

## 딥러닝 모델을 이용한 실시간 부정맥 감지 이중화 모바일 시스템

김 세 진<sup>1</sup> · 이 현 주<sup>2</sup> · 박 라 영<sup>3</sup> · 원 용 관<sup>4\*</sup>

<sup>1</sup>전남대학교 컴퓨터정보통신공학과 연구원

<sup>2</sup>전남대학교 지능전자컴퓨터공학 석·박사통합과정

<sup>3</sup>전남대학교 BIT융합기술사업단 연구교수

<sup>4</sup>전남대학교 컴퓨터정보통신공학과 교수

## Duplexing Mobile System for Real-time Arrhythmia Detection Using a Deep Learning Model

Sejin Kim<sup>1</sup> · Heonzoo Lee<sup>2</sup> · Rayoung Park<sup>3</sup> · Yonggwon Won<sup>4\*</sup>

<sup>1</sup>Researcher, Department of Computer Engineering, Chonnam National University, Gwangju 61186, Korea

<sup>2</sup>Ph.D. Candidate, Department of Intelligent Electronics and Computer Engineering, Chonnam National University, Gwangju 61186, Korea

<sup>3</sup>Research Professor, BIT Fusion Technology Center, Chonnam National University, Gwangju 61186, Korea

<sup>4</sup>Professor, Department of Computer Engineering, Chonnam National University, Gwangju 61186, Korea

### [요 약]

본 연구에서는 웨어러블 심전도 센서 디바이스, 휴대형 스마트폰, 그리고 심전도 정밀분석 서버를 통합한 시스템을 제안한다. 이 시스템은 딥러닝 모델을 활용하여 부정맥 발생 징후를 실시간으로 감지하고 스마트폰으로 경고 알림을 전송하며 서버와의 통신 장애 시에도 스마트폰에 탑재된 경량 판별시스템을 통해 이중으로 감지 기능을 제공한다. 또한, 부정맥 감지에 중요한 R-peak 감지 알고리즘, 부정맥 감지를 위한 CNN 모델과 False Negative를 최소화하기 위한 딥러닝 모델의 출력에 대한 임계값 조정 방법을 제안한다. 따라서, 제안하는 시스템을 이용하면 부정맥 진단의 효율성을 향상시킬 수 있다.

### [Abstract]

In this study, a system is introduced that integrates a wearable electrocardiogram (ECG) sensor device, a portable smartphone, and a server that performs accurate ECG analysis. The system that performs accurate analysis on ECG signals detects the most important signs of arrhythmia using a deep learning model and transmits warning notifications to the portable smartphone. The system continues detection using a small-scale lightweight detection analysis system in case of communication failure with the ECG analysis server system. In addition, we introduce an algorithm for R-peak detection of ECG signals—which is essential for the detection of arrhythmia—a CNN model specifically designed for this purpose, and a method of adjusting the threshold for the output of the deep learning model. Therefore, using the proposed system, the efficiency of arrhythmia diagnosis can be improved.

**색인어** : 심전도, R-피크, 신호분석, 딥러닝, 부정맥

**Keyword** : Electrocardiogram (ECG), R-Peak, Signal Analysis, Deep Learning, Arrhythmia

<http://dx.doi.org/10.9728/dcs.2024.25.12.3743>



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** 18 November 2024; **Revised** 28 November 2024

**Accepted** 10 December 2024

**\*Corresponding Author; Yonggwon Won**

**Tel:** +82-62-530-1804

**E-mail:** ykwon@jnu.ac.kr

## I. 서론

심전도(ECG; electrocardiogram)는 심장에서 심장 박동을 유지하고 조절하기 위해 생성되는 전기적 활동을 파장 형태로 기록한 것을 말하며 기본적으로 심전도 검사를 통해 심장의 건강 상태와 심장 질환을 진단한다[1]. 심전도 검사를 통해 진단할 수 있는 질환 중 부정맥은 여러 가지 원인으로 인해 전기 신호체계가 비정상적으로 나타나 심장 박동이 불규칙하게 나타나는 것을 의미하며, 일반적으로 증상이 짧은 시간 동안 발생하고 사라지는 경우가 많다[2],[3]. 따라서 심전도 검사 방법 중 홀터 심전도 검사를 이용하여 심장의 이상 증상을 진단한다. 홀터 심전도 검사는 일반적으로 내원을 통해 심전도를 검사하는 방법과 달리 병원에서 처방받은 휴대용 심전도 측정장치를 착용하여 일상생활에서 심전도 신호를 측정하여 저장한다. 환자는 24시간 또는 48시간의 정해진 시간 동안 홀터 심전도 기기를 착용하게 되며, 저장된 신호는 별도의 과정을 통하여 병원에서 전문가에 의하여 분석이 이루어져 심장의 이상 징후 여부를 확인하게 된다[4],[5].

이러한 홀터 심전도 검사 방법은 일상생활에서 일정 기간 심전도를 측정함으로써 내원을 통해 진행되는 기본 심전도 검사에 비해 심장 질환 검출 가능성이 높다. 그러나, 24시간 또는 48시간의 정해진 시간 동안만 측정할 수밖에 없다는 점과 저장된 신호가 추후 별도로 분석되어 심장 질환의 이상 여부를 판단해야 한다는 점에서 홀터 심전도는 언제 어디서나 심장의 이상 징후의 발생을 실시간으로 감지하고 대응하기에는 한계가 있다.

본 연구를 통하여 제안하는 부정맥 실시간 진단을 위한 심전도 모니터링 및 부정맥 감지 시스템은 기존의 홀터 심전도 검사 방법의 제약사항들을 해결하는 것을 목적으로 한다. 사용자는 웨어러블 심전도 센서 장치를 통해 장시간 심전도를 측정할 수 있으며, 측정된 심전도 신호는 휴대용 모바일 장치인 스마트폰을 통해 수신되어 심전도 신호의 정밀분석을 수행하는 서버시스템으로 전송된다. 정밀분석 서버시스템은 심전도의 R-peak를 감지하고 이를 기반으로 딥러닝 모델에 의한 부정맥 징후를 감지하며, 부정맥이 감지된 경우 환자의 휴대용 장치 및 미리 설정된 연락처로 부정맥 발생의 경고를 전송한다. 또한, 모바일 기기는 비록 판별의 정밀도는 낮을 수 있지만, 서버와의 통신 장애가 발생한 상황에서도 부정맥 징후 발생에 대비하기 위하여 규모가 작은 경량모델을 갖추고 있다.

본 논문의 본문에서는 딥러닝 모델을 이용한 실시간 부정맥 감지 이중화 모바일 시스템의 전체적인 구조와 시스템의 각 구성요소인 웨어러블 심전도 센서 디바이스, 심전도 신호 데이터, 모바일 애플리케이션 및 서버시스템의 설계 및 구현 방법에 대하여 설명한다. 이어서 심전도 신호의 정밀분석 및 서비스 기능을 위한 핵심 기능인 R-peak 감지 및 부정맥 감지 알고리즘과 실제 구현한 시스템의 결과에 대한 성능평가에 관해서 기술한다.

## II. 시스템 구성

본 장에서는 제안한 시스템의 전체적인 구조와 각 구성요소들에 대한 상세한 설명을 그림 1을 이용하여 설명한다.

심전도를 측정하기 위한 웨어러블 ECG 센서 장치는 움직임 측정을 위한 가속도 센서, 세 개의 전극을 가진 심전도 센서 및 BLE 블루투스 통신 모듈을 중심으로 구성되어 있으며, 휴대용 모바일 장치와 BLE 통신을 통해 심전도와 움직임 신호인 가속도 신호를 전달한다. 본 연구의 휴대용 모바일 장치는 일반적인 스마트폰을 사용하였으며, 특별한 조건을 요구하지 않는다.

휴대용 모바일 장치는 사용자와 관련된 정보의 입출력을 위한 인터페이스 제공, BLE 통신을 위한 블루투스 스캔 및 연결, 심전도 신호의 수신, 수신된 심전도를 정밀분석 서버시스템으로 전송, 정밀분석 서버시스템에서 수신한 이상 징후 감지 메시지에 따른 경고 발생 등을 상시 수행하게 된다. 또한, 부수적으로 정밀분석 서버시스템에 저장된 이력 정보 등을 제공하는 등 다양한 사용자 요구를 위한 인터페이스 기능을 제공한다. 이러한 일상적인 기능들과 더불어 모바일 장치가 제공하는 중요한 기능은 정밀분석 서버시스템과의 통신 장애 상황에 대한 대응 기능으로 비록 ECG 신호분석 및 판별 능력은 낮지만, 자체적으로 심장 이상 징후를 감지하기 위한 경량 감지 알고리즘을 수행하는 것이다. 경량 감지 알고리즘은 휴대용 장치에서 실시간 실행이 가능한 정도로 가벼우며 파라미터는 정밀분석 서버시스템에서 수시로 학습이 수행되어 얻어지게 된다.

서버는 사용자 정보, 모바일 장치의 정보, 웨어러블 센서의 정보, 심전도 데이터 등을 저장, 관리 및 배포하는 통합 관리 기능을 수행한다. 핵심 기능으로는 모바일 기기에서 수집한 심전도 데이터를 받아 정밀하게 분석하여 심장 박동의 이상 징후를 감지하고, 이상 징후가 발생할 경우 사전에 지정된 대상에게 이상 감지 메시지를 전송하게 된다. 또한, 분석이 완료된 전체 심전도 데이터 및 그 결과를 저장하는 기능을 부수적으로 수행한다.

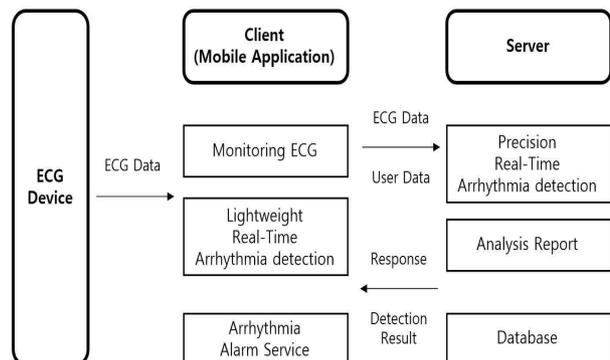


그림 1. 실시간 부정맥 감지 이중화 모바일 시스템의 구조도  
 Fig. 1. Architecture of a duplexing mobile system for real-time arrhythmia detection

2-1 웨어러블 심전도 센서 디바이스

웨어러블 심전도 센서 디바이스는 그림 2에 나타난 바와 같이 외형적으로는 3개의 부착형 전극을 가지고 있다. 내부에는 배터리를 포함하여 움직임을 측정하는 가속도 센서와 심전도 센서 및 블루투스 통신 모듈로 구성되어 있으며, 전극은 특정 위치에 부착하여야 한다. 감지된 심전도 신호의 처리에 필수적으로 필요한 디바이스의 서비스 정보는 표 1과 같으며, 디바이스의 서비스 정보는 휴대형 모바일 장치와 연결된 이후 서버에 전송되어 저장 및 사용되게 된다. 웨어러블 디바이스에 포함된 가속도 센서는 과도한 움직임 발생을 감지하여 분석을 포기하는 목적으로 탑재되었으나, 본 논문에서는 상세 내용에 대한 설명을 포함하지 않는다.

MAC Address는 웨어러블 심전도 센서 디바이스에 할당된 고유한 식별자로 이를 통해 모바일 애플리케이션에서 디바이스를 식별하고 연결 및 통신을 수행한다. 연속적인 신호에서 단위 시간당 얻어진 샘플 수를 의미하는 sample rate, 하나의 샘플을 표현하는데 필요한 바이트 수를 의미하는 byte per sample, 신호에서 동시에 처리되는 독립적인 신호의 개수를 의미하는 number of channel, A/D conversion bit 정보는 심전도 신호의 획득, 전송, 데이터 처리 및 분석에 이용된다. 모바일 장치와 연결된 디바이스는 250ms를 주기로 130 Byte의 패킷을 보내게 되며, 이때 심전도 신호의 경우 단일채널의 100 Byte, 50 sample로 구성되어 있다. 모바일 장치에서는 Little-Endian 방식으로 저장된 패킷을 처리하여 신호에 대한 값을 얻어내게 된다.

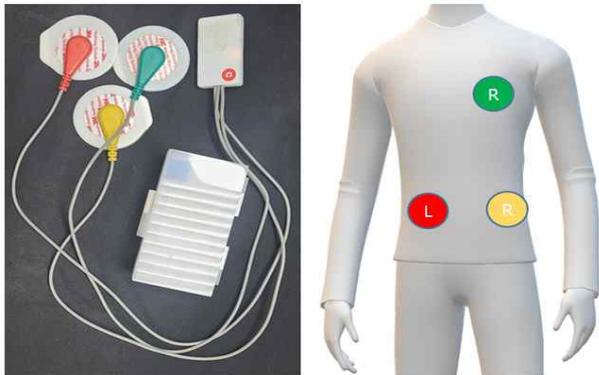


그림 2. 웨어러블 심전도 디바이스 구성 및 착용 위치  
Fig. 2. Wearable ECG device components and placement

표 1. 웨어러블 심전도 디바이스 서비스 정보  
Table 1. Wearable ECG device service info

| Service            | ECG Device |
|--------------------|------------|
| Sample rate        | 200        |
| Byte per sample    | 2          |
| Number of channel  | 1          |
| A/D conversion bit | 12         |

2-2 심전도 신호 데이터

심전도를 분석하는 것은 심장의 전기적 활동을 해석하는 것으로 심장 질환의 적절한 진단에 중요한 역할을 한다. 일반적으로 심전도 신호는 P, Q, R, S, T, U 파형을 가지며 정상적인 심전도는 순서대로 이 파형이 반복된다. 각 파형의 모양, 위치를 통해 심장의 문제를 확인할 수 있으며 특히 심실이 수축 전에 탈분극될 때 생성되는 전류로 인해 발생하는 QRS 복합체에 기반한 특징은 심전도 분석에 유용하게 이용된다[6].

본 논문의 정밀분석 서버시스템에서 심장 박동 이상 징후를 감지하기 위해서는 먼저 부정맥 감지 시스템이 구현되어야 하며, 이를 위해서는 심전도의 R-peak 검출이 선행되어야 한다. 먼저, 심전도 신호는 대역 통과 필터링, 정규화, 미분 및 절댓값 반환, 이동 적분 윈도우, peak 감지, 교정 순서의 과정을 거쳐 R-peak가 감지된다. 이때, R-peak 감지 알고리즘은 심전도 신호에서 QRS 복합체를 감지하기 위하여 가장 일반적으로 사용되는 Pan-Tompkins의 알고리즘 방식을 바탕으로 구현하였다[7].

본 연구를 위하여 사용된 심전도 신호는 MIT-BIH에서 제공하는 Arrhythmia 데이터를 이용하였다[8]. MIT-BIH 데이터는 '정상'과 15종의 부정맥으로 구성된 '비정상' 두 개의 클래스로 나누어 구성되어있다. 부정맥 감지 알고리즘 개발을 위하여 MIT-BIH 데이터에 제공된 R-peak의 위치를 기준으로 좌측 2.5초와 우측 0.5초 총 3초의 분할된 신호를 사용하였으며, 그 결과 '정상' 74,666개와 부정맥을 의미하는 '비정상' 30,712개로 총 105,378개의 심전도 신호 데이터를 추출하였다. 정상과 비정상에 대한 데이터의 분할 결과 예시는 그림 3과 같다. 그림 3에 보이는 바와 같이, 2.5초 지점을 벗어난 지점들에서도 수많은 R-peak의 형상이 나타나는데, 이는 건강한 성인의 안정기 평균 심박수가 60~100이라는 점을 고려하면 3초 동안 R-peak는 3~5개가 나타날 수 있기 때문이다.

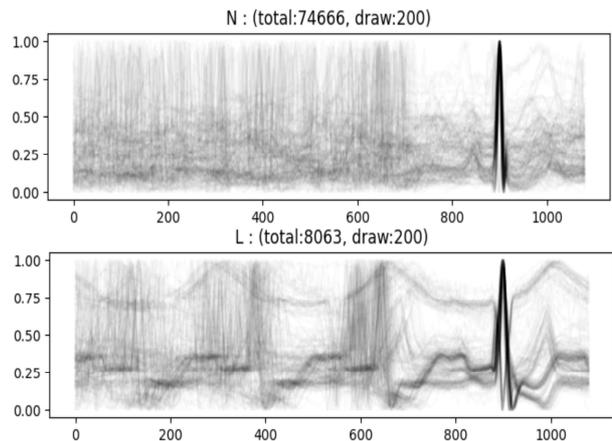


그림 3. 정상 및 비정상 신호 분할 예시  
Fig. 3. Example of normal and abnormal data segmentation

### 2-3 모바일 애플리케이션 및 서버

사용자가 모바일 애플리케이션을 이용하고자 할 경우 먼저 사용자 등록을 진행하게 된다. 이때 중복 등록을 방지하기 위해 서버에 저장되어있는 사용자 데이터베이스를 참조한다. 서버에서 중복되지 않음을 검증받게 되면 등록 과정이 종료되고 다음과 같은 4가지의 기능을 사용할 수 있게 된다.

먼저 현재 착용하고 있는 센서 디바이스 장치를 연결하기 위해 주변의 블루투스 장치를 스캔하고 스캔 된 장치들의 리스트들 중에서 심전도 센서 장치와 연결을 맺는 기능이다. 연결 후 심전도 모니터링과 데이터 처리에 필요한 장치의 서비스 정보는 모바일 기기를 거쳐 서버에 전송되어 저장된다.

두 번째로는 심전도 신호의 수신 및 분석으로 심전도 센서 디바이스로부터 신호를 수신하고 분석을 통해 비정상적 리듬의 발생 여부를 판단한다. 이때 수신된 심전도 신호의 실시간 부정맥 발생 여부를 판정은 모바일 애플리케이션 및 서버에서 모두 이루어진다. 서버에서는 대용량 모델을 통하여 정밀한 진단이 이루어지며, 서버와의 통신이 어려울 경우를 대비하여 모바일 애플리케이션에서는 정확도가 떨어지는 경량 모델을 실행한다. 서버와의 통신 장애 발생 시 모바일 애플리케이션에서 수집 및 실행된 모든 신호 및 데이터는 서버로 전송된다.

세 번째로는 부정맥이 감지되었을 경우에 대한 알람 송출 기능으로 서버 또는 단말 애플리케이션에서의 분석에서 부정맥이 감지된 경우 사용자가 미리 설정한 연락처로 알람 메시지를 보내 위험 상황에 대비할 수 있다.

마지막으로는 부정맥 감지 여부가 포함된 분석 리포트의 조회 기능으로 날짜 정보를 통해 심전도의 분석에 대한 리포트를 열람할 수 있다.

다음 그림 4에서는 사용자, 모바일 단말 및 서버 사이에서 이루어지는 서비스 기능의 작동 시나리오 및 데이터 송수신에 대한 흐름을 나타내고 있다.

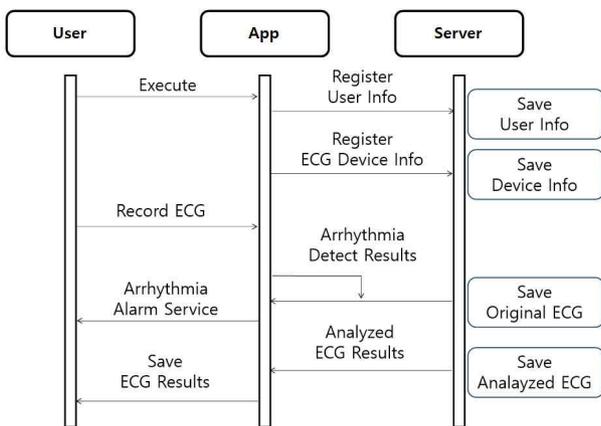


그림 4. 모바일 애플리케이션 및 서버의 데이터 처리 및 저장 과정

Fig. 4. Process of data processing and saving data in mobile application and server

### III. 심전도 신호 분석 및 서비스 기능

#### 3-1 R-peak 감지 및 부정맥 감지 알고리즘

제 II 장에서 설명한 심전도의 R-peak 감지 알고리즘의 구현에 있어서 대역 통과 필터링은 저주파와 고주파 노이즈를 제거하여 QRS 복합체를 잘 감지할 수 있도록 신호 대 잡음비를 높이는데 사용되었으며, 미분 및 절댓값 반환 과정은 ECG 신호에서 급격한 상승과 하강을 나타내는 특징을 이용하여 신호율을 계산하고 큰 피크를 더 강하게 강조하기 위해 사용되었다. 이후 QRS 복합체를 뚜렷하게 감지하기 위해 신호의 변화를 통합하여 감지하는 과정인 이동 적분 윈도우 필터링 과정을 거치며, 최종적으로 임계점이 2.1 이상인 피크의 위치를 R-peak의 위치로 지정하였다[7]. 이때, 이동 적분 윈도우의 길이는 알고리즘 성능에 영향을 주지 않으므로 임의의 길이를 선택할 수 있으나 본 연구에서는 1초의 길이를 선택하였다. 또한, 임계치 값 2.1은 반복적 검증을 통하여 선정하였으며, 전처리 및 정규화 방법의 차이로 인하여 달라질 수 있을 것이다.

그림 5는 최종적으로 얻어진 R-peak 감지 결과의 예시로 R-peak는 ECG 신호에 빨간색 점으로 표시되었다. 이 그림에서 보는 바와 같이 R-peak의 강도는 다른 peak들에 비해 월등히 높으며, 리듬이 불규칙하거나 신호가 왜곡된 구간에서도 peak 감지가 잘 이루어지고 있음을 보여주고 있다.

심전도 신호는 시간에 따른 전압 변화를 기록한 1차원 시계열 데이터로 정상적인 심박동인지 판별하는데 있어 신호의 연속적인 패턴이 중요한 역할을 한다. 따라서 연속적인 데이터의 상관관계를 학습하고 신호의 주요 특징이 발생하는 구간을 알아내기 위해 합성곱 신경망 모델을 이용하였다.

부정맥을 감지하기 위한 합성곱 신경망 모델의 구조는 그림 6과 같으며 1차원 1D convolution layer 2개와 2개의 은닉층을 가진 MLP(multi-layer perceptron)로 구성되었다 [9],[10]. 2개의 1D convolution layer의 mask는 각각 16개이고 크기는 31이며 활성화함수는 ReLU를 사용하였으며, 각 1D convolution layer마다 maxpooling 통해 출력 크기를 절반으로 줄였다. 또한, 2개의 MLP 은닉층은 각각 128개의 뉴런을 가지며, 출력층의 1개의 뉴런을 포함하여 모든 뉴런의 활성화함수는 모두 sigmoid 함수로 설정하였다.

신경망 학습과 성능 검증을 위하여 총 105,378개의 심전도 segment 신호를 5:5로 분할하여 학습용과 성능 시험용으로 사용하였다. 신경망의 매개변수를 효과적으로 학습시키기 위한 최적화는 Adam 방식을 사용하였고, convolution layer에 Batch-Normalization 층과 Drop-Out 층을 적용하여 과적합(overfitting)의 발생 가능성을 최소화하였다. 또한, ‘정상’과 ‘비정상’ 클래스 간의 데이터의 수는 각각 74,666개, 30,712개로 데이터가 균일하지 않아 이를 해결하기 위한 방안으로 클래스별로 상이한 가중치를 학습률(learning rate)에 적용하였다.

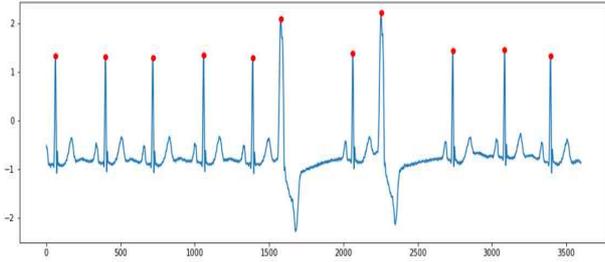


그림 5. R-peak 감지 알고리즘 적용 결과 예시  
Fig. 5. Example of ECG R-peak detection algorithm

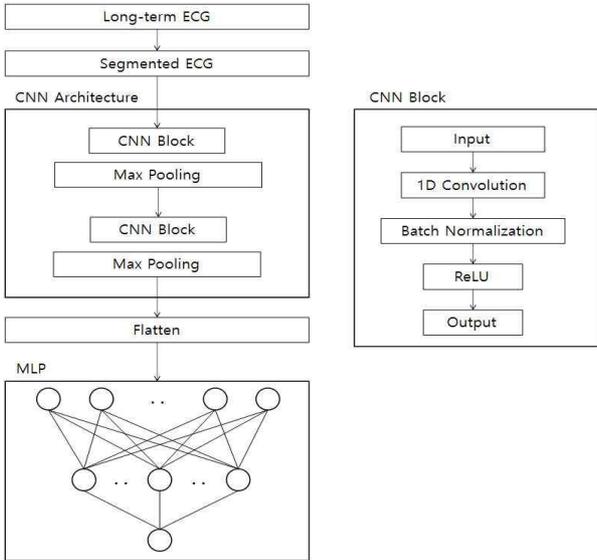


그림 6. 부정맥 감지를 위한 합성 신경망 모델 구조도  
Fig. 6. Architecture of CNN model for arrhythmia detection

학습의 결과에 대한 평가 척도는 일반적으로 사용되는 정확도(accuracy), 민감도(sensitivity) 및 특이도(specificity)를 이용하였으며, 이의 계산은 식 (1), 식 (2) 및 식(3)과 같다. 수식에서 사용된 TP, TN, FP, FN은 각각 True Positive, True Negative, False Positive, False Negative를 의미한다.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (2)$$

$$Specificity = \frac{TN}{TN + FP} \quad (3)$$

부정맥을 감지하기 위한 1차원 합성곱 신경망 모델의 성능 평가를 위한 데이터 52,689개에 대하여 부정맥을 의미하는 비정상과 정상을 판별하는 모델은 임계값이 0.5인 sigmoid 함수를 출력 노드의 활성화 함수로 가지며 0.5 이상이면 비정상으로 출력하고 0.5 미만이면 정상으로 출력한다. 그에 따른

| Predicted \ Actual    | Threshold=0.5   |                 | Accuracy              |
|-----------------------|-----------------|-----------------|-----------------------|
|                       | Arrhythmia      | Normal          |                       |
| Arrhythmia (Positive) | 15,006 (97.72%) | 350 (2.28%)     | Sensitivity<br>97.72% |
| Normal (Negative)     | 204 (0.55%)     | 37,129 (99.45%) | Specificity<br>97.25% |

(a)

| Predicted \ Actual    | Threshold=0.075 |                 | Accuracy              |
|-----------------------|-----------------|-----------------|-----------------------|
|                       | Arrhythmia      | Normal          |                       |
| Arrhythmia (Positive) | 15,203 (99.00%) | 153 (1.00%)     | Sensitivity<br>98.99% |
| Normal (Negative)     | 1,026 (2.75%)   | 36,307 (97.25%) | Specificity<br>97.25% |

(b)

그림 7. 임계점 (a) 0.5 일때와 (b) 0.075 일때의 혼돈행렬 및 성능평가 지표의 결과

Fig. 7. Confusion matrix and performance index for threshold value of (a) 0.5 and (b) 0.075

평가 결과는 그림 7(a)의 혼돈 행렬과 같다.

모든 클래스의 중요도를 동일하게 다루는 일반적인 문제와 다르게 부정맥의 감지는 특정 클래스로의 분류가 중대한 문제를 일으킬 수 있다. 즉, ‘정상’을 ‘비정상’으로 분류하는 오류를 의미하는 False positive는 단순히 주의해야 하는 정도의 비용을 요구하지만, ‘비정상’을 ‘정상’으로 분류하는 오류를 의미하는 False negative는 치명적인 비용을 요구할 수 있다. 따라서, 양성인 부정맥 사례를 음성인 정상으로 판단하는 False negative의 비율을 최대한 낮춰야 하는 점이 학습의 중요한 고려 사항이다. 이를 위해서는, 그림 7(a)의 혼돈행렬 중 부정맥을 정상으로 판별한 데이터의 개수가 350개, 오류율 2.28%를 나타내는 이상 구역을 최소로 하는 판정 기준을 설정하여야 한다.

간단한 방법으로 출력 노드의 임계값을 낮춤으로써, 비록 ‘정상’을 ‘비정상’으로 분류하는 오류인 False positive의 비율은 상승할지라도, ‘비정상’ 즉 부정맥 사례를 ‘정상’으로 판단하는 False negative의 비율을 낮출 수 있다. 그림 7(b)는 임계값을 0.075로 설정한 경우인데, 혼돈행렬의 이상 구역의 오류가 1.00%로 그림 7(a)의 2.28% 경우보다 현격히 낮아졌다. 반면 False positive를 나타내는 좌하 구역의 오류는 0.55%에서 2.75%로 높아졌고, 정확도(Accuracy) 역시 98.95%에서 97.76%로 낮아졌다.

TensorFlow 모델을 TensorFlow Lite로 변환하여 동일한 구조의 학습된 모델을 모바일 환경에 적용하여 부정맥 진단에 활용하였다. 삼성 갤럭시 탭 S9의 모바일 단말에서 약 40ms 내외의 분류 시간이 소요되었으며, 이는 실시간 부정맥 진단이 가능함을 보여주는 수치이다. 따라서 서버용으로 설계된 모델은 TensorFlow Lite를 탑재한 적절한 컴퓨팅 성능을

갖는 모바일 단말에서 서버와 동일한 정확도를 제공하는 모바일용 경량 모델로도 활용할 수 있을 것이다. 또한, 필요에 따라서는 정확도가 조금 낮아질지라도 모델의 구조를 경량화하여 컴퓨팅 성능이 낮은 모바일 단말에도 적용이 가능할 것이다.

### 3-2 주요 기능 구현

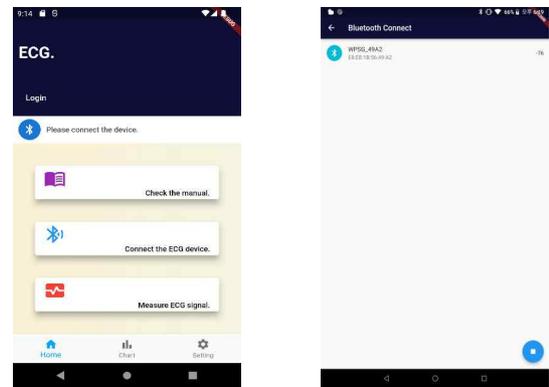
모바일 애플리케이션은 사용자가 휴대하는 단말기에서 실행되며, 단말기로는 스마트폰이나 태블릿 등이 대표적이다. 사용자는 모바일 애플리케이션을 통하여 사용자 등록, 심전도 웨어러블 장치와 연결, 심전도 신호 수신, 서버와의 통신 관리, 수신 신호 및 사용자 정보를 서버로 송신, 서버의 분석 결과 및 경고 메시지 수신, 실시간 부정맥 진단 등의 기능을 수행한다. 이와 더불어 심전도의 기록 및 분석에 대한 보고서 생성을 포함한 다양한 사용자 인터페이스를 제공한다. 그림 8 은 구현된 모바일 애플리케이션의 화면을 보여주고 있다.

모바일 애플리케이션을 최초로 실행할 때 사용자는 로그인 및 회원가입 기능을 통하여 사용자 등록을 수행하게 되며, 부정맥이 감지되었을 때 알람 메시지를 보내기 위한 연락처를 추가 등록하게 된다. 입력된 사용자 정보와 알람 메시지의 연락처 정보는 서버로 전송되어 저장되며 이후 메뉴얼의 안내에 따라 웨어러블 심전도 디바이스를 착용한 후 사용자는 블루투스 장치를 스캔하여 장치명 또는 MAC 주소를 통해 착용하고 있는 센서 디바이스와 연결을 진행한다.

이상의 과정이 모두 완료되면 심전도 측정 페이지에 접근이 가능하며, 오프셋이 5초인 심전도 신호와 사용자의 움직임에 대한 가속도계 신호를 나타내는 총 2개의 그래프를 실시간으로 모니터링을 할 수 있으며 1초마다 업데이트된다. 측정된 신호는 단말에 그래프로 제공하는 것과 동시에 서버로 전송된다. 또한, 서버로부터 부정맥 발생 경고 메시지를 수신하였을 경우 소리, 진동, 화면 깜빡임 등과 같은 경고를 발생한다. 이때, 옵션에 따라 미리 설정된 연락처로 문자, 전화, 메신저 등을 발송할 수 있으며, 이는 서버에서도 이루어진다.

만약 모바일 단말기가 서버와 통신이 불가능한 경우 모바일 단말기는 미리 탑재된 경량 부정맥 감지 모델을 구동하여 부정맥의 발생 여부를 실시간으로 분석한다. 이때 경량 분석 모델은 서버의 정밀분석 모델과 동일한 알고리즘을 사용하거나 계산 부담이 적은 모델을 채용할 수 있으며, 모델의 파라미터는 별도로 학습되어 서버로부터 전송을 받는다. 한편, 통신 장애 기간에 수신된 신호 정보는 모두 단말에 저장되었다가 서버와의 통신이 재개될 때 서버로 전송한다.

서버의 주요 기능은 사용자 정보와 심전도 및 움직임에 대한 데이터 신호의 수신 및 저장, 관리하는 기능을 수행하며, 분석 및 리포트 생성과 관련된 다양한 기능들을 포함하고 있다. 특히 분석 결과에 따라 부정맥이 발생하였을 경우 발생 시간, 지속 시간 등의 상세 정보를 포함한 경고 메시지를 모바일 단말로 송신하여 사용자가 대응할 수 있도록 지원한다.

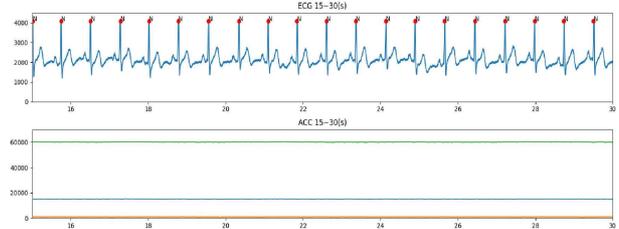


(a) Main Page

(b) BLE Scan/Connect



(c) Real-Time ECG Monitoring



(d) Results of Analyzed ECG

그림 8. 모바일 애플리케이션 실행 화면

Fig. 8. An example of the mobile application screen

## IV. 결 론

본 논문에서 제시한 시스템은 웨어러블 심전도 센서, 모바일 기기 및 서버로 구성되어 실시간으로 심전도 신호를 수신하고 분석하여 부정맥 리듬의 발생 여부를 감지하고 이를 사용자 및 등록된 연락처로 경고를 보내는 기능을 수행한다. 기존의 홀터 시스템과 비교해 볼 때, 본 연구에서 개발한 시스템은 웨어러블 장치로서 일상생활 중에도 서비스의 제공이 가능하며, 저장 후 분석 방식이 아닌 실시간 분석으로 부정맥 발생을 즉시 경고할 수 있어 응급 상황의 대처가 가능하다.

특히, 사용자가 휴대한 단말 장치에 실시간으로 실행이 가능한 부정맥 감지 경량모델을 탑재하여 단말기와 서버의 통신이 불가능한 상황에서도 수신된 심전도 신호 정보를 이용하여 부정맥 여부를 감지한다. 이러한 구조는 비록 감지의 정확도는 서버의 정밀분석보다 낮을지라도 부정맥 발생 상황을 간과하지 않을 수 있다는 장점이 있다. 또한, 수신된 신호 정보들은 추후 통신이 재개되었을 때 서버로 송신하게 된다.

부정맥 감지 알고리즘은 1D 합성곱 신경망 모델을 사용하

였으며, 각각 크기가 31인 16개의 마스크를 갖는 2개의 합성곱 층과 각각 128개의 뉴런을 갖는 2개의 은닉층 및 1개의 뉴런을 갖는 출력층으로 구성되었다. 정상과 비정상 클래스의 데이터 개수의 불균형 문제를 줄이고자 합성곱 신경망 학습률에 각 클래스의 데이터 숫자의 비율을 가중치로 반영하였다. 또한, 이러한 모델은 ‘비정상’을 ‘정상’으로 분류하는 치명적인 오류인 False negative의 가능성을 줄이고자 클래스 분류의 임계값 선정을 출력값의 중간값이 아닌 0.075 이상일 경우 비정상, 0.075 미만일 경우 정상을 출력하는 임계값 0.075를 적용하여 민감도(sensitivity)가 크게 개선되었다.

일상생활 중 과도한 움직임이 발생한 경우 심전도 신호에 심각한 왜곡이 발생하여 오경보를 발생하는 경우가 빈번하다. 이런 경우, 움직임 감지 센서의 신호를 이용하여 분석을 중단하거나 분석 결과를 무시하는 방법으로 오경보를 줄일 수 있을 것이다. 또한, 심전도 센서의 부착이 정상적이지 않아 신호의 품질이 나쁜 경우도 발생하는데, 이러한 경우를 감지하는 기술의 개발도 추가로 요구된다.

## 감사의 글

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2020R1A5A8018367)

## 참고문헌

- [1] C. Fisch, “Evolution of the Clinical Electrocardiogram,” *Journal of the American College of Cardiology*, Vol. 14, No. 5, pp. 1127-1138, November 1989. [https://doi.org/10.1016/0735-1097\(89\)90407-5](https://doi.org/10.1016/0735-1097(89)90407-5)
- [2] C. W. Israel, G. Grönefeld, J. R. Ehrlich, Y.-G. Li, and S. H. Hohnloser, “Long-Term Risk of Recurrent Atrial Fibrillation as Documented by an Implantable Monitoring Device: Implications for Optimal Patient Care,” *Journal of the American College of Cardiology*, Vol. 43, No. 1, pp. 47-52, January 2004. <https://doi.org/10.1016/j.jacc.2003.08.027>
- [3] A. Hammerer-Lercher, M. Namdar, and N. Vuilleumier, “Emerging Biomarkers for Cardiac Arrhythmias,” *Clinical Biochemistry*, Vol. 75, pp. 1-6, January 2020. <https://doi.org/10.1016/j.clinbiochem.2019.11.012>
- [4] M. A. Serhani, H. T. El Kassabi, H. Ismail, and A. N. Navaz, “ECG Monitoring Systems: Review, Architecture, Processes, and Key Challenges,” *Sensors*, Vol. 20, No. 6, 1796, March 2020. <https://doi.org/10.3390/s20061796>
- [5] P. M. Barrett, R. Komatireddy, S. Haaser, S. Topol, J. Sheard, J. Encinas, ... and E. J. Topol, “Comparison of 24-Hour Holter Monitoring with 14-Day Novel Adhesive Patch Electrocardiographic Monitoring,” *The American Journal of*

*Medicine*, Vol. 127, No. 1, pp. 95.e11-95.e17, January 2014. <https://doi.org/10.1016/j.amjmed.2013.10.003>

- [6] S. K. Berkaya, A. K. Uysal, E. S. Gunal, S. Ergin, S. Gunal, and M. B. Gulmezoglu, “A Survey on ECG Analysis,” *Biomedical Signal Processing and Control*, Vol. 43, pp. 216-235, May 2018. <https://doi.org/10.1016/j.bspc.2018.03.003>
- [7] J. Pan and W. J. Tompkins, “A Real-Time QRS Detection Algorithm,” *IEEE Transactions on Biomedical Engineering*, Vol. BME-32, No. 3, pp. 230-236, March 1985. <https://doi.org/10.1109/TBME.1985.325532>
- [8] G. B. Moody and R. G. Mark, “The Impact of the MIT-BIH Arrhythmia Database,” *IEEE Engineering in Medicine and Biology Magazine*, Vol. 20, No. 3, pp. 45-50, May-June 2001. <https://doi.org/10.1109/51.932724>
- [9] A. Y. Hannun, P. Rajpurkar, M. Haghpanahi, G. H. Tison, C. Bourn, M. P. Turakhia, and A. Y. Ng, “Cardiologist-Level Arrhythmia Detection and Classification in Ambulatory Electrocardiograms Using a Deep Neural Network,” *Nature Medicine*, Vol. 25, No. 1, pp. 65-69, January 2019. <https://doi.org/10.1038/s41591-018-0268-3>
- [10] A. Eleyan, F. Bayram, and G. Eleyan, “Spectrogram-Based Arrhythmia Classification Using Three-Channel Deep Learning Model with Feature Fusion,” *Applied Sciences*, Vol. 14, No. 21, 9936, October 2024. <https://doi.org/10.3390/app14219936>

## 김세진(Sejin Kim)



2024년 : 전남대학교 컴퓨터정보통신공학과 졸업

2024년~현 재: 전남대학교 컴퓨터정보통신공학과 연구원  
 ※ 관심분야 : 기계학습(Machine Learning), 인공지능(Artificial Intelligence), 의료IoT시스템(Medical IoT System)

## 이헌주(Heonzoo Lee)



2018년 : 전남대학교 (공학사)

2018년~현 재: 전남대학교 대학원(지능전자컴퓨터공학 석·박사통합과정)  
 ※ 관심분야 : 기계학습(Machine Learning), 신호처리(Signal Processing), 의료IoT시스템(Medical IoT System)



**박라영(Rayoung Park)**

2001년 : 조선대학교 유전공학과 졸업  
2003년 : 조선대학교 대학원 (이학석사  
-유전자과학과)  
2014년 : 조선대학교 대학원 (이학박사  
-생물신소재학과, 분자생물학)

2002년~2003년: 전남대학교병원  
2003년~2006년: 조선대학교  
2006년~2007년: 화순전남대학교병원  
2007년~2011년: 전남대학교  
2014년~2021년: 화순전남대학교병원  
2021년~현 재: 전남대학교 BIT융합기술사업단 학술연구교수  
※ 관심분야 : 분자세포생물학(Molecular Cell Biology), 바이오  
의료데이터분석(Biomedical Data Analysis)



**원용관(Yonggwon Won)**

1987년 : 한양대학교 (공학사)  
1991년 : University of Missouri 대학원  
(공학석사-신경회로망,  
신호처리)  
1995년 : University of Missouri 대학원  
(공학박사-신경회로망, 신호처  
리, 영상처리, 영상 인식)

1986년~1988년: 금성통신 교환기 사업부  
1991년~1995년: University of Missouri, Research &  
Teaching Assistant  
1995년~1995년: University of Missouri, Research Associate  
1996년~1996년: 한국전자통신연구원(선임연구원)  
1996년~1999년: KT(선임연구원)  
1999년~현 재: 전남대학교 컴퓨터공학과 교수  
※ 관심분야 : 기계학습(Machine Learning), 인공지능(Artificial  
Intelligence), 데이터분석(Data Analysis), 의료  
IoT시스템(Medical IoT System)