

## 일상생활 환경에서의 안정적인 심박수 추정을 위한 PPG-가속도계 신호 및 맥락 정보 융합 기반 접근

이 재 혁\*

서울과학기술대학교 IT융합기술연구소 연구교수

# Multimodal and Context-Aware Fusion of PPG and Accelerometer Signals for Robust Heart Rate Estimation in Free-Living Conditions

Jaehyuk Lee\*

Research Professor, IT Convergence Technology Research Institute, Seoul National University of Science and Technology, Seoul 01811, Korea

### [요 약]

웨어러블 기기에서 광용적맥파 센서를 이용한 심박수 추정은 신체 움직임으로 인해 발생하는 motion artifacts로 인해 일상 생활 환경에서 정확도가 저하되는 문제가 있다. 본 연구에서는 이러한 문제를 완화하기 위해 PPG 신호 특징, 가속도 센서 기반 움직임 특징, 그리고 시간/컨텍스트 정보를 융합한 트리 기반 멀티모달 심박수 추정 프레임워크를 제안한다. 제안 모델은 PPG 신호에서 추출한 통계 및 주파수 특징과 손목 착용 가속도 센서에서 추출한 움직임 특징을 결합하고, 이전 심박수와 활동 정보와 같은 컨텍스트 변수를 추가적으로 활용하여 추정 성능을 향상시켰다. 실험 결과, 제안 모델은 MAE 5.03bpm, RMSE 7.26bpm의 성능을 보였으며, PPG 단일 특징 기반 모델 대비 약 29%의 오차 감소를 확인하였다. 특히 계단 오르기 및 자전거 타기와 같은 움직임이 큰 활동에서 성능 향상이 두드러졌다. 이러한 결과는 멀티모달 센서 융합이 웨어러블 환경에서의 심박수 추정 정확도를 효과적으로 향상시킬 수 있음을 보여준다.

### [Abstract]

Accurate heart rate estimation using wearable photoplethysmography (PPG) sensors remains a challenge in free-living conditions due to motion artifacts caused by body movements. This study proposes a multimodal heart rate estimation framework that integrates PPG signal features, accelerometer-based motion features, and contextual information. The model combines statistical and spectral features extracted from PPG signals with motion features derived from wrist-worn accelerometer data, and incorporates contextual variables such as previous heart rate and activity labels to enhance estimation robustness. The proposed model achieved a mean absolute error of 5.03 bpm and root mean squared error of 7.26 bpm, reducing estimation error by approximately 29% compared with a PPG-only baseline. Activity-wise analysis showed improved performance during motion-intensive activities such as stair climbing and cycling. Feature importance analysis indicated that motion and contextual features play an important role in improving estimation accuracy.

**색인어** : 심박수 추정, 광용적맥파, 멀티모달 융합, 웨어러블 센싱, 특징 공학

**Keyword** : Heart Rate Estimation, Photoplethysmography, Multimodal Fusion, Wearable Sensing, Feature Engineering

<http://dx.doi.org/10.9728/dcs.2026.27.5.1345>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

Received 09 March 2026; Revised 31 March 2026

Accepted 06 April 2026

\*Corresponding Author, Jaehyuk Lee

Tel: 

E-mail: [jhl9405@seoultech.ac.kr](mailto:jhl9405@seoultech.ac.kr)

## I. 서 론

최근 스마트워치와 같은 웨어러블 기기의 보급이 확대되면서 광용적맥과 Photoplethysmography 기반 심박수 모니터링 기술이 개인 건강관리 및 운동 모니터링 분야에서 널리 활용되고 있다[1],[2]. 심박수는 운동 강도, 심혈관 반응, 피로도 등을 반영하는 중요한 생리학적 지표로, 재활 치료, 운동 처방, 만성질환 관리 등 다양한 임상 및 건강관리 영역에서 활용된다[3].

PPG 센서는 혈류 변화에 따른 광학적 신호를 기반으로 심박수를 비침습적으로 측정할 수 있으며, 구조가 간단하고 소형화가 가능하다는 장점으로 인해 대부분의 웨어러블 기기에 탑재되고 있다[4]. 이러한 특성으로 인해 PPG 기반 심박수 측정은 일상생활 환경에서의 지속적인 생체 신호 모니터링을 가능하게 하는 핵심 기술로 평가된다. 그러나 웨어러블 환경에서 측정되는 PPG 신호는 사용자 움직임에 의해 쉽게 왜곡되며, 특히 손목 기반 센서에서는 motion artifact가 심박수와 유사한 주파수 성분을 포함하여 추정 정확도를 저하시킬 수 있다. 이러한 문제는 신체 활동이 증가하는 상황에서 더욱 두드러지며, 안정적인 심박수 추정을 어렵게 만드는 주요 요인으로 작용한다.

최근에는 이러한 한계를 극복하기 위해 가속도 센서 Accelerometer와 같은 추가 센서를 활용한 멀티모달 융합 접근과 머신러닝 기반 분석 기법이 활발히 연구되고 있다[5],[6]. 특히 트리 기반 알고리즘은 구조적으로 단순하고 다양한 특징 간 비선형 관계를 효과적으로 모델링할 수 있으며, 해석 가능성과 안정적인 성능 측면에서도 장점을 가진다[7].

이에 본 연구에서는 PPG와 ACC 신호에 더해 이전 심박수 및 활동 정보를 포함한 Temporal/Context 특징을 통합한 특징 기반 앙상블 심박수 추정 프레임워크를 제안한다. 제안 방법은 통계 및 주파수 기반 PPG 특징과 움직임 특징을 결합하여 부스팅 기반 회귀 모델을 구축하고, 맥락 정보를 활용하여 예측의 안정성을 향상시킨다. 또한 PPG 단일 모델, PPG와 ACC 결합 모델, PPG와 ACC 및 Context 정보를 통합한 모델을 단계적으로 비교하는 구성요소 분석을 통해 각 정보의 기여도를 정량적으로 평가한다. 이를 통해 멀티모달 정보 융합이 심박수 추정 성능 향상에 미치는 영향을 체계적으로 분석하고, 웨어러블 환경에서의 안정적인 심박수 추정을 위한 센서 융합 전략을 제시하고자 한다.

본 연구의 주요 기여는 다음과 같다.

- 1) PPG, ACC, Temporal/Context 특징을 통합한 특징 기반 심박수 추정 프레임워크 제안
- 2) 구성요소별 성능 분석을 통해 각 특징의 기여도를 정량적으로 검증
- 3) subject-wise split 기반 평가를 통해 실제 환경에서의 일반화 성능 확인

## II. 관련 연구

### 2-1 멀티센서 융합 기반 심박수 추정

기존 연구에서는 PPG 기반 심박수 추정을 위해 다양한 신호 처리 기반 접근이 제안되어 왔다. 예를 들어, band-pass filtering, peak detection, spectral analysis 등 신호 처리 기반 방법을 통해 PPG 신호에서 심박수 성분을 추출하는 접근이 주로 사용되어 왔다[8],[9].

그러나 웨어러블 환경에서 측정되는 PPG 신호는 사용자 움직임에 의해 쉽게 왜곡되며, 특히 손목 기반 센서에서는 motion artifact가 심박수와 유사한 주파수 성분을 포함하여 추정 정확도를 저하시킬 수 있다. 이러한 문제는 활동이 증가하는 환경에서 더욱 두드러지며, 단순 신호 처리 기반 접근만으로는 안정적인 심박수 추정에 한계가 있다.

이러한 한계를 극복하기 위해 가속도 센서와 같은 추가 센서를 활용한 멀티센서 융합 접근이 제안되고 있다. ACC 센서는 사용자의 움직임 패턴과 활동 강도를 반영할 수 있어 PPG 신호에 포함된 motion artifact를 분석하거나 보정하는 데 활용된다[10],[11].

최근에는 머신러닝 기반 방법을 통해 다양한 센서 특징을 통합적으로 활용하는 연구가 증가하고 있으며, 센서 간 비선형 관계를 학습함으로써 복잡한 움직임 환경에서도 성능 향상 가능성을 보이고 있다. 그러나 기존 멀티모달 접근은 주로 센서 신호의 단순 결합 또는 딥러닝 기반 특징 학습에 초점을 두고 있어, 각 특징의 기여도를 해석하기 어렵고 모델 구조가 복잡해지는 한계를 가진다. 또한 이전 심박수 및 활동 정보와 같은 Temporal/Context 정보를 함께 고려하고, 그 기여도를 체계적으로 분석한 연구는 상대적으로 부족한 실정이다.

## III. 제안 방법

### 3-1 데이터셋

본 연구에서는 일상생활 환경에서의 심박수 추정 연구를 위해 공개 데이터셋인 PPG-DaLiA (Photoplethysmography Dataset for Heart Rate Estimation in Daily Living Activities)[12]를 사용하였다.

해당 데이터셋은 손목 기반 웨어러블 장치를 이용하여 측정된 PPG 신호와 3축 ACC 신호를 포함하고 있으며, 다양한 일상 활동 중 측정된 심박수 데이터를 제공한다.

PPG-DaLiA 데이터셋은 총 15명의 피험자로부터 수집되었으며, 각 피험자는 앉기, 걷기, 계단 오르기, 자전거 타기 등 다양한 활동을 수행하는 동안 생체 신호가 기록되었다. PPG 신호와 ACC 신호는 손목 착용형 센서를 통해 동시에 측정되었으며, 기준 심박수(ground truth HR)는 흉부 ECG 센서를 이용하여 기록되었다.

모델의 일반화 성능을 평가하기 위해 subject-wise split

방식을 적용하였다. 즉, 동일 피험자의 데이터가 학습과 테스트 데이터에 동시에 포함되지 않도록 피험자 단위로 데이터를 분리하였다. 본 연구에서는 14명의 피험자 데이터를 학습에 사용하고, 독립된 1명의 피험자 데이터를 이용하여 검증을 수행하였다.

### 3-2 전처리 및 특징 추출

웨어러블 센서 신호는 다양한 환경적 요인과 사용자 움직임에 의해 잡음이 포함될 수 있으므로, 모델 학습에 앞서 신호 전처리 및 특징 추출 과정을 수행하였다.

먼저 PPG 신호에 포함된 저주파 및 고주파 노이즈를 제거하기 위해 band-pass filtering을 적용하였다. 이후 일정 길이의 sliding window를 적용하여 각 구간별 특징(feature)을 추출하였다. window는 8초 길이로 설정하였으며, 2초 간격으로 이동시키며 특징을 추출하였다.

#### 1) PPG 관련 특징

PPG 신호로부터 심박수와 관련된 통계적 및 주파수 기반 특징을 추출하였다.

시간 영역 특징으로는 mean, standard deviation, variance, skewness, kurtosis와 같은 통계적 특징을 포함하였으며, 이는 신호의 분포 및 변동성을 반영한다.

주파수 영역 특징으로는 dominant frequency와 spectral power를 포함하여 심박수와 직접적으로 관련된 주파수 성분을 반영하였다. 또한 spectral entropy와 zero-crossing rate와 같은 신호 품질 관련 특징을 추가하여 신호의 불규칙성 및 잡음 수준을 반영하였다.

이와 함께 FFT 기반 분석을 통해 PPG 신호로부터 추정된 심박수 후보값(hr\_ppg)을 특징으로 포함하였다.

#### 2) ACC 관련 특징

ACC 센서는 사용자의 움직임 패턴을 반영하며 PPG 신호의 motion artifacts와 밀접한 관련이 있다.

각 축(x, y, z)에 대해 mean 및 standard deviation과 같은 통계적 특징을 추출하여 움직임의 기본적인 분포를 반영하였다. 또한 acceleration magnitude를 기반으로 한 mean, standard deviation, RMS 등의 특징을 추가하여 전체적인 움직임 강도를 표현하였다.

더불어 acceleration 신호의 dominant frequency를 추출하여 보행 cadence와 같은 주기적인 움직임 패턴을 반영하였으며, motion intensity와 같은 특징을 통해 활동 강도를 정량적으로 표현하였다.

#### 3) Temporal/Context 관련 특징

심박수는 시간적으로 연속적인 생리 신호이므로 이전 시점의 심박수 정보가 현재 심박수 추정에 중요한 단서를 제공할 수 있다. 이를 반영하기 위해 이전 심박수(prev\_hr), PPG 기반 심박수와 이전 심박수 간의 차이( $\Delta HR$ ), 그리고 활동(activity) 정

보를 포함한 Temporal/Context 특징을 추가하였다.

본 연구에서 사용된 prev\_hr은 이전 시점( $t-1$ )의 실제 심박수 값을 기반으로 생성된 특징으로, 각 시점의 입력은 해당 시점 이전의 정보만을 사용하도록 시계열 순서를 유지하여 구성하였다. 또한 학습 데이터와 테스트 데이터 모두에서 동일한 방식으로 prev\_hr을 생성하였으며, 미래 시점의 정보는 어떠한 형태로도 포함되지 않도록 하여 데이터 누수를 방지하였다.

이러한 연구 설정은 웨어러블 기반 연속적 심박수 모니터링 환경을 가정하며, 이전 시점의 심박수 정보가 활용 가능한 시나리오를 반영한다.

### 3-3 멀티모달 특징 융합 기반 심박수 추정 모델

본 연구에서는 웨어러블 센서 환경에서의 심박수 추정을 위해 특징 기반 회귀 모델을 활용하였다. PPG 신호는 움직임에 의해 쉽게 왜곡되는 특성이 있기 때문에, 단일 신호 기반 추정보다는 다양한 센서 정보와 특징을 결합한 모델링 접근이 필요하다. 이를 위해 본 연구에서는 PPG 신호에서 추출한 통계 및 주파수 특징과 함께 가속도 센서 기반 움직임 특징, 그리고 이전 심박수 및 활동 정보와 같은 컨텍스트 특징을 통합하여 심박수 추정 모델을 구성하였다.

제안된 모델은 각 시간 window에서 추출된 특징 벡터를 입력으로 받아 심박수를 회귀 방식으로 예측한다. 모델 학습에는 부스팅 기반의 LightGBM 회귀 모델을 사용하였으며, 다양한 특징 간의 비선형 관계를 효과적으로 학습할 수 있도록 하였다.

### 3-4 모델 학습 및 평가

모델 학습은 심박수 추정을 위한 회귀(regression) 문제로 정의되었으며, 학습 데이터셋을 이용하여 모델 파라미터를 최적화하였다.

모델의 성능 평가는 테스트 데이터셋을 이용하여 수행하였으며, 심박수 추정 정확도를 평가하기 위해 Mean Absolute Error (MAE), Root Mean Square Error (RMSE), 결정계수 ( $R^2$ ), 그리고 정규화된 Root Mean Square Error (NRMSE)를 평가 지표로 사용하였다.

### 3-5 모델 설명 가능성(Explainability) 분석

본 연구에서는 심박수 추정 모델에서 각 입력 특징이 예측 결과에 미치는 영향을 분석하기 위해 모델 설명가능성 분석을 수행하였다. LightGBM 모델은 학습 과정에서 각 특징이 분할 기준으로 사용된 빈도 및 정보 이득을 기반으로 특징 중요도(feature importance)를 산출할 수 있다.

이를 통해 심박수 추정에 기여하는 주요 특징을 정량적으로 분석할 수 있으며, 특히 PPG 기반 특징, 가속도 기반 움직임 특징, 그리고 이전 심박수 및 활동 정보와 같은 Temporal/Context 특징이 모델 성능 향상에 어떠한 역할을 하는지 평

가할 수 있다.

본 연구에서는 학습된 LightGBM 모델로부터 산출된 특징 중요도를 기반으로 상위 특징을 분석하고, 각 특징 유형이 심박수 추정에 미치는 영향을 비교하였다.

### 3-6 구성요소 분석

제안된 모델에서 각 센서 정보와 context 정보의 기여도를 분석하기 위해 구성요소 분석을 수행하였다.

본 연구에서는 1) PPG-only 모델, 2) PPG와 ACC 융합 모델 3) PPG와 ACC, Temporal/Context 정보를 모두 융합한 모델, 세 가지 모델을 비교하였다.

## IV. 실험 결과

제안하는 심박수 추정 시스템은 Python 3.10.9 환경에서 PyTorch 2.0.1 (CUDA 11.7) 프레임워크를 사용하여 구현되었다. 실험은 NVIDIA RTX A5000 GPU와 Intel Xeon Silver 4215R (3.20GHz) CPU가 탑재된 워크스테이션에서 수행되었으며, 총 32개의 CPU 스레드와 251GB RAM을 사용하였다.

### 4-1 융합 기법 기반 Heart Rate 추정 성능

표 1과 같이, 제안된 멀티모달 융합 기반 심박수 추정 모델은 MAE 5.029bpm, RMSE 7.263bpm, R<sup>2</sup> 0.8342, NRMSE 0.0912의 성능을 보였다. 이는 PPG와 ACC 센서, 그리고 Temporal/Context 정보를 통합한 특징 구성이 심박수 추정 성능 향상에 효과적임을 보여준다.

### 4-2 활동별 HR 추정 성능 분석

표 2와 같이, 활동 유형별 심박수 추정 오차를 분석한 결과, 활동에 따라 오차 수준의 차이가 나타났다. 특히 계단(Stairs)과 자전거(Cycling)와 같은 동작 강도가 높은 활동에서 비교적 높은 오차가 나타났으며, 이는 PPG 신호에 발생하는 motion artifacts의 영향으로 해석될 수 있다.

### 4-3 모델 특징 기여도 분석

표 3과 같이, 특징 중요도 분석 결과, ACC 기반 motion 특징(acc\_y\_mean, acc\_x\_mean, acc\_z\_mean)이 높은 중요도를 보였으며, prev\_hr 및 activity와 같은 Temporal/Context 정보 또한 상위 중요 특징으로 나타났다. 이는 심박수 추정에서 움직임 정보와 시간적 맥락 정보가 중요한 역할을 함을 시사한다.

### 4-4 제거 실험

표 4와 같이 모델 구성요소별 성능 변화를 분석한 결과,

PPG 단일 모델 대비 가속도 기반 motion 특징을 추가할 경우 MAE가 7.10bpm에서 5.64bpm으로 감소하여 유의한 성능 향상이 나타났다. 또한 여기에 Temporal/Context 특징을 추가한 제안 모델은 MAE 5.03bpm을 달성하여 추가적인 성능 개선을 보였다.

특히 PPG+ACC 모델 대비에서도 성능 향상이 관찰되는 점은, 단순한 센서 융합을 넘어 이전 심박수 및 활동 정보와 같은 Temporal/Context 특징이 심박수 추정 정확도 향상에 독립적으로 기여함을 시사한다.

표 1. 멀티모달 융합 기반 제안 심박수 추정 모델의 전체 성능  
Table 1. Overall performance of the proposed heart rate estimation model

Model	MAE (bpm)	RMSE (bpm)	R <sup>2</sup>	NRMSE
PPG + ACC + Context	5.029	7.263	0.8342	0.0912

표 2. 활동 유형별 심박수 추정 오차(MAE)  
Table 2. Activity-wise performance analysis

Activity	PPG+ACC+Temporal/Context
Transient	6.278
Sitting	2.019
Stairs	11.343
Table soccer	5.541
Cycling	5.219
Driving	5.215
Lunch	3.170
Walking	5.820
Working	3.693

표 3. 심박수 추정에 기여하는 주요 특징 중요도  
Table 3. Top important features for heart rate estimation

Rank	Feature	Feature Type	Importance
1	acc_y_mean	ACC motion	1494
2	prev_hr	Context	1267
3	activity	Context	1019
4	ppg_dom_freq_hz	PPG spectral	789
5	acc_x_mean	ACC motion	780
6	acc_z_mean	ACC motion	774
7	ppg_zcr	PPG signal quality	715
8	acc_mag_mean	ACC motion	618
9	acc_y_std	ACC motion	523
10	acc_mag_std	ACC motion	512

표 4. 모델 구성요소에 따른 성능 변화 분석  
Table 4. Ablation analysis of model components

Model Configuration	MAE (bpm)	RMSE (bpm)	Error Reduction (%)
Baseline	7.10	10.72	-
+ Motion features	5.64	8.37	20.6
+ Context features	5.03	7.26	29.2




그림 1. 심박수 추정 모델별 실제 심박수와 예측 심박수의 산점도 비교

Fig. 1. Scatter plots of true versus predicted heart rate for different models




그림 2. 기준 심박수와 추정 심박수 간의 일치도 평가를 위한 Bland-Altman 분석

Fig. 2. Bland-Altman plots for agreement analysis between reference and estimated heart rate

그림 1은 실제 심박수와 모델이 예측한 심박수 간의 관계를 나타낸 산점도이다. PPG 단일 모델에 비해 PPG와 ACC, Temporal/Context 정보를 결합한 모델에서 실제값과 예측값 간의 분포가 대각선에 더 밀접하게 분포하는 경향을 보이며, 이는 예측 정확도의 향상을 의미한다.

그림 2와 같이, Bland-Altman 분석을 통해 제안 모델과 기준 심박수 간의 일치도를 추가적으로 평가하였다.

PPG 단일 센서 모델의 경우 평균 편차(bias)는 1.92bpm으로 나타났으며, 일치 한계( $\pm 1.96$  SD)는  $-18.76$ bpm에서  $22.61$ bpm 범위로 비교적 넓게 분포하였다. PPG와 ACC 신호를 함께 활용한 모델에서는 평균 편차가 0.47bpm으로 감소하였고, 일치 한계 범위 역시  $-15.92$ bpm에서  $16.86$ bpm으로 축소되었다. 이는 가속도 센서 기반 움직임 정보를 활용함으로써 PPG 신호에 포함된 움직임 유래 잡음을 일부 보정할 수 있음을 시사한다. 또한 PPG, ACC 및 Temporal/Context 정보를 함께 활용한 확장 모델에서는 평균 편차가 1.32bpm으로 나타났으며, 일치 한계 범위는  $-12.69$ bpm에서  $15.32$ bpm으로 세 모델 중 가장 좁은 범위를 보였다. 다시 말해, 멀티센서 융합 및 context 정보 통합 모델은 PPG 단일 센서 모델에 비해 예측 오차의 분산을 감소시키고 기준 심박수와의 일치도를 향상시키는 경향을 보였다.

## V. 결론

본 논문에서는 웨어러블 PPG 기반 심박수 추정에서 발생하는 motion artifacts 문제를 완화하기 위해 멀티모달 센서 융합 기반 심박수 추정 기법을 제안하였다. 기존 PPG 기반 방식은 간편한 측정이 가능하다는 장점이 있으나, 신체 움직

임이 발생하는 환경에서는 신호 왜곡으로 인해 추정 정확도가 저하되는 한계를 가진다[13]-[15].

이를 해결하기 위해 본 연구에서는 PPG 특징과 ACC 기반 움직임 특징을 결합하고, 이전 심박수 및 활동 정보를 포함한 Temporal/Context 특징을 통합한 특징 기반 모델을 설계하였다. 또한 특징 중요도 분석과 구성요소 분석을 통해 각 특징이 심박수 추정에 미치는 영향을 체계적으로 평가하였다.

PPG-DaLiA 데이터셋을 활용한 실험 결과, 제안 모델은 MAE 5.029bpm, RMSE 7.263bpm,  $R^2$  0.834의 성능을 보였으며, PPG 단일 모델 대비 약 29%의 오차 감소를 나타냈다. 특히 계단과 자전거와 같은 고강도 활동에서 오차 감소가 두드러졌으며, 이는 ACC 기반 특징이 motion artifacts 완화에 기여함을 의미한다. 또한 ACC 특징과 이전 심박수, 활동 정보와 같은 Temporal/Context 특징이 중요한 역할을 수행함을 확인하였다.

이러한 결과는 멀티모달 센서 정보와 Temporal/Context 특징의 통합이 웨어러블 환경에서 심박수 추정 정확도를 향상시키는 데 효과적임을 보여준다. 또한 복잡한 딥러닝 구조 없이도 특징 기반 접근을 통해 비교적 단순한 구조로 구현 가능하다는 점에서 실용적인 적용 가능성을 제시한다.

본 연구에서는 subject-wise split을 적용하여 학습에 포함되지 않은 새로운 피험자에 대한 일반화 성능을 평가하였으며, 이는 실제 웨어러블 환경에서의 적용 시나리오를 반영한 설정이다. 다만 전체 피험자 수가 15명으로 제한되어 있어 LOSO 교차검증을 수행할 경우 피험자별 특성에 따른 성능 편차가 크게 나타날 수 있으며, 이에 따라 결과 해석의 안정성이 저하될 수 있다는 한계가 존재한다. 또한 본 연구는 심박수의 연속적 추정을 가정하는 웨어러블 기반 실시간 모니터링 환경을 전제로 하며, 이전 시점의 심박수 정보는 실제 적용 환경에서도 활용 가능한 정보라는 전제를 뒀다. 실제 환경에서는 초기 시점에서는 이전 심박 정보를 사용할 수 없는 경우가 존재한다.

결론적으로 향후 연구에서는 실제 이전 심박수 정보를 대체할 Context 정보에 관한 연구를 수행할 계획이며, 다양한 사용자 환경에서의 일반화 성능을 보다 정밀하게 평가하기 위해 LOSO 교차검증을 포함한 다각적인 subject-wise 평가를 수행할 계획이다. 또한 개인 간 생리적 차이를 반영한 개인화 모델링(personalized modeling) 기법을 적용하고, 앙상블 모델링을 통해 심박수 추정 성능을 추가적으로 향상시켜 다양한 웨어러블 센서 환경에서도 적용이 가능한 모델 구조로 확장하여 실제 헬스케어 시스템에 적용할 계획이다.

## 감사의 글

이 논문은 2023년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(No. RS-2023-00275579).

## 참고문헌

- [1] K. R. Arunkumar and M. Bhaskar, "Heart Rate Estimation from Photoplethysmography Signal for Wearable Health Monitoring Devices," *Biomedical Signal Processing and Control*, Vol. 50, pp. 1-9, April 2019. <https://doi.org/10.1016/j.bspc.2019.01.021>
- [2] D. Biswas, N. Simões-Capela, C. Van Hoof, and N. Van Helleputte, "Heart Rate Estimation from Wrist-Worn Photoplethysmography: A Review," *IEEE Sensors Journal*, Vol. 19, No. 16, pp. 6560-6570, August 2019. <https://doi.org/10.1109/JSEN.2019.2914125>
- [3] D. Hansen, K. Bonn , T. Alders, A. Hermans, K. Copermans, H. Swinnen, ... and P. Dendale, "Exercise Training Intensity Determination in Cardiovascular Rehabilitation: Should the Guidelines Be Reconsidered?," *European Journal of Preventive Cardiology*, Vol. 26, No. 18, pp. 1921-1928, December 2019. <https://doi.org/10.1177/2047487319859450>
- [4] A. G. Polak, B. Klich, S. Saganowski, M. A. Prucnal, and P. Kazienko, "Processing Photoplethysmograms Recorded by Smartwatches to Improve the Quality of Derived Pulse Rate Variability," *Sensors*, Vol. 22, No. 18, 7047, September 2022. <https://doi.org/10.3390/s22187047>
- [5] A. John, K. K. Nundy, B. Cardiff, and D. John, "Multimodal Multiresolution Data Fusion Using Convolutional Neural Networks for IoT Wearable Sensing," *IEEE Transactions on Biomedical Circuits and Systems*, Vol. 15, No. 6, pp. 1161-1173, December 2021. <https://doi.org/10.1109/TBCAS.2021.3134043>
- [6] J. Wang, M. Xia, Y. Xie, and C. Shi, "Multimodal Sensor Fusion-Based Lightweight Pedestrian Wearable System for Continuous Health Monitoring and Location Tracking," *IEEE Sensors Journal*, August 2025. <https://doi.org/10.1109/JSEN.2025.3593999>
- [7] H. Shi, B. Chikhaoui, and S. Wang, "Tree-Based Models for Pain Detection from Biomedical Signals," in *Proceedings of the International Conference on Smart Homes and Health Telematics*, Paris: France, pp. 183-195, June 2022. [https://doi.org/10.1007/978-3-031-09593-1\\_14](https://doi.org/10.1007/978-3-031-09593-1_14)
- [8] P. Batra, A. Kumar, R. Komaragiri, and M. Kumar, "A Review on Computation Methods Used in Photoplethysmography Signal Analysis for Heart Rate Estimation," *Archives of Computational Methods in Engineering*, Vol. 29, No. 2, pp. 921-940, 2022. <https://doi.org/10.1007/s11831-021-09597-4>
- [9] S. Ismail, U. Akram, and I. Siddiqi, "Heart Rate Tracking in Photoplethysmography Signals Affected by Motion Artifacts: A Review," *EURASIP Journal on Advances in Signal Processing*, Vol. 2021, 5, January 2021. <https://doi.org/10.1186/s13634-020-00714-2>
- [10] S. Puranik and A. W. Morales, "Heart Rate Estimation of PPG Signals with Simultaneous Accelerometry Using Adaptive Neural Network Filtering," *IEEE Transactions on Consumer Electronics*, Vol. 66, No. 1, pp. 69-76, February 2020. <https://doi.org/10.1109/TCE.2019.2961263>
- [11] A. J. Casson, A. V. Galvez, and D. Jarchi, "Gyroscope vs. Accelerometer Measurements of Motion from Wrist PPG During Physical Exercise," *ICT Express*, Vol. 2, No. 4, pp. 175-179, December 2016. <https://doi.org/10.1016/j.ict.2016.11.003>
- [12] A. Reiss, I. Indlekofer, and P. Schmidt, "PPG-DaLiA Dataset," *UCI Machine Learning Repository*, 2019. <https://doi.org/10.24432/C53890>
- [13] P. H. Lai and I. Kim, "Lightweight Wrist Photoplethysmography for Heavy Exercise: Motion Robust Heart Rate Monitoring Algorithm," *Healthcare Technology Letters*, Vol. 2, No. 1, pp. 6-11, February 2015. <https://doi.org/10.1049/htl.2014.0097>
- [14] B. Bent, B. A. Goldstein, W. A. Kibbe, and J. P. Dunn, "Investigating Sources of Inaccuracy in Wearable Optical Heart Rate Sensors," *npj Digital Medicine*, Vol. 3, 18, 2020. <https://doi.org/10.1038/s41746-020-0226-6>
- [15] P. H. Charlton, P. A. Kyriacou, J. Mant, V. Marozas, P. Chowienczyk, and J. Alastruey, "Wearable Photoplethysmography for Cardiovascular Monitoring," *Proceedings of the IEEE*, Vol. 110, No. 3, pp. 355-381, March 2022. <https://doi.org/10.1109/JPROC.2022.3149785>



이재혁 (Jaehyuk Lee)

2020년 : 고려대학교 보건과학대학원  
(이학박사-재활과학)

2023년 ~ 2024년 : 공주대학교 스마트기술연구소 연구교수  
2025년 ~ 현 재 : 서울과학기술대학교 IT융합기술연구소  
연구교수

※ 관심분야 : 디지털 헬스(Digital Health), 인공지능(Artificial Intelligence), 신호처리(Signal Processing)