

PPG의 형태 및 Time-Domain Attributes를 활용한 딥러닝 기반 혈압 추정 연구

배승호¹, 김민성^{2*}, 이현정², 김규형²

¹영남대학교, ²한국전자통신연구원

j04sh926@gmail.com, {kms5905*, ehj1224, jaykim}@etri.re.kr

Deep learning-based blood pressure estimation study using Morphology of PPG signal and Time-Domain Attributes

Seung Ho Bae¹, Minseong Kim^{2*}, Hyeonjeong Lee², Kyu Hyung Kim²

¹Yeungnam University, ²Electronics and Telecommunications Research Institute

요약

본 논문은 딥러닝을 활용하여 PPG 기반의 혈압 추정을 목표로 한다. 이를 위해 PPG의 형태(morphology)와 시간 영역 특성(time-domain attributes)을 활용하여 수축기 혈압(SBP)을 추정하는 3 Branch CNN-LSTM 모델을 설계하였다. 공개 데이터베이스를 사용하여 SBP 추정 성능을 검증한 결과 평균 절대 오차(MAE) 8.924 mmHg의 결과를 얻었다.

1. 서론

현대사회가 고령화 사회에 접어들에 따라 심혈관 질환을 포함한 여러 가지 질환의 위험성이 대두되고 있으며, 이때 혈압은 사람의 건강상태를 판단할 수 있는 중요한 지표 중 하나이다. 일상에서 개인의 건강상태를 모니터링하기 위한 방법 중 하나로, 스마트워치 등 웨어러블 장비를 사용하여 생체신호를 측정하고 사용자의 혈압을 추정하고자 하는 수요가 증가하고 있다.

그에 따라 주로 ECG와 PPG를 모두 활용하여 형태학적 특징을 추출하고 기계 학습 기반 혈압 추정 연구가 많이 이루어져 왔다. 그러나 ECG는 측정 시 사용자에게 불편함을 유발하여 웨어러블 환경에서 적용하기 어려운 한계점을 가지고 있다. 반면 PPG는 웨어러블 장비를 통해 측정이 용이하기 때문에 스마트 헬스케어에 널리 적용되고 있다. 따라서 본 연구에서는 8초 길이의 단일 PPG 신호와 PPG로부터 추출한 시간 영역 특성(Time-domain attributes)를 함께 모델에 사용하여 수축기혈압(SBP)을 추정하는 3-Branch CNN-LSTM 기반 딥러닝 모델을 설계하였고, 공개 데이터를 활용하여 제안한 방법을 검증하였다.

II. 본론

본 연구에서는 3 Branch CNN-LSTM 모델을 설계하고, 학습과 검증에서 Beth Israel Deaconess Medical Center 중환자실에서 수집한 MIMIC-III 데이터를 사용하였다.[1][2][3] 해당 데이터는 ABP, PPG 신호 등의 정보를 포함한다.

해당 데이터베이스에서 약 1,600명의 환자에 대해 8초 이상인 데이터를 최대 100개까지 추출하고, Peak noise, Flat line을 제거하는 전처리과정을 통하여 최종적으로 101,087개의 8초길이 PPG를 학습에 사용하였다.

제안하는 모델의 학습 및 검증 흐름도는 Fig.1 와 같다. 학습 데이터와 테스트 데이터셋을 로드한 후, 주파수 대역에서 노이즈를 필터링하는 단계를 거치고 PPG신호에서 Time-domain Attributes를 추출한다. 그 후, PPG와 Time-Domain Attribute 각각마다 0~1사이의 값으로 정규화하고

SBP 값을 Target으로 하여 모델 학습을 진행한다.

제안하는 모델의 구조는 Fig2 과 같다. 첫 번째 및 두 번째 Branch는 PPG신호의 waveform으로부터 feature를 학습 및 추출하는 CNN-LSTM 네트워크를 적용하였으며, 세 번째 Branch는 PPG에서 추출한 Time-Domain Attributes를 입력으로 한다.




Fig.1 Model Training & Evaluation Flowchart




Fig 2. Model Architecture

General CNN-LSTM Branch

CNN은 특징 학습을 통해 문제의 유용한 특징을 자동적으로 추출할 수 있는 강력한 네트워크이며, 합성곱을 통하여 형태적 특징 정보를 파악할 수 있어 신호의 특징들이 변환되거나 왜곡된 형태가 섞여 있어도 원활하게 추출할 수 있다는 장점을 가지고 있다.

그리고 LSTM은 신호에 존재하는 시간 의존성(Temporal Dependence)을 학습하는 특성을 가지며, 특히 장기간에 걸친 신호의 연관관계를 추출하

는데 탁월한 성능을 가지고 있다.

본 논문에서는 여러 연구에서 채택하고 있는 CNN-LSTM 모델 구조를 기반으로 하여 PPG신호의 시간적,공간적 특징을 활용할 수 있도록 하였다.[4][5]

첫 번째 Branch에서는 세 개의 Convolution Layer 와 1개의 LSTM Layer을 조합한 CNN-LSTM 구조이고, Convolution Layer의 경우 32,64,128, LSTM Layer의 경우 64개의 필터 개수를 가지고 있으며 Stride 와 Kernel size 는 각각 1,3 이다.

Wide CNN-LSTM Branch

두 번째 Branch에서는 첫 번째 Branch와 유사하나 넓은 영역의 수용영역을 통한 PPG신호의 거시적인 공간정보를 특징으로 추출하기 위해 최근 연구 내용을 참고하여 Kernel size를 13으로 설정하였다.[6] 또한 파라미터 수를 조절하기 위해 Convolution Layer의 필터 개수는 각각 16,32,64로 조정하였다.

Time domain Attributes branch

PPG를 활용한 딥러닝 기반 연속 혈압 추정을 위해 8초 길이의 PPG 만을 학습에 사용하게 되는데, 부가적인 임상정보 없이 수축기혈압을 예측하는 데는 큰 어려움이 따른다. 이를 보완하기 위해 PPG 신호에서 시간 영역 특성들을 추출해 하나의 Branch를 구성하였고, 시간영역 특성에는 BPM(Beats Per Minute, 분당심박수) , IBI(interbeat intervals, 심박 간격) Amp(Amplitude, 신호 진폭)를 입력으로 사용하였다. 네트워크 구조는 두 개의 Fully Connected Layer로 이루어져 있으며, 필터개수는 각각 8,16으로 설정하였고 시간 영역 특성 추출에는 Heartpy 라이브러리를 활용하였다.[7][8]

Branch 통합 - model output

세 개의 Branch으로부터 출력되는 125,125,16개의 레이어를 하나로 연결하고, 32개,8개의 필터 개수를 가진 두 개의 Dense층과 Batch Normalization 층 이후 SBP값을 예측하기 위한 하나의 출력 레이어로 연결된다.

모델의 총 학습가능한 파라미터 수는 152,321개 이며 모든 Branch의 Convolution Layer에는 elu, LSTM Layer에는 Hyperbolic Tangent를 사용하였다. 또한 과적합을 방지하기 위해 30%의 Dropout 층을 사용하였다.

HyperParameter

딥러닝 모델에서 하이퍼파라미터의 조절은 성능의 큰 영향을 끼친다. 그중, 학습률은 Gradient의 방향으로 얼마나 가중치가 빠르게 이동할 지를 결정하는 중요한 변수이다. 본 연구에서는 Step Size 에 따라 학습률을 조정하는 Cyclic Learning rate 기법을 적용하여 3e-4와 1e-3 구간의 학습률을 가지는 스케줄러로 설정한 Adam을 사용하였다.[9]

III. 실험결과 및 분석

실험 및 검증에는 MIMIC-3 데이터에서 랜덤으로 추출한 10,000개의 샘플을 사용하였고, 학습 데이터와 동일하게 8초길이의 PPG와 PPG로부터 추출한 Time-domain Attributes , SBP 로 구성되어있는 데이터 세트로 재구성하여 사용하였다. 성능 평가 지표로는 Mean Absolute Error를 사용하였다.

Branch Model	General CNN-LSTM	Wide CNN-LSTM	Time-domain Attribute	Error
Model 1	O	X	X	9.9805
Model 2	O	O	X	9.4603
Model 3	O	O	O	8.9248

Table 1. Performance Comparison by Model Branch

3 Branch CNN-LSTM 모델의 Branch 유무 별 성능 비교표는 Table 1. 과 같다. 세 개의 Branch를 모두 사용한 모델과 특정한 Branch를 뺀 모델과의 성능을 비교하였고, Batch size 와 Epochs 는 각각 32, 100을 사용하였다. 성능 비교표를 통해 확인할 수 있듯이 본 연구에서 제안하는 모델의 절대 평균 오차는 8.9248 mmHg이며, General CNN-LSTM Branch만을 사용하는 모델에 비해 약 12% 우수한 성능을 보여주었다. 또한 Time-Domain Attribute Branch가 포함된 경우 CNN-LSTM 만 사용하는 모델에 비해 6% 높은 성능을 보여주었다.

Fig 3.은 제안하는 3 Branch CNN-LSTM 모델을 통하여 SBP를 추정된 결과를 Regression Plot으로 나타낸 결과이다. 흑색의 점선은 평균 오차 0mmHg, 적색의 점선은 평균 오차 ± 5 mmHg를 나타내며, 청색 선은 현재 모델이 추정된 SBP 값의 Trend Line을 의미한다.




Fig 3. Estimation Result

IV. 결론

본 연구에서는 PPG 신호와 PPG에서 추출한 Time-domain Attribute를 입력으로 하는 3 Branch CNN-LSTM 모델을 설계하고 SBP를 추정하였다. General CNN-LSTM Branch에는 선행 연구에서 활발히 연구되고 있는 CNN-LSTM 모델을 채택하였고, Wide CNN-LSTM Branch에는 수용영역의 크기를 늘리고 PPG의 거시적인 추세를 특징으로 사용할 수 있도록 하였다. 또한 Time-domain Attribute Branch에는 PPG에서 추출한 시간영역 특성을 활용한 DNN 모델을 사용하였다.

MIMIC-III 데이터베이스에서 학습에 사용되지 않은 샘플들 중 랜덤으로 추출한 10,000개의 테스트 데이터를 사용하여 검증을 진행하였고, 연구에서 제안하는 3 Branch CNN-LSTM 모델은 일부 Branch를 사용한 경우와 비교해 보았을 때 각각 12%, 6% 의 성능 향상이 있음을 확인하였다. 한편 10,000개의 테스트 데이터에 대해 수축기 혈압의 오차가 ± 8.924 mmHg 이내로 우수하지만, 10,000개의 한정적인 데이터를 사용한 결과이므로, 향후 더 많은 데이터를 사용하여 성능을 검증하고자 하며, 수축기혈압 추정 오차를 의료기기 수준으로 줄이는 연구를 진행할 예정이다.

ACKNOWLEDGMENT

본 연구는 한국전자통신연구원 연구운영지원사업의 일환으로 수행되었음. [22ZD1140, 대경권 지역산업 기반 ICT 융합 기술 고도화 지원(의료)]

참 고 문 헌

- [1] Moody, B., Moody, G., Villarroel, M., Clifford, G. D., & Silva, I.

(2020). MIMIC-III Waveform Database (version 1.0). PhysioNet.
<https://doi.org/10.13026/c2607m>.

[2] Johnson, A. E. W., Pollard, T. J., Shen, L., Lehman, L. H., Feng, M., Ghassemi, M., Moody, B., Szolovits, P., Celi, L. A., & Mark, R. G. (2016). MIMIC-III, a freely accessible critical care database. *Scientific Data*, 3, 160035.

[3] Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P. C., Mark, R., ... & Stanley, H. E. (2000). PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals. *Circulation [Online]*. 101 (23), pp. e215-e220.

[4] H. Chung, H. Ko, H. Lee and J. Lee, "Deep Learning for Heart Rate Estimation From Reflectance Photoplethysmography With Acceleration Power Spectrum and Acceleration Intensity," in *IEEE Access*, vol. 8, pp. 63390-63402, 2020, doi: 10.1109/ACCESS.2020.2981956.

[5] Ding, Xiaohan, et al. "Scaling up your kernels to 31x31: Revisiting large kernel design in cnns." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022.

[6] Jeong, D.U., Lim, K.M. Combined deep CNN-LSTM network-based multitasking learning architecture for noninvasive continuous blood pressure estimation using difference in ECG-PPG features. *Sci Rep* 11, 13539 (2021).
<https://doi.org/10.1038/s41598-021-92997-0>

[7] van Gent, P., Farah, H., van Nes, N., & van Arem, B. (2019). Analysing Noisy Driver Physiology Real-Time Using Off-the-Shelf Sensors: Heart Rate Analysis Software from the Taking the Fast Lane Project. *Journal of Open Research Software*, 7(1), 32. DOI: <http://doi.org/10.5334/jors.241>

[8] van Gent, P., Farah, H., van Nes, N., & van Arem, B. (2019). HeartPy: A novel heart rate algorithm for the analysis of noisy signals. *Transportation Research Part F: Traffic Psychology and Behaviour*, 66, 368-378. <https://doi.org/10.1016/j.trf.2019.09.015>

[9] Smith, Leslie N. "Cyclical learning rates for training neural networks." *2017 IEEE winter conference on applications of computer vision (WACV)*. IEEE, 2017.