배치사이즈(병렬적으로 동시에 학습 및 연산이 진행 가능한 세그먼트의 묶음 크기)는 128로 설정되었다.

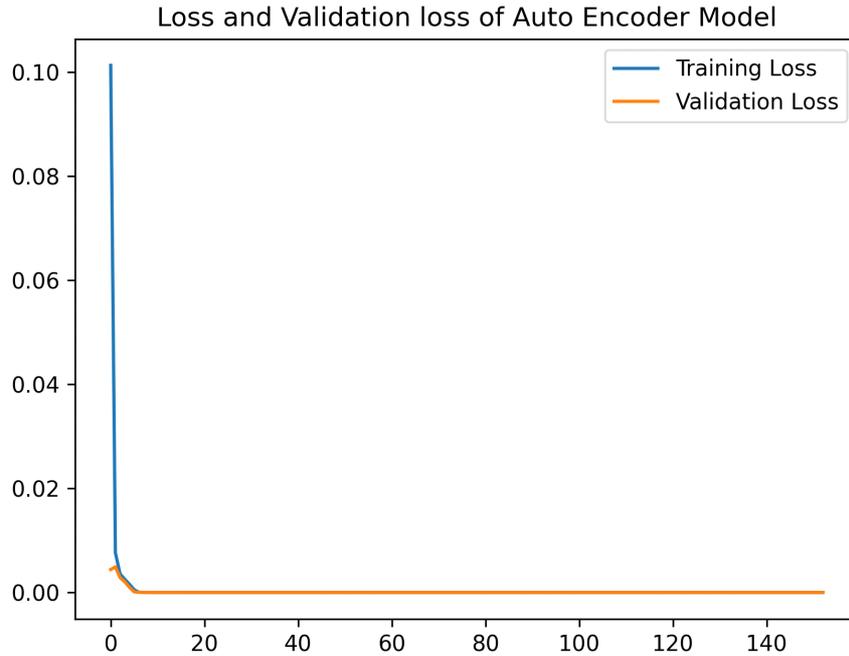


그림 26 오토인코더 모델의 학습, 검증 손실 그래프

오토인코더 모델의 학습 손실의 값은 매우 작으며, 과적합(Overfitting: 모델이 데이터에 과도하게 학습 되는 현상)을 손실 함수의 결과 값으로만 판단하는 것은 어렵기 때문에, 최소의 검증 손실 값을 가진 성능을 기준으로 대표 오토인코더 모델을 선정하였다.

3.4 Auto Encoder 파형 품질 임계값 결정

오토인코더를 통한 데이터 클리닝을 진행하기 위해 오토인코더의 정상 파형과 저 품질 파형의 평균 제곱 오차 값의 분포를 통해 정상파형의 제곱 오차 값 임계값을 정하였다. 반복적인 실험을 통해, 정상파형의 MSE 최대 임계값을 $4.75e-7$ 로 정하여 ResNet 학습용 데이터 클리닝을 진행하였다.

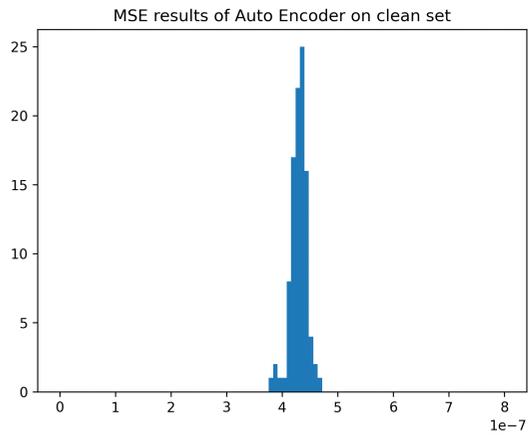


그림 27 정상 파형의 MSE 분포도

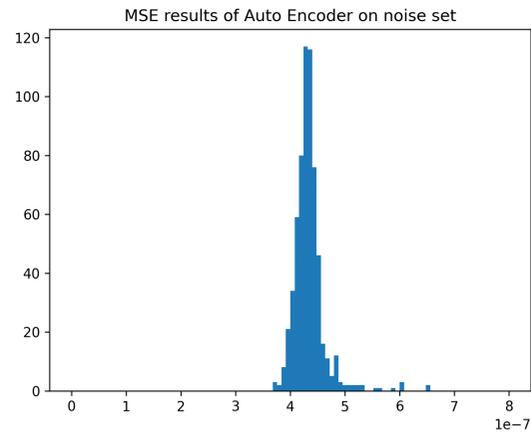


그림 28 저품질 파형의 MSE 분포도

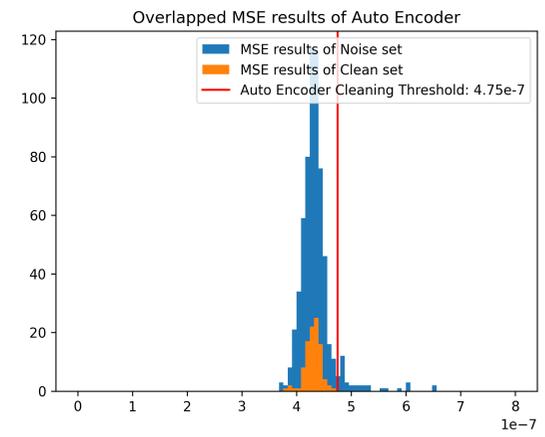


그림 29 중첩된 분포도와 임계값

3.5 ResNet 학습 및 검증 용 데이터 클리닝 진행

ResNet 학습용 데이터 셋은 최초의 추출된 데이터로부터 제외처리 기준에 의해 4,312,905개의 세그먼트가 제외된 후, 남은 4,801,022의 세그먼트 중 2,000개의 샘플은 오토인코더의 학습과 임계값 결정을 위해 사용되었다. 이후 남은 데이터 셋에 대하여 오토인코더를 통해 평균 제곱 오차가 계산 되었으며, 임계값인 $4.75e-7$ 을 초과하는 세그먼트는 제외하였다. 남은 데이터 셋의 경우 4,799,022 개의 세그먼트 중 오토인코더 MSE 임계값을 넘는 365,804개의 세그먼트가 데이터 셋에서 제외 되어 4,433,218개의 세그먼트가 ResNet 모델 학습용 데이터로 최종 결정 되었다. ResNet 모델 검증용 데이터 셋은 총 2,229,689개의 세그먼트가 추출 되었으며, 제외 처리 기준에 의해 679,160개의 세그먼트가 제외 되었다. 나머지 1,550,529개의 세그먼트 중 오토인코더 MSE 결과 값 $4.75e-7$ 임계값을 넘는 74,183개의 세그먼트가 추가로 제외되어 최종 1,476,346개의 데이터에 대하여 모델 검증을 진행하였다. 이어서 진행될 보정 방법을 통한 모델 검증을 위해서는, 시계열상 연속적인 데이터 셋을 확보하는 것이 필수적이었으며, 각 세그먼트 별 연속적인 샘플을 분류 후, 제외처리 및 클리닝 이후 연속적으로 확보된 6,867개의 연속적 세그먼트 데이터 셋 중, 연속적인 세그먼트가 30개(약 60초) 미만인 레코드 1,536개를 제외하여 5,331개에 해당하는 1,345,092 세그먼트에 대하여 모델 예측의 보정에 대한 검증을 진행하였다.

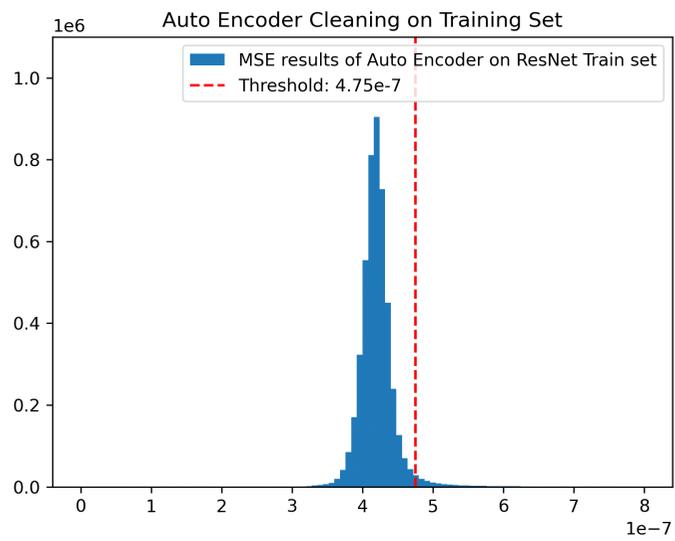


그림 30 ResNet 학습용 데이터 셋 MSE 분포도

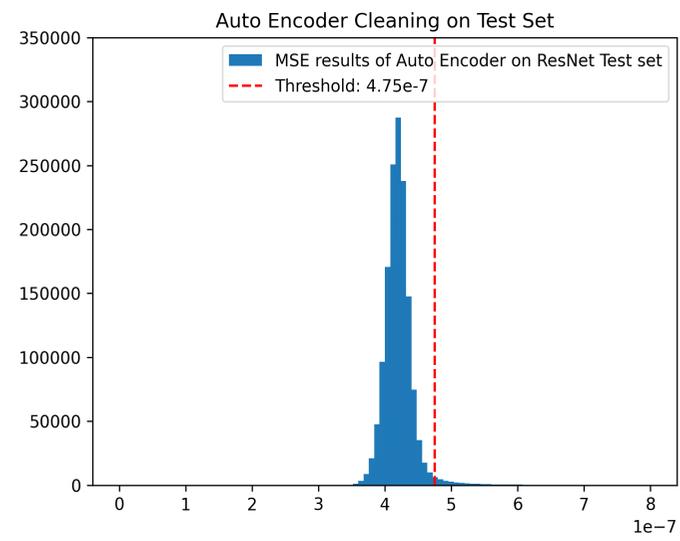


그림 31 ResNet 검증용 데이터 셋 MSE 분포도

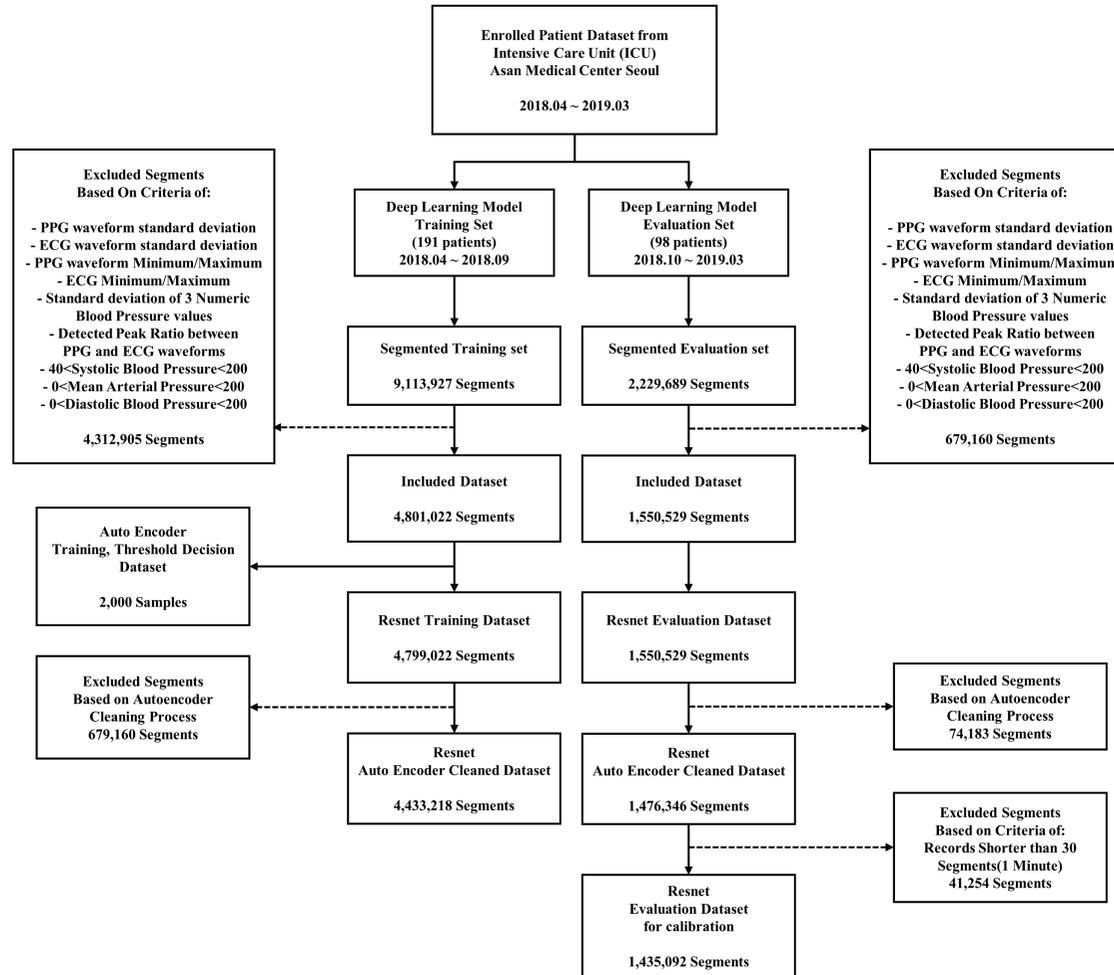


그림 32 데이터 셋에 대한 제외 처리 및 클리닝 과정

4. ResNet 딥러닝 모델

4.1 ResNet 모델의 개요 및 구조

LeCun et al.에 의해 처음 제안된 CNN 구조의 딥러닝 신경망이 개발되었으며, 인공신경망에 필터링 기술이 적용된 이러한 방법은 이미지 및 영상을 효과적으로 분석하는데 도움을 주었다. CNN의 등장 초기에는 수기로 작성된 숫자의 이미지로부터 숫자를 인식하기 위해 많은 연구들이 이루어졌다. 이후 Li et al.에 의해 방대한 양의 이미지로부터 학습된 모델로 좋은 성능을 보이는 ImageNet[28]이 제시되면서 점차 컨볼루션, 레이어, 구조를 변경한 다양한 딥러닝 모델이 등장했으며 그 중 다양한 딥러닝 성능 비교 대회에서 뛰어난 성능을 보이는 더 깊은 신경망 구조, 경량화, ReLU함수의 사용, Inception 모듈의 사용을 장점으로 한 다양한 딥러닝 모델이 대회 상위권을 차지하였다. 그러나, 다양한 연구들에서 신경망의 깊이를 깊게 만들수록 성능이 증가하다 과도하게 깊어질수록 성능이 오히려 줄어드는 현상이 보고되며, 이러한 성능 저하의 원인이 'Vanishing Gradient Problem'에 있다는 것을 발견하였다. Vanishing Gradient란, 모델의 입력과 출력 사이 순전파와 역전파를 진행하며 모델의 가중치와 편향을 조절하는 과정에서, 모델의 깊이가 너무 깊어 순전파와 역전파의 영향력이 적어지는 현상을 의미한다.[51]

ResNet모델은 이러한 Vanishing Gradient 문제를 해결하기 위해 He et al.이 Residual Block을 활용하여 해결한 딥러닝 모델이다.

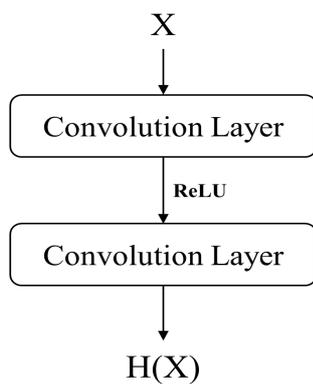


그림 33 Plain Layers의 구조

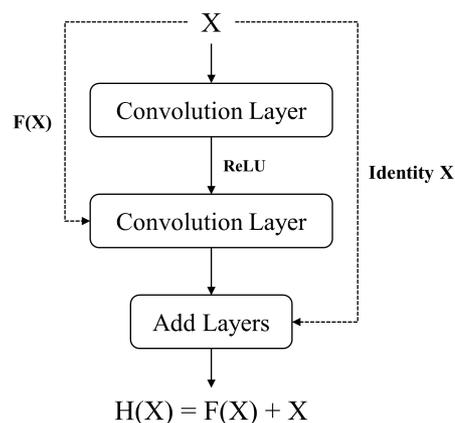


그림 34 Residual Block의 구조

Residual Block의 Skip Connection의 등장으로 출력 레이어에 이전 레이어의 정보를 연결함으로써 기존에 학습한 정보는 보존하며 새로운 정보를 학습할 수 있게 되었으며, 이러한 기능으로 인해 ResNet의 레이어는 152 Layer이라는 매우 깊은 신경망임에도 불구하고 Gradient Vanishing 없이 학습을 진행할 수 있게 되었다. ResNet 모델은 다양한 대회에서 1위를 차지하며, 이후 ResNet의 아이디어를 활용한 모델들이 파생되었다.

4.2 ResNet 모델 학습

본 연구에서는 2차원의 이미지를 분석하기 위한 ResNet모델의 핵심 개념을 적용하여 1차원 입출력과 1차원 Convolution block 및 Skip Connection을 적용하여 모델을 설계하였다. Convolution Block 사이의 활성화 함수는 Dying ReLU현상을 방지하기 위하여 LeakyReLU 활성화 함수를 사용하였으며, 빠른 학습과 공변량 변화 문제점을 해결하기 위해 BatchNormalization을 적용하였다. 본 연구는 1차원 신호를 입력으로 한 회귀 목적 딥러닝 모델이기에, 입력 단계, Convolution block에 이어 Flatten Layer와 Dense Layer를 통해 단일 값을 예측하도록 설계하였다.

모델의 학습을 위한 입력 데이터는 심전도 파형 2초(120 샘플)와 광전용적맥파형 2초(120 샘플)를 결합한 형태의 (240,1) 크기의 세그먼트를 입력으로 받았으며 해당 2초 단위의 연속 파형에 해당하는 동맥혈압의 수치 값을 라벨로 설정하여 모델 학습을 진행하였다. 각 연속 파형 신호 조각의 데이터 세그먼트는 심전도의 경우 최소: -1204.26, 최대: 2218.37로 설정하여 정규화를 진행하였으며, 광전용적맥파형의 경우 최소: 125, 최대: 1500로 설정하여 데이터 정규화를 진행하였다. 손실함수의 경우, 평균 제곱 오차로 손실이 계산 되었다. 최적화 함수는 Adam 최적화 함수를 사용하였으며, 초기 학습률은 0.0001로 시작하여 Reduce Learning Rate on Plateau 콜백 기능을 사용하여 학습률을 감소시켰다. 배치사이즈를 256으로 설정하여 동맥혈압 별 ResNet모델을 각각 학습 시켰으며, 120 Epoch 동안 가장 낮은 검증손실을 가진 모델을 선정하였다.

5. 동맥혈압 유형 별 모델 적용

5.1 동맥혈압 예측용 모델 학습

본 연구는 설계된 ResNet 모델을 기반으로 입력으로 수축기, 확장기, 평균 동맥 혈압을 예측하는 모델을 각각 학습시켰다. 다수의 연구 결과에 따르면, 수축기 혈압의 동적인 특성에 의해 수축기 혈압 예측 성능이 확장기 및 평균 동맥 혈압 예측 성능에 비해 낮은 경향을 보였다. 따라서 본 연구에서는 수축기를 기준으로 ResNet 모델에 대하여 하이퍼 파라미터 튜닝 (Hyper Parameter Tuning: 모델에 직접적으로 영향을 주는 딥러닝 모델의 파라미터를 성능이 개선되는 방향으로 조정하는 행위)을 진행했다. 이후, 수축기 동맥혈압 예측 성능이 가장 좋은 모델을 선정하여, 확장기와 평균 동맥 혈압 예측에 동일한 모델을 적용하였다.

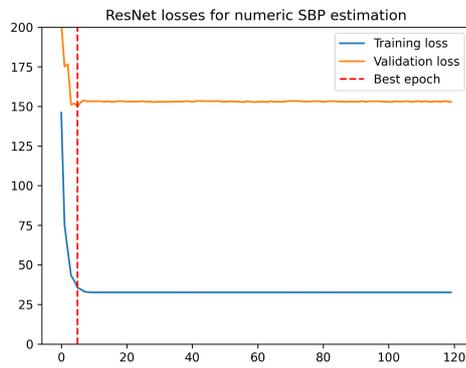


그림 35 SBP 예측 모델 손실 곡선 [MSE]

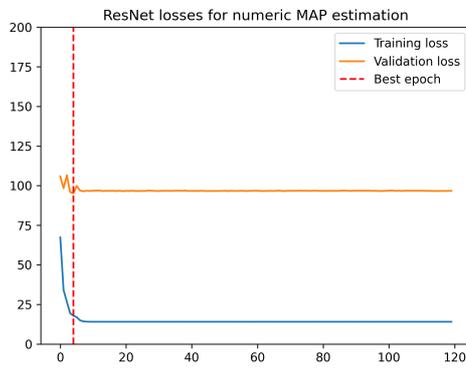


그림 36 MAP 예측 모델 손실 곡선 [MSE]

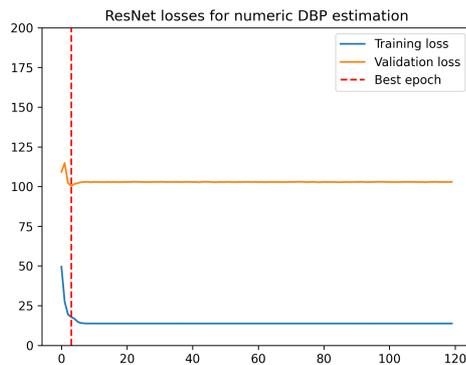


그림 37 DBP 예측 모델 손실 곡선 [MSE]

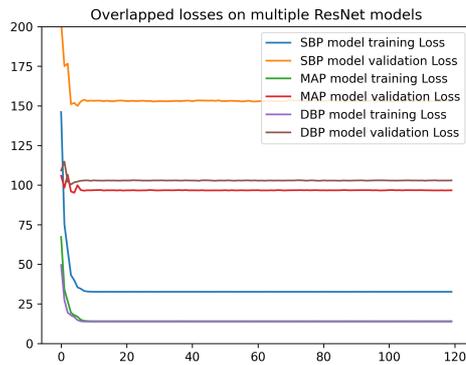


그림 38 중첩된 모델별 손실 곡선 [MSE]

6. 보정이 적용된 동맥 혈압 예측 모델

6.1 보정의 적용 및 방법

본 연구에서는 ResNet의 동맥혈압 예측 결과를 추가적으로 개선하기 위하여 보정을 적용하였다. 본 연구에서는 ResNet 모델의 앞서 예측된 동맥혈압 값과 실제 동맥 혈압 간 선형회귀 방법을 통해 선형 회귀계수를 구하여 새로이 예측된 값에 보정을 적용하고 보정된 값을 구하였다.

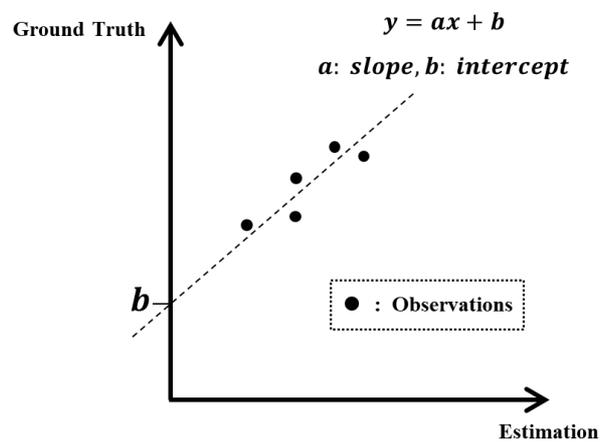


그림 39 예측 및 실제 혈압 수치에 대한 선형 회귀

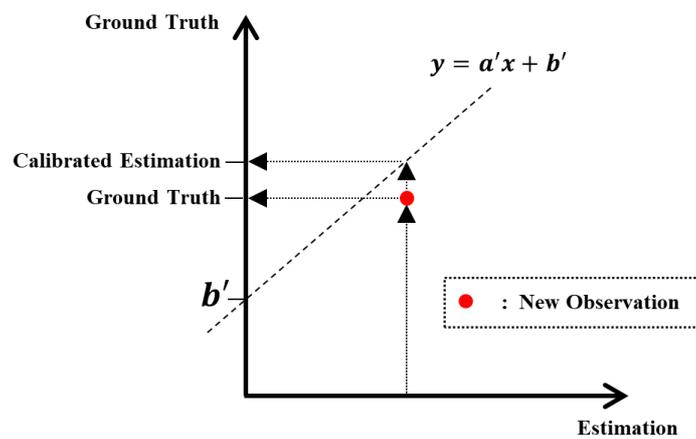


그림 40 새로운 예측 값의 선형 회귀를 통한 보정 방법

6.2 보정을 위한 선형 회귀 방법의 참고 혈압 값 개수 결정

모델의 예측 동맥 혈압 값과 실제 동맥 혈압 간 선형 회귀 계수를 계산하기 위해 사용될 변수의 개수는 무작위로 선별된 10개의 레코드에 대하여 평균절대오차 값을 통해 정하였으며, 본 연구에서는 6개의 선 측정된 혈압 값을 참고 값으로 정하였다.

Preceding sample window size decision	Mean Absolute Error
2 samples	12.05
3 samples	0.94
4 samples	0.81
5 samples	0.80
6 samples	0.79
7 samples	0.80
8 samples	0.81
9 samples	0.82

표 5 보정을 위한 참고 동맥 혈압 값 개수 결정

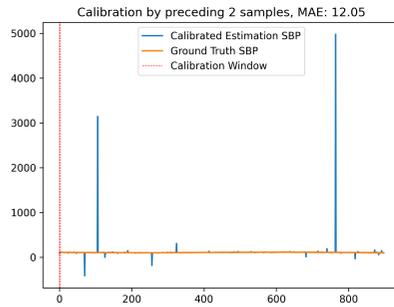


그림 41 2개 샘플 보정 윈도우

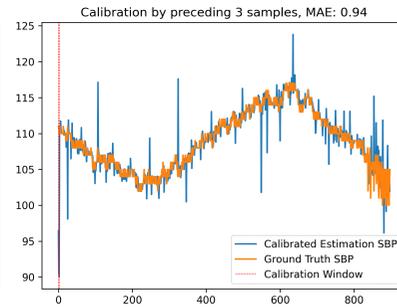


그림 42 3개 샘플 보정 윈도우

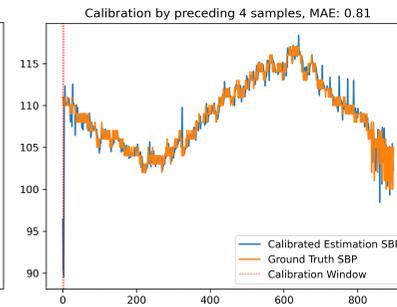


그림 43 4개 샘플 보정 윈도우

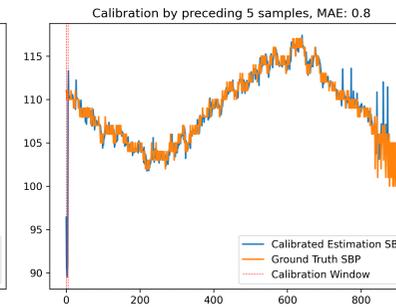


그림 44 5개 샘플 보정 윈도우

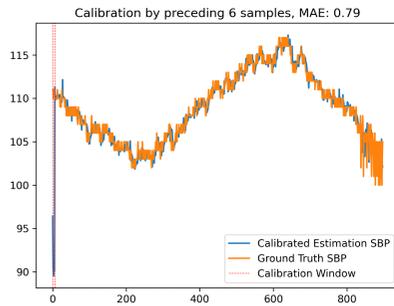


그림 45 6개 샘플 보정 윈도우

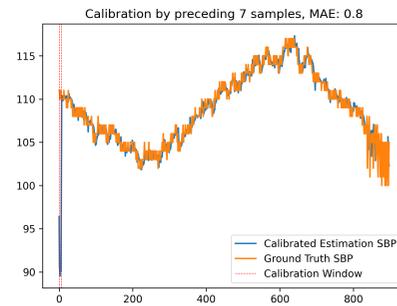


그림 46 7개 샘플 보정 윈도우

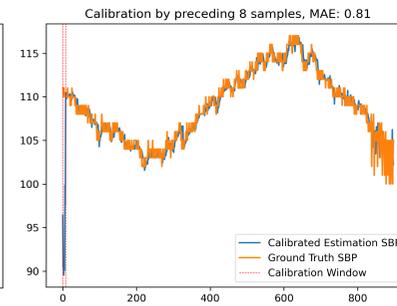


그림 47 8개 샘플 보정 윈도우

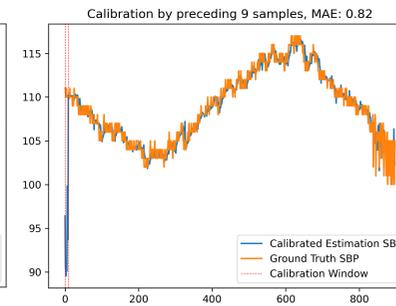


그림 48 9개 샘플 보정 윈도우

7. 혈압 예측 결과 평가 방법

7.1 회귀 목적의 동맥혈압 예측 모델 평가 지표

본 연구에서는 혈압 예측을 위한 ResNet 모델을 평가하기 위하여 상관 계수 R, R Squared, MAE, RMSE, MAPE를 도입하였다. 상관계수로 알려진 R 및 R squared의 값은 두 변수 집단 간 선형적인 관계를 나타내는 지표이며, 예측 값과 실제 값의 선형적인 관계를 나타내는 지표이다. 평균 절대 오차, 평균 제곱근 오차, 평균 백분율 오차는 두 변수 집단 간 발생한 전체적인 오차를 분석할 수 있는 지표이며, 회귀형 딥러닝 모델의 학습을 위한 손실 함수 값으로도 사용되어진다.

7.2 혈압 측정 장치를 위한 국제 표준에 따른 예측 성능 평가

본 연구에서 개발된 딥러닝 방법을 통한 혈압 예측 장치의 성능을 평가하기 위한 방법으로 혈압 측정 장치의 성능을 비교하기 위해 고안된 BHS(British Hypertension Society) 표준 혈압 측정 장치 검증 프로토콜과 AAMI(Association for the Advancement of Medical Instrumentation) 표준 혈압 측정 장치 검증 프로토콜을 통하여 ResNet 모델의 예측력을 평가하였다.[52]

BHS 표준의 경우, 실제 동맥 혈압 값과 예측 동맥 혈압 값 간 절대 오차를 계산하여, 실제 혈압 값으로부터 특정 오차 구간 내에 예측된 결과 값을 성공적인 예측으로 규정하고, 각 오차 구간 별 전체 예측 수 대비 성공적인 예측의 비율을 구하여 등급을 부여하며, 모든 구간에 해당하여 기준을 통과해야 등급이 부여된다.[53]

BHS standards	Grade A	Grade B	Grade C	Grade D
≤5 mmHg	60%	50%	40%	The presence of any cumulative blood pressure percentage values falling below Grade C threshold signifies as Grade D
≤10 mmHg	85%	75%	65%	
≤15 mmHg	95%	90%	85%	

표 6 British Hypertension Society
혈압 측정 장치 등급 기준

AAMI 표준의 경우, 두 혈압 측정기기간 허용 가능한 오차의 범위를 평가하기 위하여 만들어진 프로토콜이며, 오차의 평균값과 표준 편차의 계산을 통해 통과/비통과가 결정된다. AAMI 표준 프로토콜에서 명시한 바에 따르면 오차의 평균은 5[mmHg] 미만, 표준 편차는 8mmHg 미만이어야 하며 피험자의 수는 최소 85명을 필요로 한다.

AAMI standards	Criteria
Mean of Error	Mean Error \leq 5
Standard Deviation	Standard Deviation of Error \leq 8
Subjects	Number of Subjects \geq 85

표 7 Association for the Advancement of Medical Instrumentation 혈압 측정 장치 표준

7.3 Correlation 분석법 및 Bland-Altman 분석법

Correlation 분석법은 두 변수 집단 간 상관성을 설명하기 위하여 상관 계수 R, R squared 와 함께 Correlation plot을 통해 상관성을 시각적으로 표현한다. Bland-Altman 분석 방법은 두 측정 값에 대하여 실제 값과 예측 값 간의 오차의 분포를 시각적으로 확인할 수 있는 방법이며, 표준 편차에 1.96을 곱한 값을 양의 방향과 음의 방향으로 수평선을 표시하여 95%의 신뢰 구간 내 오차의 분포를 시각적으로 확인할 수 있는 방법이다.[54]

7.4 예측 오차 분포 분석

실제 동맥 혈압 값과 ResNet 모델을 통해 계산된 절대 오차 값의 분포를 시각적으로 표현하기 위하여 두 변수 간 절대 오차를 계산하여 히스토그램으로 표현하였다. BHS 프로토콜에 사용되는 오차구간인 5mmHg, 10mmHg, 15mmHg를 수직선으로 표시하여 각 구간에 해당하는 오차의 분포를 시각적으로 확인할 수 있다.

시험 및 결과

1. 혈압 예측 모델 성능 평가

1.1 동맥 혈압 예측 모델의 평가 지표에 따른 평가 결과

Model Performance	SBP	MAP	DBP
R	0.945	0.949	0.933
R^2	0.893	0.9	0.87
MAE	4.64	3.18	2.96
RMSE	6.8	4.57	4.33
MAPE	3.71	3.64	4.44

표 8 모델 성능 평가 지표

1.2 국제 표준에 따른 예측 성능 평가

동맥혈압 예측 ResNet 모델에 대하여 BHS 표준 프로토콜을 적용한 결과, 수축기, 확장기, 평균 동맥 혈압 예측 모델 모두 A등급 기준을 통과하였다. AAMI 표준 프로토콜에 대하여 세 가지 예측 모델 모두 허용 오차 기준을 통과 하였으며, 피험자의 수에 대한 기준 또한 통과하였다.

BHS standards (Before Calibration)	SBP	MAP	DBP
≤5 mmHg	67.72%	81.33%	83.46%
≤10 mmHg	89.77%	96.36%	96.89%
≤15 mmHg	95.89%	98.84%	99.11%

표 9 BHS 표준에 따른 모델의 혈압 예측 성능 평가

AAMI standards (Before Calibration)	SBP	MAP	DBP
Mean of Error [mmHg]	0.284	0.694	0.026
Standard Deviation of Error [mmHg]	6.805	4.52	4.323
Subjects	93		

표 10 AAMI 표준에 따른 모델의 혈압 예측 성능 평가

1.3 Correlation 분석 결과

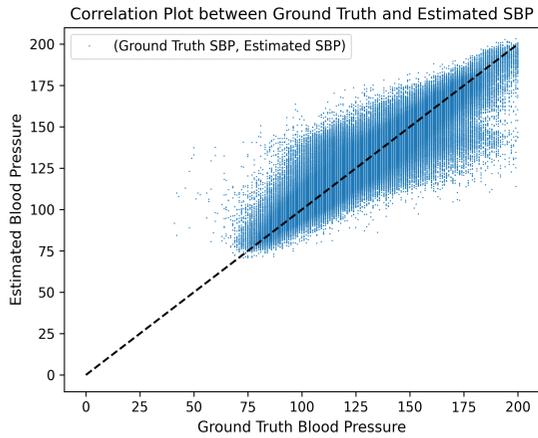


그림 49 SBP에 대한 Correlation Plot
(R value: 0.945)

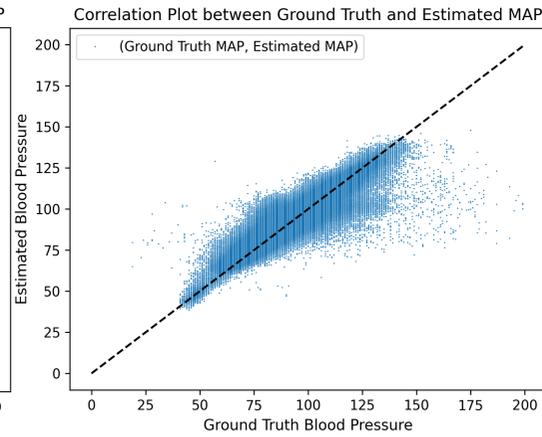


그림 50 MAP에 대한 Correlation Plot
(R value:0.949)

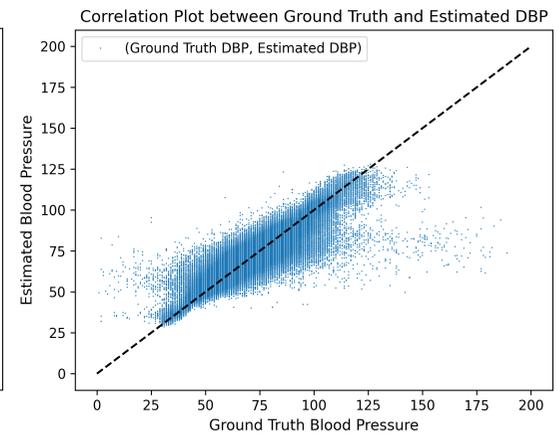


그림 51 DBP에 대한 Correlation Plot
(R Value: 0.933)

1.4 Bland-Altman 분석 결과

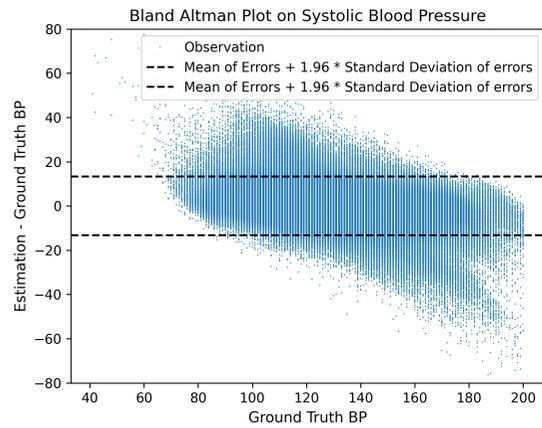


그림 52 SBP에 대한 Bland-Altman plot

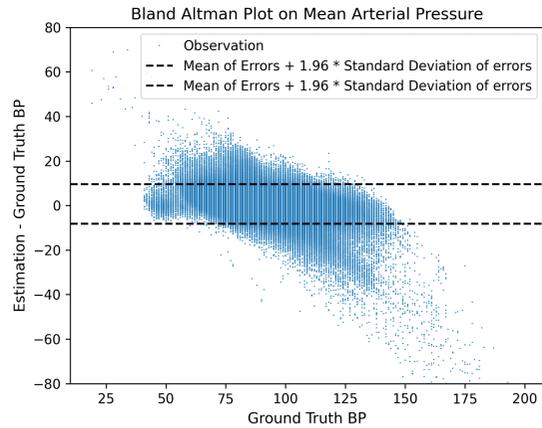


그림 53 MAP에 대한 Bland-Altman plot

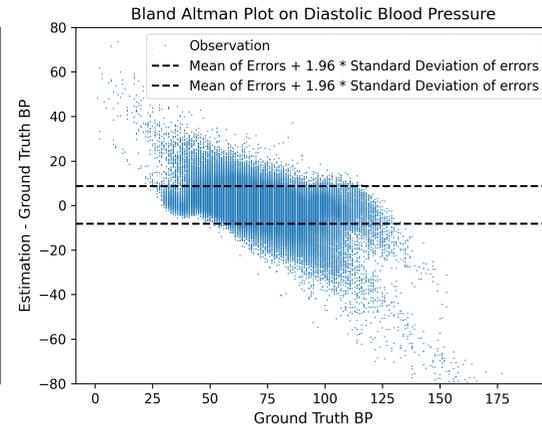


그림 54 DBP에 대한 Bland-Altman plot

1.5 예측 오차 분포 분석 결과

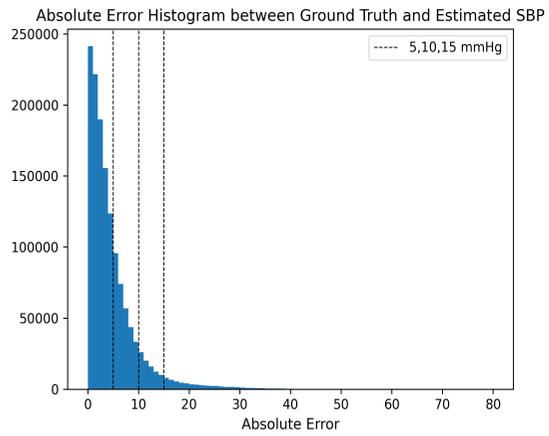


그림 55 SBP에 대한 혈압 예측 오차 분포

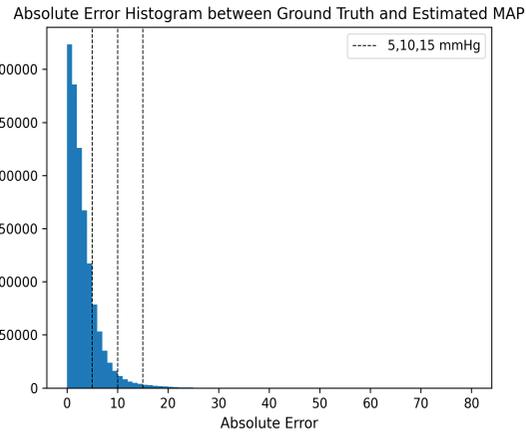


그림 56 MAP에 대한 혈압 예측 오차 분포

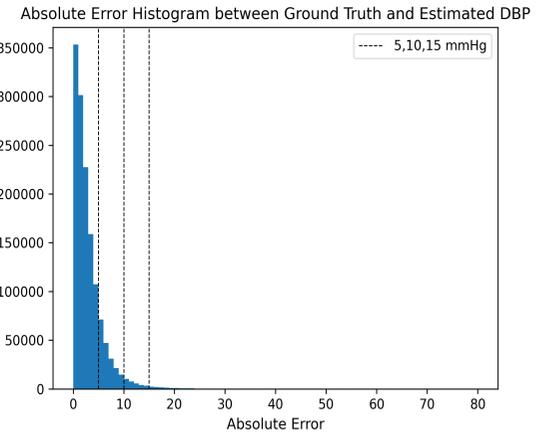


그림 57 DBP에 대한 혈압 예측 오차 분포

2. 보정된 예측 결과의 성능 평가 결과

연속적으로 확보된 93명 환자의 5331개의 레코드에 대하여 보정을 적용한 결과, 모든 성능 평가 결과가 개선되는 양상을 보였다.

2.1 동맥 혈압 예측 모델의 평가 지표에 따른 평가 결과

Model Performance (After Calibration)	SBP	MAP	DBP
R	0.98	0.983	0.968
R^2	0.961	0.966	0.936
MAE	2.54	1.52	1.71
RMSE	4.09	2.62	3.01
MAPE	2.04	1.72	2.57

표 11 딥러닝 모델 성능 평가 지표 (보정 후)

2.2 국제 표준에 따른 혈압 예측 성능 평가 결과

BHS standards (After Calibration)	SBP	MAP	DBP
≤ 5 mmHg	87.37%	95.80%	94.49%
≤ 10 mmHg	97.16%	99.27%	98.90%
≤ 15 mmHg	98.99%	99.73%	99.58%

표 12 BHS 표준에 따른 모델의 혈압 예측 성능 평가 (보정 후)

AAMI standards (After Calibration)	SBP	MAP	DBP
Mean of Error [mmHg]	0.004	0.003	0.003
Standard Deviation of Error [mmHg]	4.36	2.78	3.08
Subjects	93		

표 13 AAMI 표준에 따른 모델의 혈압 예측 성능 평가 (보정 후)

2.3 Correlation 분석 결과

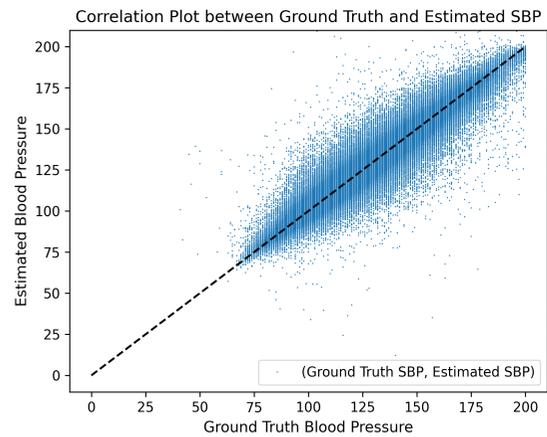


그림 58 SBP에 대한 Correlation Plot
(보정 후, R value: 0.980)

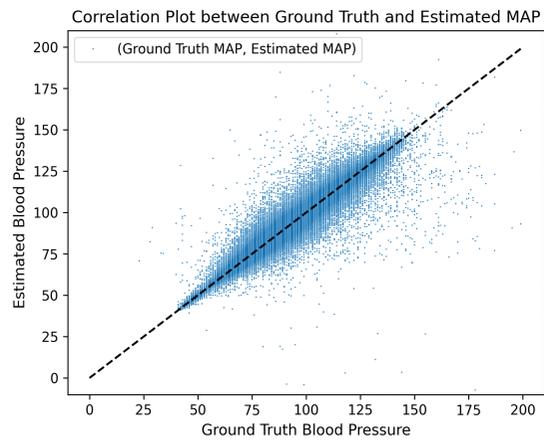


그림 59 MAP에 대한 Correlation Plot
(보정 후, R value: 0.983)

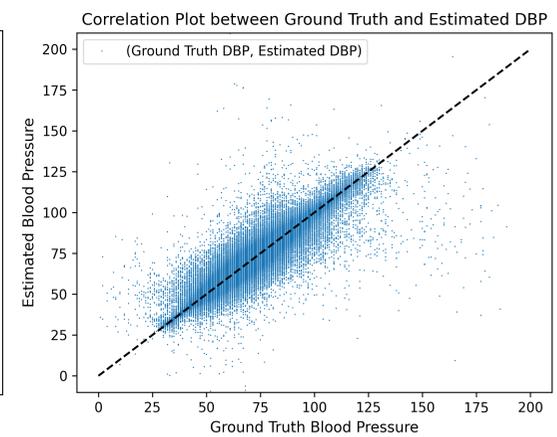


그림 60 DBP에 대한 Correlation Plot
(보정 후, R value: 0.968)

2.4 Bland-Altman 분석 결과

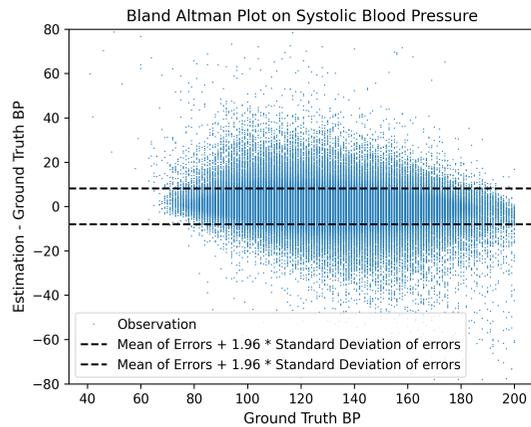


그림 61 SBP에 대한 Bland-Altman plot
(보정 후)

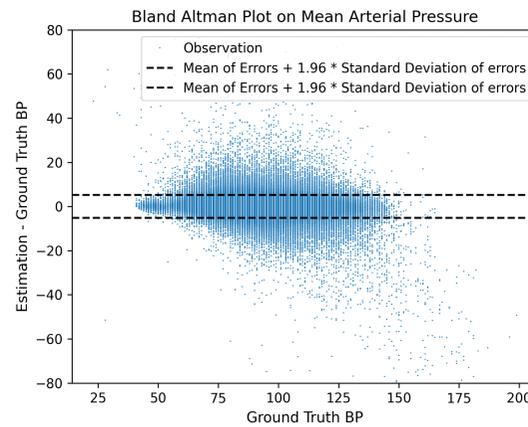


그림 62 MAP에 대한 Bland-Altman plot
(보정 후)

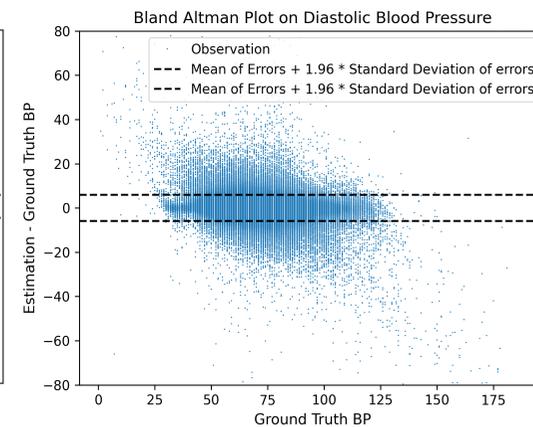


그림 63 DBP에 대한 Bland-Altman plot
(보정 후)

2.5 예측 오차 분포 분석 결과

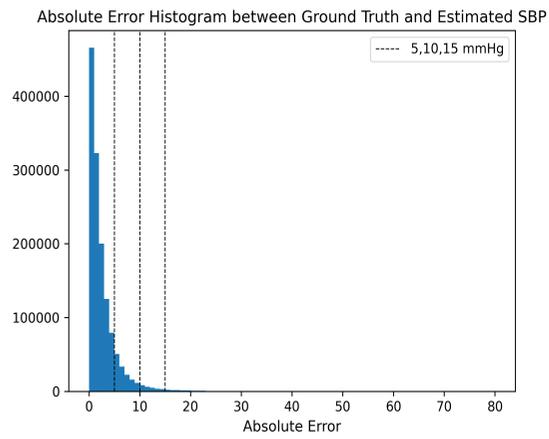


그림 64 SBP 혈압 예측 오차 분포
(보정 후)

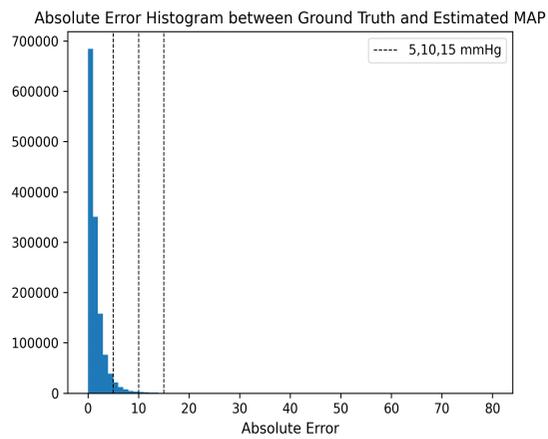


그림 65 MAP 혈압 예측 오차 분포
(보정 후)

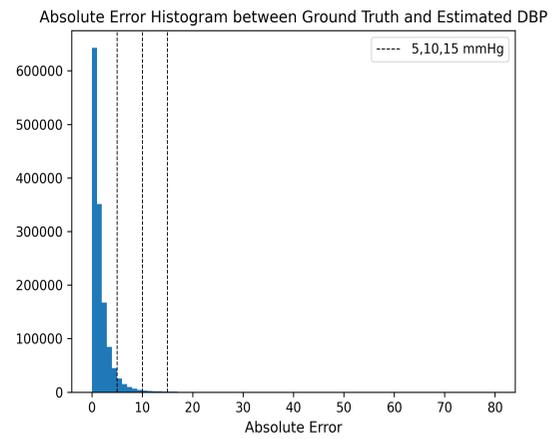


그림 66 DBP 혈압 예측 오차 분포
(보정 후)

고찰

본 연구에서 제안된 ResNet 딥러닝 모델이 동맥혈압을 예측함에 있어 AAMI의 혈압장치 관련 표준 프로토콜과 BHS 혈압 장치 관련 표준 프로토콜을 준수하여 모든 항목에서 A 등급과, 오차 기준을 통과하였다. 또한, 본 연구에서는 선형회귀와 6가지 선행된 동맥혈압 값으로 딥러닝 모델의 예측을 보정한 결과 성능이 향상 되었다. 딥러닝 모델의 학습에 사용된 참고 동맥혈압의 값은 수축기 기준:40~200, 확장기 기준: 0~200, 평균 동맥혈압 값 기준:0~200으로 광범위한 혈압의 값을 예측하였다. 개발된 ResNet 딥러닝 모델은 2초 단위를 입력으로 한 혈압의 예측을 수행하기에, 비침습적인 혈압 측정 방법에 비해 비교적 연속적으로 측정이 가능하다. 모델에 참고한 동맥혈압 값은 B-650 환자 모니터로부터 수집된 값이며, 실제 임상에서 의료 전문가가 참고하게 될 동맥 혈압 값에 근접하여 혈압을 예측하였다.

딥러닝을 활용한 혈압 예측 관련 연구 분야에서 많은 연구 방법론이 제시 되었지만, 딥러닝을 학습시키기 위한 데이터를 준비하는 과정 또한 중요하다. 본 연구에서는 딥러닝 모델의 학습용 데이터를 준비하는 과정에 있어 딥러닝의 학습에 영향을 주는 이상치의 제외 과정과 함께, 의료 전문가의 자동 라벨링 과정에 많이 활용 되는 오토인코더 모델을 활용하여 데이터에 대한 클리닝을 진행 하였다. 이상치의 분석과 오토인코더를 활용한 방법은 수작업이 동반되는 데이터 준비 과정에 비해 비교적 객관적이다. 따라서 본 연구를 재현함에 있어 이러한 데이터 준비 과정은 연구의 재현성에 도움이 될 것이라 기대한다. 딥러닝의 입력으로 활용되는 심전도와 광전용적맥파형은 다운샘플링, 분할 외에는 별도의 주파수 필터링과 같은 전처리 과정이 필요 하지 않아 2초 길이의 원 신호를 입력으로 한 ResNet 모델의 동맥 혈압의 예측이 가능하다.

일반적으로 계측용 의료기기는 보정을 필요로 하며, 본 연구에서는 예측이 적용된 세그먼트의 선행된 6개의 실제 동맥혈압 값을 기반으로 보정을 적용한 결과 오차의 평균과 분산 범위가 수축기: (평균:-0.280, 분산:-2.445), 확장기: (평균: -0.691, 분산: -1.74), 평균동맥혈압: (평균:-0.023, 분산:-1.243)의 범위로 확연하게 줄어든 것을 확인할 수 있었다. 본 보정 방법은 비침습적인 방법인 커프를 활용한 혈압 측정 방식을 사용하여 본 모델의 예측을 보정할 수 있을 것으로 기대된다.

다만, 본 연구는 중환자를 대상으로 수집된 데이터로 학습된 딥러닝 기반 동맥혈압 예측 모델이다. 따라서, 정상적인 심전도와 광전용적맥파 그리고 혈압 범위를 가진 환자 혹은 일반인, 나아가 다른 인종을 대상으로 한 모델의 예측에 대한 추가적인 실험 및 외부 검증이 필요하다. 본 연구는 2가지의 센서인 심전도와 광전용적맥파를 활용한 딥러닝 기반 동맥혈압 예측 모델이다. 최근의 혈압 예측 관련 연구에 따르면, 단일 심전도 혹은 단일 광전용적맥파 신호를 기반으로 한 혈압 예측 관련 연구 결과도 다수 보고 된다. 단일신호를 기반으로 한 방법의 경우, 편리함이 증가하지만 광전용적맥파의 경우 동적 잡음과 같은 외부적 요소에 영향을 많이 받는 만큼 단일 신호와 이중 신호를 입력으로 한 딥러닝 모델의 예측력에 대한 추가적인 검증 또한 필요하다. 또한 본 연구에서는 모델의 입력 데이터 셋에 대한 정규화 과정에 있어, 정규화를 적용하기 전, 정규화 범위를 초과하는 세그먼트는 제외 시켰다. 이러한 방법을 적용하는 것에 있어, 지정된 정규화 범위를 벗어나는 세그먼트에 대한 추가 검증이 필요하다. 마지막으로, 오토인코더의 학습 및 제외 임계값을 정하는 데이터 분류 과정은 직접 진행 되었다. 이러한 분류 과정이 다수의 의료 전문가에 의해 직접 진행 되었을 경우, 모델의 성능이 개선되는지에 대한 추가적인 실험이 필요할 것으로 생각된다.

결론

본 연구는 심전도와 광전용적맥파를 사용하여 침습적인 동맥혈압을 예측하는 딥러닝 모델을 개발하였다. 본 연구방법에 따른 딥러닝 모델은 국제적인 표준에 부합하는 성능을 검증 받았으며, 보정을 적용할 시 매우 높은 정확도로 동맥혈압을 예측한다. 또한 입력으로 활용되는 심전도와 광전용적맥파 신호의 주파수에 대한 필터링, 특성 추출 등의 특별한 전처리 없이 원신호만으로 동맥혈압 예측을 진행하였다. 예측 범위는 수축기, 확장기, 평균 동맥혈압 모두 모델의 예측 범위가 광범위 하였다. 이러한 방법을 사용하여 비교적 연속적으로 높은 정확도를 제공하며, 비침습적인 동맥 혈압 예측을 진행했다. 본 연구는 딥러닝 방법을 사용하여 혈압을 예측하는 방법에 있어 비교적 객관적인 방법론을 제시하였으며, 의료기기 계측에 적용되는 보정방법을 통해, 의료 현장에 딥러닝 방법론의 적용을 보다 더 용이하게 한다. 향후 연구에서 비침습적인 방법으로 계산된 혈압 수치를 활용한 딥러닝 모델 예측 보정 및 다양한 기관과 인종을 대상으로 한 빅데이터를 기반으로 딥러닝 모델을 추가적으로 학습시킬 수 있다면 성능이 더욱 향상 될 것으로 기대한다.

참고문헌

- [1] Vasan, R. S. et al. Antecedent blood pressure and risk of cardiovascular disease: the Framingham Heart Study. *Circulation* 105, 48-53 (2002).
- [2] Gu, D. et al. Blood pressure and risk of cardiovascular disease in Chinese men and women. *American journal of hypertension* 21, 265-272 (2008).
- [3] Kang, S.-H. et al. Prevalence, awareness, treatment, and control of hypertension in Korea. *Scientific reports* 9, 1-8 (2019).
- [4] Rehman S, Hashmi MF, Nelson VL. Blood Pressure Measurement. [Updated 2022 Dec 28]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2023 Jan-.
- [5] Burget GE. Stephen Hales (1677-1761). *Ann Med Hist.* 1925 Summer;7(2):109-116. PMID: 33944401; PMCID: PMC7945924.
- [6] Rader F, Victor RG. The Slow Evolution of Blood Pressure Monitoring: But Wait, Not So Fast! *JACC Basic Transl Sci.* 2017 Dec 25;2(6):643-645. doi: 10.1016/j.jacbts.2017.11.001. PMID: 30062179; PMCID: PMC6059006.
- [7] Ogedegbe G, Pickering T. Principles and techniques of blood pressure measurement. *Cardiol Clin.* 2010 Nov;28(4):571-86. doi: 10.1016/j.ccl.2010.07.006. PMID: 20937442; PMCID: PMC3639494.
- [8] Nguyen Y, Bora V. Arterial Pressure Monitoring. [Updated 2023 Mar 19]. In: StatPearls [Internet]. Treasure Island (FL): StatPearls Publishing; 2023 Jan-.
- [9] Dobson R. Blood pressure readings may be wrong for overweight patients. *BMJ.* 2003 Aug 30;327(7413):468. PMCID: PMC1142484.

- [10] Center for Disease Control (2011). Intravascular catheter-related infection (BSI)
- [11] Geddes, L. A. & Baker, L. E. Principles of applied biomedical instrumentation. (John Wiley & Sons, 1975).
- [12] Tijsseling, A. S., & Anderson, A. (2012). A. Isebree Moens and D.J. Korteweg: on the speed of propagation of waves in elastic tubes. (CASA-report: Vol. 1242). Technische Universiteit Eindhoven
- [13] Westenberg, J.J., van Poelgeest, E.P., Steendijk, P. et al. Bramwell-Hill modeling for local aortic pulse wave velocity estimation: a validation study with velocity-encoded cardiovascular magnetic resonance and invasive pressure assessment. *J Cardiovasc Magn Reson* 14, 2 (2012). <https://doi.org/10.1186/1532-429X-14-2>.
- [14] Bramwell JC, Hill AV: The velocity of the pulse wave in man. *Proc R Soc Lond B*. 1922, 93: 298-306. 10.1098/rspb.1922.0022.
- [15] Mukkamala R, Hahn JO, Inan OT, Mestha LK, Kim CS, Töreyn H, Kyal S. Toward Ubiquitous Blood Pressure Monitoring via Pulse Transit Time: Theory and Practice. *IEEE Trans Biomed Eng*. 2015 Aug;62(8):1879-901. doi: 10.1109/TBME.2015.2441951. Epub 2015 Jun 5. PMID: 26057530; PMCID: PMC4515215
- [16] Welykholowa K, Hosanee M, Chan G, Cooper R, Kyriacou PA, Zheng D, Allen J, Abbott D, Menon C, Lovell NH, et al. Multimodal Photoplethysmography-Based Approaches for Improved Detection of Hypertension. *Journal of Clinical Medicine*. 2020; 9(4):1203. <https://doi.org/10.3390/jcm9041203>
- [17] McCulloch, W.S., Pitts, W. A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics* 5, 115-133 (1943). <https://doi.org/10.1007/BF02478259>

- [18] Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59, 433-460.
- [19] A. L. Samuel, "Some Studies in Machine Learning Using the Game of Checkers," in *IBM Journal of Research and Development*, vol. 3, no. 3, pp. 210-229, July 1959, doi: 10.1147/rd.33.0210.
- [20] McCarthy, J., Minsky, M. L., Rochester, N., & Shannon, C. E. (2006). A Proposal for the Dartmouth Summer Research Project on Artificial Intelligence, August 31, 1955. *AI Magazine*, 27(4), 12. <https://doi.org/10.1609/aimag.v27i4.1904>
- [21] Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386-408. <https://doi.org/10.1037/h0042519>
- [22] Rumelhart, D., Hinton, G. & Williams, R. Learning representations by back-propagating errors. *Nature* 323, 533-536 (1986). <https://doi.org/10.1038/323533a0>
- [23] Dean, Jeffrey & Corrado, G.s & Monga, Rajat & Chen, Kai & Devin, Matthieu & Le, Quoc & Mao, Mark & Ranzato, Aurelio & Senior, Andrew & Tucker, Paul & Yang, Ke & Ng, Andrew. (2012). Large Scale Distributed Deep Networks. *Advances in neural information processing systems*.
- [24] Ahmad Alwosheel, Sander van Cranenburgh, Caspar G. Chorus, Is your dataset big enough? Sample size requirements when using artificial neural networks for discrete choice analysis, *Journal of Choice Modelling*, Volume 28, 2018, Pages 167-182, ISSN 1755-5345, <https://doi.org/10.1016/j.jocm.2018.07.002>.
- [25] Palm, G. (1986). Warren McCulloch and Walter Pitts: A Logical Calculus of the Ideas Immanent in Nervous Activity. In: Palm, G., Aertsen, A. (eds) *Brain Theory*. Springer, Berlin, Heidelberg.

https://doi.org/10.1007/978-3-642-70911-1_14

[26] Fukushima, K. A feature extractor for curvilinear patterns: a design suggested by the mammalian visual system. *Kybernetik* 7, 153-160 (1970). <https://doi.org/10.1007/BF00571695>

[27] Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.

[28] J. Deng, W. Dong, R. Socher, L. -J. Li, Kai Li and Li Fei-Fei, "ImageNet: A large-scale hierarchical image database," 2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, FL, USA, 2009, pp. 248-255, doi: 10.1109/CVPR.2009.5206848.

[29] Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. In: *Advances in neural information processing systems*, 2012: 1097-1105

[30] Zeiler, M.D., & Fergus, R. (2013). Visualizing and Understanding Convolutional Networks. *ArXiv*, abs/1311.2901.

[31] Simonyan, K., & Zisserman, A. (2014). Very Deep Convolutional Networks for Large-Scale Image Recognition. *CoRR*, abs/1409.1556.

[32] Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S.E., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2014). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1-9.

[33] He, K., Zhang, X., Ren, S., & Sun, J. (2015). Deep Residual Learning for Image Recognition. *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.

[34] Liou, C.-Y., Cheng, W.-C., Liou, J.-W., & Liou, D.-R. (2014). Autoencoder for words. *Neurocomputing*, 139, 84-96.

- [35] Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., ... Bengio, Y. (2014). Generative adversarial nets. In *Advances in neural information processing systems* (pp. 2672-2680).
- [36] Vaswani, A., Shazeer, N.M., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, L., & Polosukhin, I. (2017). Attention is All you Need. *Neural Information Processing Systems*.
- [37] Rashidi, Parisa (2020). AI History.svg. figshare. Figure. <https://doi.org/10.6084/m9.figshare.12363890.v10>
- [38] Maqsood, Sumbal & Xu, Shuxiang & Tran, Son & Garg, Saurabh & Springer, Matthew & Karunanithi, Mohan & Mohawesh, Rami. (2022). A survey: From shallow to deep machine learning approaches for blood pressure estimation using biosensors. *Expert Systems with Applications*. 197. 10.1016/j.eswa.2022.116788.
- [39] Kim, J. Y., Cho, B. H., Im, S. M., Jeon, M. J., Kim, I. Y., & Kim, S. I. (2006). Comparative study on artificial neural network with multiple regressions for continuous estimation of blood pressure. In *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference* (pp. 6942-6945): IEEE.
- [40] Kachuee, M., Kiani, M. M., Mohammadzade, H., & Shabany, M. (2015). Cuff-less high-accuracy calibration-free blood pressure estimation using pulse transit time. In *2015 IEEE international symposium on circuits and systems (ISCAS)* (pp. 1006-1009): IEEE.
- [41] Su, P., Ding, X.-R., Zhang, Y.-T., Liu, J., Miao, F., & Zhao, N. (2018). Long-term blood pressure prediction with deep recurrent neural networks. In *2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI)* (pp. 323-328): IEEE.

- [42] Tanveer, M. S., & Hasan, M. K. (2019). Cuffless blood pressure estimation from electrocardiogram and photoplethysmogram using waveform based ANN-LSTM network. *Biomedical Signal Processing and Control*, 51, 382-392.
- [43] Ribas Ripoll, V., & Vellido, A. (2019). Blood pressure assessment with differential pulse transit time and deep learning: a proof of concept. *Kidney Diseases*, 5(1), 23-27.
- [44] Wang, C., Yang, F., Yuan, X., Zhang, Y., Chang, K., & Li, Z. (2020). An end-to-end neural network model for blood pressure estimation using ppg signal. In *Artificial Intelligence in China: Proceedings of the International Conference on Artificial Intelligence in China* (pp. 262-272). Springer Singapore.
- [45] Senturk, U., Polat, K., & Yucedag, I. (2020). A non-invasive continuous cuffless blood pressure estimation using dynamic recurrent neural networks. *Applied Acoustics*, 170, 107534.
- [46] MATLAB. (2022a). Natick, Massachusetts: The MathWorks Inc.
- [47] Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Rafal Jozefowicz, Yangqing Jia, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dan Mané, Mike Schuster, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu, and Xiaoqiang Zheng. *TensorFlow: Large-scale machine learning on heterogeneous systems*, 2015. Software available from [tensorflow.org](https://www.tensorflow.org).
- [48] Chollet, F. (2015) keras, GitHub.<https://github.com/fchollet/keras>

- [49] Whelton, P. K. & Carey, R. M. The 2017 clinical practice guideline for high blood pressure. *Jama* 318, 2073-2074 (2017).
- [50] Whelton, P. K. et al. 2017 ACC / AHA / AAPA / ABC / ACPM/ AGS / APhA / ASH / ASPC / NMA / PCNA guideline for the prevention, detection, evaluation, and management of high blood pressure in adults: a report of the American College of Cardiology/American Heart Association Task Force on Clinical Practice Guidelines. *Journal of the American College of Cardiology* 71, e127-e248 (2018).
- [51] Hochreiter, Sepp. (1998). The Vanishing Gradient Problem During Learning Recurrent Neural Nets and Problem Solutions. *International Journal of Uncertainty, Fuzziness and Knowledge-Based Systems*. 6. 107-116. 10.1142/S0218488598000094.
- [52] Stergiou GS, Alpert B, Mieke S, Asmar R, Atkins N, Eckert S, Frick G, Friedman B, Graßl T, Ichikawa T, Ioannidis JP, Lacy P, McManus R, Murray A, Myers M, Palatini P, Parati G, Quinn D, Sarkis J, Shennan A, Usuda T, Wang J, Wu CO, O'Brien E. A universal standard for the validation of blood pressure measuring devices: Association for the Advancement of Medical Instrumentation/European Society of Hypertension/International Organization for Standardization (AAMI/ESH/ISO) Collaboration Statement. *J Hypertens*. 2018 Mar;36(3):472-478. doi: 10.1097/HJH.0000000000001634. PMID: 29384983; PMCID: PMC5796427.
- [53] O'Brien, Eoin & Waeber, Bernard & Parati, Gianfranco & Staessen, Jan & Myers, Martin. (2001). Blood pressure measuring devices: Recommendations of the European Society of Hypertension. *BMJ (Clinical research ed.)*. 322. 531-6.
- [54] Bland JM, Altman DG. Statistical methods for assessing agreement between two methods of clinical measurement. *Lancet*. 1986 Feb 8;1(8476):307-10. PMID: 2868172.

[55] Zhang, Gengjia and Shin, Siho and Jung, Jaehyo, Cascade Forest Regression Algorithm for Non-Invasive Blood Pressure Estimation Using PPG Signals. Available at SSRN: <https://ssrn.com/abstract=4230992> or <http://dx.doi.org/10.2139/ssrn.4230992>

[56] Dey, J., Gaurav, A., Tiwari, V.N.: InstaBP: cuff-less blood pressure monitoring on Smartphone using single PPG sensor. In: 2018 40th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 5002-5005. IEEE, Honolulu (2018)

[57] He, R., Huang, Z.-P., Ji, L.-Y., Wu, J.-K., Li, H., Zhang, Z.-Q.: Beat-to-beat ambulatory blood pressure estimation based on random forest. In: 2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN), pp. 194-198. IEEE, San Francisco (2016)

[58] Gao, S.C., Wittek, P., Zhao, L., Jiang, W.J.: Data-driven estimation of blood pressure using photoplethysmographic signals. In: 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), pp. 766-769. IEEE, Orlando (2016)

[59] Kachuee, M., Kiani, M.M., Mohammadzade, H., Shabany, M.: Cuffless blood pressure estimation algorithms for continuous health-care monitoring. *IEEE Trans. Biomed. Eng.* 64, 859-869 (2017). <https://doi.org/10.1109/TBME.2016.2580904>

[60] Yang, S., Zhang, Y., Cho, SY. et al. Non-invasive cuff-less blood pressure estimation using a hybrid deep learning model. *Opt Quant Electron* 53, 93 (2021). <https://doi.org/10.1007/s11082-020-02667-0>

[61] R. He, Z. -P. Huang, L. -Y. Ji, J. -K. Wu, H. Li and Z. -Q. Zhang, "Beat-to-beat ambulatory blood pressure estimation based

on random forest," 2016 IEEE 13th International Conference on Wearable and Implantable Body Sensor Networks (BSN), San Francisco, CA, USA, 2016, pp. 194-198, doi: 10.1109/BSN.2016.7516258.

[62] Simjanoska, M., Gjoreski, M., Bogdanova, A. M., Koteska, B., Gams, M., & Tasic, J. F. (2018, January). ECG-derived Blood Pressure Classification using Complexity Analysis-based Machine Learning. In HEALTHINF (pp. 282-292).

[63] Liu, S., Huang, Z., Zhu, J., Liu, B., & Zhou, P. (2024). Continuous blood pressure monitoring using photoplethysmography and electrocardiogram signals by random forest feature selection and GWO-GBRT prediction model. *Biomedical Signal Processing and Control*, 88, 105354.

[64] Eom, H., Lee, D., Han, S., Hariyani, Y. S., Lim, Y., Sohn, I., ... & Park, C. (2020). End-to-end deep learning architecture for continuous blood pressure estimation using attention mechanism. *Sensors*, 20(8), 2338.

[65] C. El Hajj and P. A. Kyriacou, "Cuffless and Continuous Blood Pressure Estimation From PPG Signals Using Recurrent Neural Networks," 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Montreal, QC, Canada, 2020, pp. 4269-4272, doi: 10.1109/EMBC44109.2020.9175699.

[66] Miao, F., Wen, B., Hu, Z., Fortino, G., Wang, X. P., Liu, Z. D., ... & Li, Y. (2020). Continuous blood pressure measurement from one-channel electrocardiogram signal using deep-learning techniques. *Artificial Intelligence in Medicine*, 108, 101919.

[67] Athaya, T., & Choi, S. (2021). An estimation method of continuous non-invasive arterial blood pressure waveform using

photoplethysmography: A U-Net architecture-based approach. *Sensors*, 21(5), 1867.

[68] Yang, S., Zaki, W.S.W., Morgan, S.P. et al. Blood pressure estimation with complexity features from electrocardiogram and photoplethysmogram signals. *Opt Quant Electron* 52, 135 (2020). <https://doi.org/10.1007/s11082-020-2260-7>

[69] Zhang, G., Shin, S., & Jung, J. (2023). Cascade forest regression algorithm for non-invasive blood pressure estimation using PPG signals. *Applied Soft Computing*, 110520.

[70] Mukkamala R, Hahn JO, Inan OT, Mestha LK, Kim CS, Töreyn H, Kyal S. Toward Ubiquitous Blood Pressure Monitoring via Pulse Transit Time: Theory and Practice. *IEEE Trans Biomed Eng.* 2015 Aug;62(8):1879-901. doi: 10.1109/TBME.2015.2441951. Epub 2015 Jun 5. PMID: 26057530; PMCID: PMC4515215

영문초록 (Abstract)

The blood pressure is one of the essential vital signs for the ongoing health management across all ages, genders, and health statuses. Notably, arterial blood pressure measurement is applied in the critical patients for it is a critical indicator for assessing prognosis. The arterial blood pressure measurement offers continuous and precise readings but the invasive nature of the method remains limitation.

From the traditional blood pressure methods using physical mechanisms to recent methods using deep learning methods, challenges to address the limitation of such methods has been undertaken. In our study, we developed a deep learning model to predict numeric arterial blood pressure from electrocardiographic and photoplethysmographic waveform. The calibration method was applied to the reliable estimations from the deep learning models, significantly enhancing their performance to reach a very high level.

The extracted data was derived from 191 patients who had been managed at Intensive Care Unit, Asan Medical Center Seoul. The training and test sets for the deep learning model were segregated by different time period. A ResNet model, based on a convolutional neural network and commonly used in similar studies, was trained using data cleaned via an Auto Encoder model. Minimal processing was applied on the signals such as signal segmentation and down sampling. This model performed broad range of predictions on systolic, diastolic, and mean arterial blood pressures derived from the patient monitor. The Auto Encoder cleaning process significantly lightened the manual task of data exclusion. Additionally, it allowed for the subjective assessment of low-quality and normal signal classifications to be objectified through the use of a deep learning model.

In utilizing the medical device to the clinical uses, the calibration method enhances measurement accuracy. The ResNet blood pressure estimation model received graded 'A' based on the BHS(British Hypertension Society) standards, and met all criteria based on AAMI(Association for the Advancement of Medical Instrumentation) standards. In the study, the performance of the ResNet deep learning model before and after calibration was quantitatively evaluated. The mean and standard deviation of the error between the predicted and actual blood pressure values were significantly reduced when using the calibration method reduced from SBP: 0.028 ± 6.81 , MAP: 0.69 ± 4.52 , DBP: 0.03 ± 4.32 to SBP: 0.004 ± 4.36 , MAP: 0.003 ± 2.78 , DBP: 0.003 ± 3.08 . As performance improves after applying calibration, it is expected that the generated deep learning model can be applied to various cohorts.

This study is limited to a single institution and a single ethnicity. In order for the developed deep learning model to be applied in practice, external validation of external institutions and multiple countries is essential. In addition, as recent studies suggests blood pressure measurement methods using fewer sensors, comparative verification of the simplicity of the deep learning method and the stability of prediction performance is necessary.

In summary, this research outlines a more pragmatic methodology by employing a straightforward approach that incorporates the AutoEncoder signal quality classification, the ResNet deep learning model, and a calibration method. This research highlights its potential applicability across diverse patient groups, as it shows that invasive arterial blood pressure values can be non-invasively and continuously predicted using electrocardiographic and photoplethysmographic waveform. Furthermore, the ability to predict blood pressure with higher accuracy after correction underlines its clinical significance.