

# ResNet 경량 구조에 의한 심전도 신호 분석 및 그 효과

백승민\*<sup>1</sup>, 문승현\*<sup>2</sup>, 박은상\*\*<sup>1</sup>, 반성범\*\*<sup>2</sup>

## ECG Signal Analysis by Lightweight ResNet Architecture and Its Effectiveness

Seung Min Baek\*<sup>1</sup>, Seung Hyun Moon\*<sup>2</sup>, Bak EunSang\*\*<sup>1</sup>, and Sung Bum Pan\*\*<sup>2</sup>

---

이 논문은 정부(교육부)의 재원으로 한국연구재단(No.NRF-2017R1A6A1A03015496)의 지원을 받아 수행된 연구임

---

### 요약

본 연구에서는 심전도(ECG) 신호의 1차원 시계열 정보를 효율적으로 분석하기 위한 딥러닝 구조의 경량 모델, 1-D ResNet Lite를 제안한다. 기존 ECG 분류 연구들이 장시간 신호 입력이나 과도한 네트워크 깊이로 인해 계산 복잡도가 증가하는 한계를 갖는 반면, 본 연구에서는 심장 박동 단위의 ECG 신호를 입력으로 사용하여 실시간 처리에 적합한 경량 신경망 구조를 구현하였다. 또한 1-D ResNet Lite를 ECG 신호 뿐만 아니라 생리학적 의미를 갖는 기하학적 형태의 특징 벡터도 처리하는 이중 구조로 설계하였다. CSU\_DB 데이터셋을 이용하여 남녀 분류 실험을 진행한 결과, 제안한 1-D ResNet Lite 모델은 CSU\_DB에서 최대 98.0%의 분류 정확도를 달성하였다. 이러한 결과는 ECG 기반 생체 인식 분류에 있어 1-D ResNet Lite의 효과성을 입증하였고, 웨어러블 디바이스나 임베디드 시스템과 같은 실제 응용 환경에 적용할 수 있는 가능성을 높였다.

### Abstract

This study presents a lightweight deep learning architecture, termed 1D ResNet Lite, for efficient analysis of one-dimensional (1D) ECG time-series signals. Unlike conventional ECG classification models that rely on long-duration inputs or excessively deep networks—leading to high computational costs—the proposed model utilizes heartbeat-level segments to enable real-time processing. Furthermore, 1D ResNet Lite contains two input modules that simultaneously process raw ECG signals and physiologically meaningful geometric feature vectors. Experimental evaluations on the CSU\_DB dataset demonstrate a classification accuracy of 98.0% for gender classification tasks. These results confirm the effectiveness of 1D ResNet Lite in ECG-based biometric classification and highlight its potential for deployment in real-world applications such as wearable devices and embedded systems.

### Keywords

lightweight ResNet, geometric feature vector, gender classification

---

\* 조선대학교 전자공학과

- ORCID<sup>1</sup>: <http://orcid.org/0009-0001-1454-2121>

- ORCID<sup>2</sup>: <http://orcid.org/0009-0004-6594-6304>

\*\* 조선대학교 IT연구소(공동교신저자)

- ORCID<sup>1</sup>: <http://orcid.org/0000-0002-5381-4206>

- ORCID<sup>2</sup>: <http://orcid.org/0000-0002-0960-5706>

· Received: Jan. 21, 2026, Revised: Mar. 09, 2026, Accepted: Mar. 12, 2026

· Co-corresponding Author: Sung Bum Pan

Research Institute of IT, Chosun university, Dong-Gu, Gwangju 61452 South Korea

Tel.: +82-62-230-6897, Email sbpan@chosun.ac.kr

· Co-corresponding Author: Bak EunSang

Research Institute of IT, Chosun university, Dong-Gu, Gwangju 61452

Tel.: +82-62-230-7855, Email bakeunsang@chosun.ac.kr

## I. 서 론

심전도 신호(ECG, Electrocardiogram)는 심장 박동에 따라 발생하는 전기적 활동을 시간에 따라 기록한 1차원 생체 신호로, 비침습적인 방식으로 측정이 가능하다는 장점으로 인해 임상 진단 뿐만 아니라, 다양한 생체 신호 분석 연구에서 널리 활용되고 있다. ECG 신호는 심장의 탈분극 및 재분극 과정에 의해 형성되는 주기적 파형 구조를 가지며, P, Q, R, S, T의 특징점을 중심으로 개인의 생리적 특성에 따라 형태적 차이를 보인다[1].

최근에는 ECG 신호에 포함된 형태적 정보를 효과적으로 학습하기 위해 심층 신경망 기반의 분석 방법이 활발히 연구되고 있다. 특히 1-D 시계열 형태의 원시 ECG 신호를 입력으로 사용하는 CNN(Convolutional Neural Network) 구조는 convolution 연산을 통해 신호의 형태적 특징을 자동으로 학습할 수 있어, 기존의 복잡한 수작업 기반의 특징 추출 과정에 대한 의존도를 줄일 수 있다는 장점이 있다[2]. 이러한 접근 방식이 분류 성능 측면에서 우수한 결과를 보였으나 대부분의 기존 연구에서 ResNet-18, ResNet-50과 같이 비교적 깊고 무거운 네트워크 구조를 사용함으로써 계산량 증가와 파라미터 과다 문제를 동반하였다[3].

ECG 신호는 본질적으로 1차원 저주파 생체 신호이며, 영상 인식에서 요구되는 수준의 깊은 네트워크 구조가 반드시 필요한 것은 아니다. 그럼에도 불구하고 기존 연구들에서는 성능 향상을 위해 과도하게 복잡한 모델 구조를 적용하는 경향이 있었으며, 이는 웨어러블 디바이스나 임베디드 시스템과 같은 실제 응용 환경에서의 활용에 제약 요인으로 작용한다[4]. 따라서 분류 성능을 유지하면서도 계산 효율을 크게 향상시킬 수 있는 경량화 신경망 구조에 대한 연구가 필요하다[5].

본 논문에서는 이러한 문제 의식을 바탕으로, 기존 ResNet-50 기반 모델과 비교하여 경량화된 1-D ResNet Lite 구조를 ECG 신호 분석에 적용하고, 두 모델 간의 계산량(FLOPs), 파라미터 수, 그리고 분류 성능을 체계적으로 비교 분석한다. 제안하는 1-D ResNet Lite 모델은 불필요한 네트워크 깊이를

제거하고, 1-D ECG 신호의 특성에 적합하도록 간결한 잔차(Residual) 구조를 기반으로 설계했다.

또한, 1-D ResNet Lite 모델을 기본 구조로 하여 ECG 신호로부터 추출 가능한 기하학적 특징 벡터를 보조 정보로 결합하는 구조로 확대하였다. 이를 통해 단순히 신경망 구조를 경량화하는 데 그치지 않고, 신호의 생리학적 특성을 반영한 저차원 특징 정보가 경량 모델의 분류 성능에 미치는 영향을 함께 분석하였다.

실험에는 자체 구축한 CSU\_DB를 사용하였으며, 데이터베이스에 대해 동일한 실험 조건 하에서 모델의 성능 및 계산 효율을 평가하였다. 본 연구는 ECG 신호의 한 주기만을 활용하여 분류 성능을 확보하면서도 계산 복잡도를 최소화하는 것을 핵심 목표로 한다. 이를 위해 경량 1-D ResNet Lite 구조를 제안하고, 기존 ResNet-50 기반 모델과의 성능 및 계산 효율을 비교 분석하였다.

본 논문의 구성은 다음과 같다. 2장에서는 ECG 신호 분석에 적용된 기존 심층 신경망 기반 방법과 경량화 연구에 대해 간략히 정리한다. 3장에서는 제안하는 1-D ResNet Lite 구조와 특징 벡터 결합 방식에 대해 설명하며, 4장에서는 CSU\_DB를 이용한 실험 결과를 통해 기존 ResNet-50 기반 모델과의 성능 및 계산량 비교 결과를 제시한다. 마지막으로 5장에서는 본 연구의 의의와 한계점을 분석하고, 향후 경량 ECG 분석 시스템으로의 확장 가능성을 논의한다.

## II. 관련 연구

### 2.1 ECG 신호 분석의 딥러닝 연구 동향

ECG 신호를 활용한 분류기 연구는 크게 심층 신경망(딥러닝) 기반 접근 방식과 전통적인 머신러닝 기반 접근 방식으로 구분할 수 있다. 초기 연구들은 심전도 신호에서 QRS 복합체, RR 간격, QT 간격과 같은 명시적인 특징을 추출한 뒤 SVM(Support Vector Machine), Random Forest, KNN(K-Nearest Neighbors) 등의 분류기를 적용하는 방식이 주를 이루었다[6]. 이러한 방법은 해석 가능성이 높고 연산

량이 적다는 장점이 있으나, 특징 설계 과정이 설계자 의존적이며 신호 품질 변화에 민감하다는 한계를 가진다. 이러한 한계로 인해 신호의 형태적 특성을 자동으로 학습할 수 있는 딥러닝 기반 접근 방식의 필요성이 제기되었다.

최근에는 원시 ECG 신호를 그대로 입력으로 사용하는 심층 신경망 기반 방법이 활발히 연구되고 있다[7][8]. 특히 1-D 합성곱 신경망(CNN)을 활용한 방식은 별도의 특징 설계 없이도 ECG 파형의 시간적 패턴을 자동으로 학습할 수 있다는 장점으로 인해 다양한 분류 및 인식 문제에 적용되고 있다[2]. 그러나 대부분의 연구에서 높은 분류 성능 확보를 위해 깊은 네트워크 구조를 사용함으로써 계산량 증가와 파라미터 과다 문제가 발생하고 있다. 한편, 성능 향상을 목적으로 ResNet-18, ResNet-50과 같은 깊은 잔차 신경망 구조를 ECG 분석에 그대로 적용하는 연구들도 다수 보고되었다[3][9]. 이러한 모델들은 높은 분류 정확도를 달성하였으나, 수백만 개 이상의 파라미터와 높은 계산량을 요구하여 실제 임베디드 환경이나 웨어러블 디바이스 적용에는 제약이 따른다[10]. ECG 신호는 본질적으로 1차원 저주파 시계열 데이터임에도 불구하고 영상 인식에 최적화된 깊은 네트워크 구조가 그대로 사용된다는 점에서 효율성 측면의 한계가 존재한다.

따라서 ECG 신호의 특성을 고려한 경량화 신경망 구조에 대한 필요성이 대두되고 있으며, 성능 저하를 최소화하면서 계산량과 파라미터 수를 효과적으로 감소시키는 방향의 연구가 요구된다. 본 논문에서는 이러한 한계를 해결하기 위해 ECG 신호의 1차원 시계열 특성에 최적화된 경량 신경망 구조인 1-D ResNet Lite를 제안하고, 기존 ResNet-50 기반 모델과의 비교를 통해 계산 효율성과 분류 성능을 동시에 향상시킬 수 있음을 실험적으로 검증하고자 한다.

### III. 제안하는 방법

#### 3.1 DB 및 데이터셋 선정

심전도 신호를 분석하기 위한 공용 데이터베이스는 주로 질환 진단 목적으로 구축되어 있으나, 일부 DB(Database)는 정상인의 신호를 포함하고 있어 인공 지능 기반의 분류 연구에 활용될 수 있다. 본 연구에서는 생리적 특성 분석을 위해 정상 심전도 데이터를 제공하는 데이터베이스인 조선대학교 IT연구소 자체 수집 데이터(CSU\_DB)[11]을 선정하여 실험을 진행하였다.

해당 데이터는 총 64명(남성 39명, 여성 25명)으로 구성되어 있으며, 각 신호는 30초 동안 2000 Hz의 샘플링 주파수로 기록되었다. 고해상도 샘플링을 통해 심전도 파형의 미세한 형태적 특성을 정밀하게 분석할 수 있다는 장점이 있다.

본 연구에서 인공 지능 모델의 효과적인 학습을 위해 심전도 신호를 심장 박동 주기(Beat) 단위로 분할하여 사용하였으며 이를 위한 절차는 다음과 같다. 심전도 신호의 심장 박동 주기 분할을 위해 NeuroKit 라이브러리[12]를 사용하여 각 신호에서 P, Q, R, S, T 지점을 자동으로 검출하였다. 검출된 PQRST 지점에 해당하는 위치에는 텍스트 기반 라벨(P, Q, R, S, T)을 원본 심전도 신호 파일 내부에 삽입하였으며, 해당 라벨 정보를 기반으로 심장 박동 주기 단위의 구간 추출을 수행하였다. 구간 정의 시 R점을 기준점으로 설정하고, 하나의 심장 박동 구간을 P점과 R점 사이 구간과 R점과 T점 사이 구간으로 분할하여 각각의 거리를 기준으로 사용하였다. 또한 P점 및 T점 지점 검출 오차에 따른 파형 정보 손실을 방지하고 박동 주기 경계의 안정성을 확보하기 위해 ECG 파형을 구성하는 샘플 수 기준으로 P점 이전과 T점 이후에 각각 50샘플의 마진을 추가하였다. 이에 따라 하나의 심장 박동 주기는 P점 이전 마진(50샘플), P점-R점 사이의 샘플 수, T점-R점 사이의 샘플 수, T점 이후 마진(50샘플)로 구성되었으며 총 1134개 샘플로 구성된 심장박동 주기로 분할하였다. 결과적으로 이와 같은 절차를 통해 총 26,806개의 심장 박동 데이터가 생성되었다.

#### 3.2 특징 벡터 추출

본 논문에서는 심전도 신호에서 검출한 P, Q, R, S, T점들을 기반으로 기하학적 도형을 구성해 특징 벡터를 추출하는 방식을 활용한다. 특징 벡터 추출 방식은 P, Q, R, S, T점을 포함한 특징점의 위치와 진폭 등을 포함하는 방식이다. 추출하는 특징 벡터는 5가지 형태로 QRS 삼각형 면적, ST 삼각형 면적, S-T 삼각형 각도, Q-R-T 삼각형의 각도, QT 간격이다.




그림 1. 특징 벡터(좌측에서부터 QRS 삼각형 면적, ST 삼각형 면적, S-T 삼각형 각도)

Fig. 1. Extraction of geometric feature vectors (from left: QRS area, ST area, and S-T angle)




그림 2. 특징 벡터(좌측에서부터 Q-R-T 삼각형의 각도, QT 간격)

Fig. 2. Extraction of geometric feature vectors (from left: Q-R-T angle, QT interval)

그림 1은 QRS 삼각형 면적, ST 삼각형 면적, S-T 삼각형 각도의 기하학적 형태를 나타내고 그림 2는 Q-R-T 삼각형의 각도, QT 간격의 기하학적 형태를 나타낸다. QRS 삼각형 면적은 남자가 여자보다 일반적으로 R심장 박동 주기로 추출하는 점의 높이가 더 높고 QRS 복합체(QRS duration)의 에너지가 더 크기 때문에 남자가 더 크게 나타나는 특성을 이용한다. ST 삼각형 면적은 남성 호르몬(테스토스테론)의 영향으로 남자는 초기 재분극 단계에서 ST 구간이 위로 오목하게 들리게 된다. 이로 인해 ST 구간에서 형성되는 삼각형의 높이와 면적이 여자보다 크게 나타나는 특성을 이용한다. S-T 삼각형 각도는 남자가 S점에서 T점의 변곡점까지 이어

지는 각도가 여자에 비해 더 급격하고 가파르게 형성되는 특성을 이용한다. Q-R-T 삼각형의 각도는 남자가 Q점에서 R점까지 도달하는 진폭이 훨씬 높기 때문에 남자가 여자보다 더 가파르게 나타나는 특성을 이용한다. QT 간격은 가장 대표적인 성별 차이 지표이며 심실의 재분극 과정에서 여성 호르몬(에스트로젠)의 영향으로 여자가 남자보다 더 느리게 진행된다. 이때 QT간격이 여자가 더 길어지게 되는 특성을 이용한다.

본 연구에서 선택한 다섯 가지 특징 벡터는 CSU\_DB 데이터를 대상으로 한 사전 분석을 통해 남녀 간 형태적 차이를 크게 나타내는 지표를 기준으로 선정하였다. QRS 면적과 QT 간격은 기존 의학 및 생체신호 분석 연구에서 성별 간 생리학적 차이를 반영하는 대표적인 지표로 널리 활용되어 왔다. 반면 ST 면적, S-T 각도, Q-R-T 각도는 PQRST 특징점 기반의 형태적 차이를 반영하기 위해 본 연구에서 정의한 기하학적 특징으로, CSU\_DB에서 남녀 간 분포 차이가 크게 나타난 지표를 중심으로 구성하였다.

### 3.3 1-D 신호를 이용한 심층 신경망 설계

기존 ResNet 모델은 2-D 영상 인식을 목적으로 설계된 구조이나, ECG 신호는 1-D 시계열 데이터이므로, 본 연구에서는 2-D CNN을 1-D CNN 연산으로 변형하고 잔차 구조를 유지하며 채널 수와 네트워크 깊이를 축소하여 계산량과 파라미터 수를 감소시킨 ResNet Lite 신경망을 설계하였다.

#### 3.3.1 입력 심전도 신호

모델의 입력으로 사용되는 심전도 신호는 심장 박동 단위로 분할된 1-D 시계열 데이터이며, 데이터셋 구성 단계에서 사전에 고정된 길이로 정규화되어 있다. 사용되는 데이터 셋에 따라 입력 심전도 신호의 길이는 상이할 수 있으나, 각 실험에서는 동일한 길이의 신호만을 사용하여 학습 및 평가를 수행하였다.

### 3.3.2 1-D ResNet 기반 파형 특징 추출

제안한 1-D ResNet Lite 구조는 ECG 신호의 1-D 시계열 특성과 주기성을 고려하여 설계되었다. 일반적인 2-D ResNet 구조는 고차원 공간 특징 학습을 위해 깊은 네트워크와 많은 채널 수를 요구하지만, ECG 데이터는 구조가 비교적 단순하고 시간축 기반의 형태 정보가 중요한 신호이므로 과도한 네트워크 깊이가 반드시 필요하지 않다. 이에 본 연구에서는 필수적인 잔차 구조를 유지하면서 네트워크 깊이와 채널 수를 단계적으로 축소하여 계산량과 파라미터 수를 감소시킨 경량 1-D ResNet Lite 구조를 설계하였다. 제안한 네트워크는 초기 1-D convolution layer를 포함한 총 9개의 convolution layer와 3개의 residual block으로 구성되며, 각 block은 두 개의 convolution 연산과 identity shortcut을 포함한다[13]. 이러한 구조는 심전도 파형의 국소적 변화와 박동 단위의 전역적 형태 정보를 안정적으로 학습할 수 있도록 하며, 추출된 파형 특징은 Adaptive Average Pooling을 통해 하나의 고정 차원 벡터로 통합된다. 결과적으로 제안한 구조는 ECG 신호의 형태적 특징을 효과적으로 반영하면서도 불필요한 계산량 증가를 억제할 수 있도록 설계되었다.

### 3.3.3 파형 기반 특징과 기하학적 특징의 결합

ECG 데이터를 CNN에 통과시켜 얻은 파형 기반 특징을 보완하기 위한 목적으로 앞 절에서 정의한 기하학적 특징 벡터를 이용하였다. 이 방법은 PQRST 점이 명확하게 검출되는 고품질 심전도 신호에 한하여 적용하였다. 기하학적 특징 벡터는 별도의 fully connected projection layer를 통해 파형 기반 특징과 동일한 차원으로 변환되며, 이를 통해 분류 성능이 어느 한 쪽에 의해 과도하게 영향을 받는 것을 방지하였다. 파형 기반 CNN 특징과 기하학적 특징 벡터는 concatenation을 통해 하나의 통합 특징인  $z$ 로 결합된다. 결합된 특징 벡터는 fully connected layer를 통해 192차원에서 64차원의 은닉 표현으로 변환되며, 이 과정에서 ReLU 활성화 함수

와 Dropout이 적용된다. 이후 또 다른 FC(Fully Connected) layer를 통해 1차원의 출력값이 생성되며, 해당 출력값은 sigmoid 함수( $\sigma$ )를 통해 최종 이진 분류 확률로 변환된다. 이 과정은 식 (1)과 같이 표현할 수 있다.

$$\hat{y} = \sigma(W_2(ReLU(W_1z + b_1)) + b_2) \quad (1)$$

$W_1$ 과  $b_1$ 은 결합된 특징 벡터를 64차원의 은닉 표현으로 변환하는 fully connected layer의 가중치와 편향을 의미하며,  $W_2$ 과  $b_2$ 는 해당 은닉 표현을 기반으로 최종 이진 분류를 수행하는 fully connected layer의 가중치와 편향을 의미한다.

### 3.3.4 모델 학습 방법

본 연구에서는 앞서 제시한 절차를 통해 생성된 심장 박동 단위 데이터를 이용하여 모델 학습을 수행하였다. 직접 구축한 데이터베이스로부터 26,806개의 심장 박동 데이터를 생성하였으며 모델 학습을 위한 데이터 분할은 학습 70%, 검증 15%, 테스트 15%의 비율로 수행하였다. 성별에 따른 데이터 수 불균형 문제는 인공 지능 학습 성능 저하의 주요 요인이 될 수 있으므로, 데이터 증강 기법은 사용하지 않고, 데이터 분할 과정에서 학습, 검증, 테스트 데이터 전반에 걸쳐 남성과 여성 심장 박동 데이터의 비율이 동일하게 유지되도록 구성하였다. 모델 학습에는 BCE(Binary Cross-Entropy) 기반 손실 함수를 사용하였으며, 클래스 불균형을 완화하기 위해 여성 심장 박동 데이터에 대한 가중치를 적용하였다. 이를 통해 소수 클래스에 해당하는 여성 심장 박동 데이터의 오분류에 대해 더 큰 패널티를 부여함으로써 학습 편향을 완화하였다. 최적화 기법으로는 AdamW optimizer를 사용하였고, 학습률 스케줄링을 위해 Cosine Annealing 기법을 적용하였다. 이러한 학습 전략을 통해 별도의 데이터 증강 과정 없이도 성비 불균형 환경에서도 안정적인 인공지능 학습이 가능하도록 하였다. 이와 같이 ResNet을 기반으로 한 1-D ResNet lite 구조는 그림 3, 4와 같다.

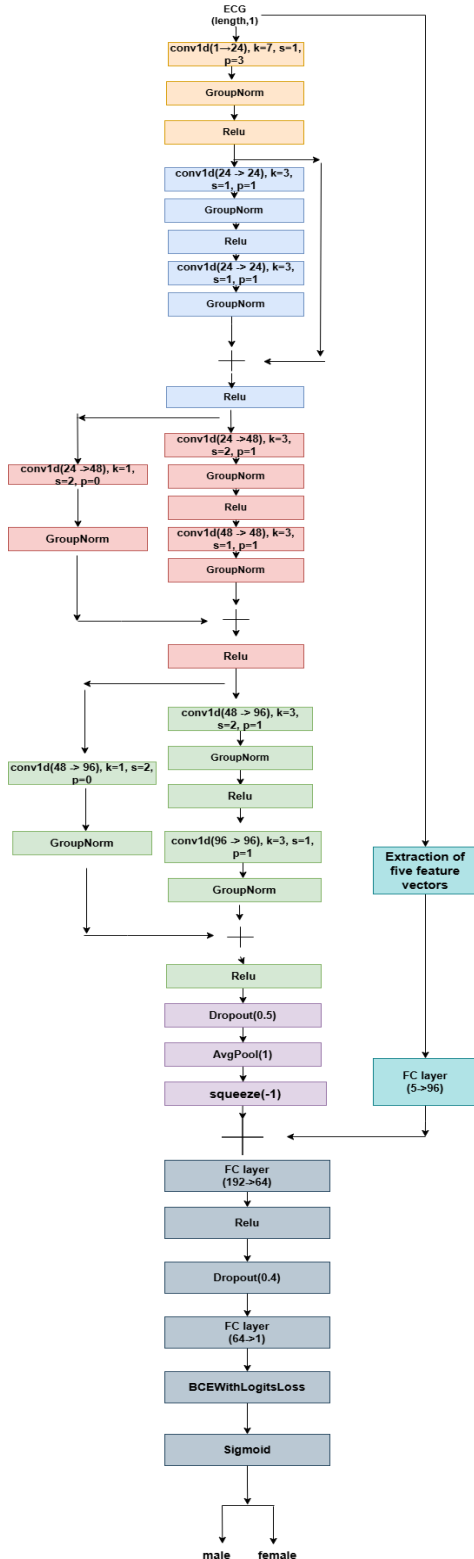


그림 3. 1-D ResNet Lite 구조도  
Fig. 3. Architecture of the 1-D ResNet Lite

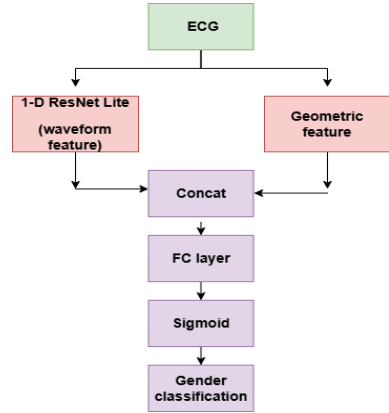


그림 4. 제안하는 ECG 성별 분류 시스템의 전체 흐름도  
Fig. 4. Overall flowchart of the proposed ECG gender

### IV. 실험 결과

#### 4.1 특징 벡터에 의한 남녀 변별력 검증

먼저, 제안하는 특징 벡터가 어떻게 남자와 여자의 차이를 구분하는 특성을 갖는지 CSU\_DB를 사용하여 변별력을 검증하였다. 추출한 특징 벡터의 개별특성은 박스플롯(Box-plot)을 사용하였고, 이를 통해 남자와 여자의 생리적 차이(호르몬, 심실 두께, 근육량 등)를 비교할 수 있다.

그림 5는 5가지의 특징 벡터에 대해 남녀 특징 차이를 비교한 박스플롯이다. QRS 면적, ST 면적, ST 각도는 남성에서 더 크게 나타났으며, QT 간격과 QRT 각도는 여성에서 더 큰 분포를 보였다. 이는 각 특징 벡터가 성별 간 형태적 차이를 반영하고 있음을 보여준다. 그러나 각 특징 벡터의 분포가 일부 구간에서 중첩되는 양상을 보이므로, 단일 특징만으로는 남녀를 완전히 구분하기에는 한계가 존재한다. 이는 심전도 신호가 개인 간 생리적 변동성과 측정 환경의 영향을 동시에 받는 생체 신호라는 특성에 기인한다. 따라서 기하학적 특징 벡터만을 단독으로 사용할 경우 완전한 변별력을 확보하기 어렵고, 파형 전체의 시간적 패턴과 형태 정보를 함께 고려할 필요가 있다. 이러한 한계를 보완하기 위해 본 연구에서는 CNN 기반 파형 특징 추출 결과와 기하학적 특징 벡터를 결합하는 이중 입력 구조를 적용하였으며, 이를 통해 단일 특징 기반 분류의

한계를 보완하고 보다 안정적인 성별 분류 성능을 확보하고자 하였다.

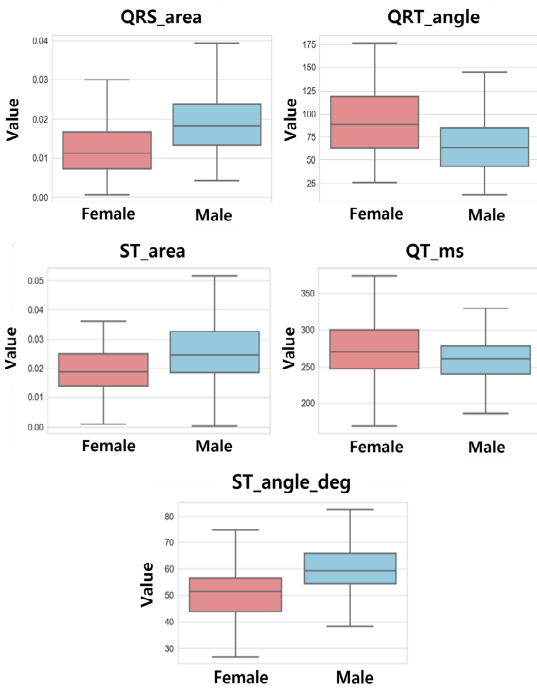


그림 5. 남자와 여자의 차이를 구분하는 박스플롯 (좌측에서부터 QRS 면적, QRT 각도, ST 삼각형 면적, QT 간격, ST 삼각형 각도)

Fig. 5. Box plots comparing the ECG feature vectors between male and female groups (from left to right: QRS triangle area, QRT angle, ST triangle area, QT interval, and ST triangle angle)

#### 4.2 1-D ResNet 모델 성능 비교

표 1. ResNet 기반 모델의 분류 성능 비교

Table 1. Performance comparison of ResNet-based models

Dataset	Model	Morphology	Epoch	Accuracy
CSU_DB	1-D ResNet-50	1-D Waveform	85	90.6%
	1-D ResNet lite	1-D Waveform	85	98.4%

표 2. 특징 벡터 결합 여부에 따른 1-D ResNet Lite 성능 비교

Table 2. Performance comparison of 1-D ResNet Lite with and without feature vectors

Dataset	Model	Feature Vector	Epoch	Accuracy
CSU_DB	1-D ResNet lite	X	85	98.4%
	1-D ResNet lite	O	80	98.7%

표 1은 CSU\_DB를 대상으로 1-D ResNet-50과 1-D ResNet Lite 모델의 분류 성능을 비교한 결과를 나타낸다. 1-D ResNet Lite는 85 epoch 이후에 98.4%의 정확도를 기록하며 동일한 epoch에서 90.6%의 정확도를 보인 1-D ResNet-50 대비 크게 향상된 성능을 나타냈다. 이는 ECG 신호가 영상 데이터와 달리 비교적 명확한 주기성과 형태적 패턴을 갖는 1-D 신호이기 때문에, 과도하게 깊은 네트워크 구조 없이도 핵심 특징을 충분히 학습할 수 있기 때문으로 판단된다. 또한 ResNet-50과 같은 깊은 구조는 파라미터 수 증가와 함께 과적합 가능성을 높일 수 있으며, 본 연구에서 사용한 CSU\_DB와 같은 고품질 ECG 데이터 환경에서는 오히려 경량 구조가 더 안정적인 일반화 성능을 보일 수 있음을 확인하였다.

#### 4.3 특징 벡터 결합에 따른 성능 변화

표 2는 1-D ResNet Lite 모델에 특징 벡터를 결합했을 때의 성능 변화를 나타낸다. 특징 벡터를 결합하지 않은 1-D ResNet Lite는 85 epoch에서 98.4%의 정확도를 기록한 반면, 특징 벡터를 결합한 모델은 80 epoch에서 98.7%의 정확도를 달성하였다. 이는 특징 벡터 결합을 통해 학습 epoch가 감소하여 학습이 빠르게 진행됐고 동시에 분류 성능이 소폭 향상되었음을 의미하며 이를 통해 특징 벡터가 CNN 기반 과형 표현의 한계를 보완하여, 보다 안정적인 분류 성능을 제공함을 확인할 수 있었다.

표 3. 1-D ResNet 기반 모델의 계산량 및 파라미터 수 비교

Table 3. Comparison of model complexity and performance of 1-D ResNet models

Model	Dataset	Params	FLOPs	Accuracy
1-D ResNet lite	CSU_DB	74,217	$4.74 \times 10^7$	98.7%
1-D ResNet-50	CSU_DB	16,032,321	$1.78 \times 10^9$	90.6%

#### 4.4 시스템별 계산량 비교 및 경량화

본 절에서는 제안한 1-D ResNet Lite 모델과 기존 1-D ResNet-50 모델을 대상으로, CSU\_DB 환경에서의 파라미터 수, 연산량(FLOPs), 그리고 분류 성능을 비교하여 시스템 관점에서의 계산 효율성과 경량화 효과를 분석한다. 각 모델의 정량적 비교 결과는 표 3에 제시되어 있다.

1-D ResNet Lite 모델은 약 74,217개의 파라미터와  $4.74 \times 10^7$  FLOPs 수준의 계산량을 요구하면서도 98.7%의 높은 분류 정확도를 달성하였다. 반면, 동일한 데이터셋을 대상으로 한 1-D ResNet-50 모델은 16,032,321개의 파라미터와  $1.78 \times 10^9$  FLOPs에 달하는 연산량을 필요로 하였으며, 분류 정확도는 90.6%에 그쳤다. 이는 파라미터 수 기준으로 약 216배, 연산량 기준으로 약 37배 이상의 차이가 존재함에도 불구하고, 경량 모델이 오히려 더 우수한 분류 성능을 보였음을 의미한다. CSU\_DB는 비교적 제한된 데이터 규모와 명확한 주기성을 갖는 1-D 신호로 구성되어 있어, 수천만 개 이상의 파라미터를 갖는 깊은 네트워크 구조를 충분히 학습시키기에는 데이터 다양성이 제한적이다. 이로 인해 ResNet-50과 같은 과도하게 깊은 구조는 학습 데이터에 대한 과적합(Overfitting)이 발생하거나, 불필요하게 복잡한 특징 표현을 형성하여 오히려 일반화 성능이 저하될 가능성이 있다. 반면 제안한 1-D ResNet Lite 구조는 ECG 신호의 특성과 데이터 규모를 고려한 경량 설계를 통해 모델 복잡도와 데이터 표현 간의 균형을 유지함으로써 보다 안정적인 일반화 성능을 확보한 것으로 판단된다.

#### V. 결론 및 향후 과제

본 논문에서는 ECG 신호 분석을 위한 1-D

ResNet Lite 모델을 제안하고, 기존의 깊은 1-D ResNet-50 모델과 비교하여 계산 효율성과 분류 성능을 종합적으로 분석하였다. 제안한 1-D ResNet Lite 모델은 CSU\_DB 데이터셋을 대상으로 실험을 수행하였으며, 적은 파라미터 수와 낮은 연산량에도 불구하고 기존 모델 대비 우수한 분류 성능을 달성함을 확인하였다. 특히 기존의 ResNet-50 기반 ECG 분류 연구와 비교할 때, 제안한 1-D ResNet Lite 모델은 더 적은 파라미터와 연산량으로도 더 높은 분류 정확도를 달성하였다. 이는 기존의 깊은 네트워크 기반 접근 방식 대비 계산 효율성과 분류 성능을 동시에 향상시킨 결과로, 본 연구에서 제안한 경량 모델 구조의 우수성을 명확히 보여준다.

실험 결과, 동일한 CSU\_DB 환경에서 기존 ResNet-50 모델의 분류 정확도는 90.6% 수준이었으나, 제안한 1-D ResNet Lite 모델은 98.7%의 분류 정확도를 달성하여 성능이 크게 향상되었다. 또한 파라미터 수와 연산량(FLOPs) 측면에서도 각각 약 200배 및 30배 이상 감소하여 계산 효율성과 분류 성능을 동시에 향상시킨 결과를 보였다. 이는 1-D ECG 신호의 구조적 특성상 과도한 네트워크 깊이가 반드시 성능 향상으로 이어지지 않으며, 핵심적인 파형 패턴을 효율적으로 추출할 수 있는 경량 구조가 더 적합함을 의미한다. 또한, 본 연구에서는 기하학적 feature vector를 1-D ResNet Lite 구조에 결합함으로써 CNN 기반 파형 표현의 한계를 보완하였다. 그 결과, feature vector를 결합한 모델은 더 적은 학습 epoch에서 수렴하면서도 분류 성능이 추가적으로 향상되는 경향을 보였다. 이는 심전도 신호에 내재된 생리학적 특성을 명시적으로 반영하는 것이 경량 CNN 기반 분류 시스템의 성능과 학습 효율을 동시에 개선할 수 있음을 실험적으로 입증하였다. 종합적으로, 본 연구에서 제안한 1-D ResNet Lite 기반 경량 모델과 feature vector 결합 방식은

ECG 신호 분석을 위한 효과적인 설계 전략으로, 높은 분류 성능과 계산 효율을 동시에 만족한다. 특히 단일 심장 박동 단위의 입력만으로도 안정적인 분류가 가능하다는 점에서, 본 시스템은 자원이 제한된 환경, 실시간 처리가 요구되는 임베디드 시스템, 웨어러블 디바이스, 생체 인증 및 헬스케어 응용 분야에 높은 활용 가능성을 지닌다[10]. 향후 연구에서는 본 모델을 다양한 생체 신호(예: PPG, EMG)로 확장하여 범용성을 검증하고, 경량 모델의 실시간 추론 성능을 실제 임베디드 하드웨어 환경에서 평가할 예정이다. 또한, feature vector의 자동 추출 및 선택 기법을 도입하여 모델의 일반화 성능을 더욱 향상시키고, 데이터 품질 변화에 따른 강건성을 확보하는 방향으로 연구를 확장할 계획이다.

## References

- [1] S. R. Lee, J. I. Choi, K. N. Lee, H. S. Park, and Y. H. Kim, "Gender Differences in P-wave Signal-averaged ECG: Association with Atrial Fibrillation", *International Journal of Arrhythmia*, Vol. 16, No. 2, pp. 69-76, Jun. 2015. <https://doi.org/10.4070/kcj.2007.37.12.656>.
- [2] Z. Wang, W. Yan, and T. Oates, "Time series classification from scratch with deep neural networks: A strong baseline", *Proc. Int. Joint Conf. Neural Networks (IJCNN)*, Anchorage, AK, USA, pp. 1578-1585, May 2017. <https://doi.org/10.1109/IJCNN.2017.7966039>.
- [3] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition", *Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, pp. 770-778, Jun. 2016. <https://doi.org/10.1109/CVPR.2016.90>.
- [4] M. Kolhar and A. M. A. Rajeh, "Deep learning hybrid model ECG classification using AlexNet and parallel dual branch fusion network model", *Scientific Reports*, Vol. 14, Art no. 26919, Nov. 2024. <https://doi.org/10.1038/s41598-024-78028-8>.
- [5] M. Hammad, S. Meshoul, P. Dziwiński, P. Plawiak, I. A. Elgendy, "Efficient Lightweight Multimodel Deep Fusion Based on ECG for Arrhythmia Classification", *Sensors* 2022, Vol. 22, No. 23, Art no. 9347, Dec. 2022. <https://doi.org/10.3390/s22239347>.
- [6] N. H. Arif, M. R. Faisal, A. Farmadi, D. T. Nugrahadi, F. Abadi, and U. A. Ahmad, "An Approach to ECG-based Gender Recognition Using Random Forest Algorithm", *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, Vol. 6, No. 2, pp. 107-115, Apr. 2024. <https://doi.org/10.35882/jeeemi.v6i2.363>.
- [7] M. Kachuee, S. Fazeli, and M. Sarrafzadeh, "ECG heartbeat classification: A deep transferable representation", *Proc. IEEE Int. Conf. Healthcare Informatics (ICHI)*, New York, USA, pp. 443-444, Jun. 2018. <https://doi.org/10.1109/ICHI.2018.00092>.
- [8] S. Hong, J. Lee, and H. Kim, "Deep learning-based ECG classification: A review", *Biomedical Signal Processing and Control*, Vol. 84, Art No. 104777, May 2023. <https://doi.org/10.1016/j.bspc.2023.104777>.
- [9] L. Zhao, et al., "ECG Heartbeat Classification Based on an Improved ResNet-18", *Circulation: Arrhythmia and Electrophysiology*, Vol. 14, No. S1, pp. 6649970-6649982, May 2021. <https://doi.org/10.1155/2021/6649970>.
- [10] T. Sadad, M. Safran, I. Khan, S. Alfarhood, R. Khan, and I. Ashraf, "Efficient Classification of ECG Images Using a Lightweight CNN with Attention Module and IoT", *Sensors* 2023, Vol. No. 18, Art no. 7697, Sep. 2023. <https://doi.org/10.3390/s23187697>.
- [11] CSU\_DB, <https://www.chosun.ac.kr/user/indexSub.do?codyMenuSeq=937215851&siteId=riit>. [accessed: Sep. 25, 2025]
- [12] D. Makowski, et al., "NeuroKit2: A Python toolbox for neurophysiological signal processing", *Behavior Research Methods*, Vol. 53, No. 4, pp. 1689-1696, Aug. 2021. <https://doi.org/10.3758/s13428-020-01516-y>.

[13] K. He, X. Zhang, S. Ren, and J. Sun, "Deep Residual Learning for Image Recognition", Proc. IEEE Conf. Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, pp. 770-778, Jun. 2016. <https://doi.org/10.1109/CVPR.2016.90>.

저자소개

반 성 범 (Sung Bum Pan)



1999년 2월 : 서강대학교  
전자공학과(공학박사)  
2005년 2월 : 한국전자통신연구원  
정보보호연구단 생체인식기술  
연구팀 팀장  
2005년 3월 ~ 현재 : 조선대학교  
전자공학과 교수

관심분야 : 영상처리, 바이오인식, VLSI 신호처리

백 승 민 (Seung Min Baek)



2026년 2월 : 조선대학교  
전자공학과(공학사)  
관심분야 : 생체신호처리, 인공지능

문 승 현 (Seung Hyun Moon )



2026년 2월 : 조선대학교  
전자공학과(공학사)  
관심분야 : 생체신호처리, 인공지능

박 은 상 (Bak EunSang)



1992년 2월 : 서강대학교  
전자공학과(학사)  
1994년 2월 : 서강대학교  
전자공학과(석사)  
2004년 8월: Univ. of North  
Carolina at Charlotte.(공학박사)  
2018년 3월 ~ 현재 : 조선대학교

IT연구소 연구교수

관심분야 : 패턴인식, 인공지능, 생체신호처리