



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

손목의 스마트 워치에서  
12리드 심전도 생성

Generation of full 12-lead electrocardiogram  
from smartwatch on wrist

울 산 대 학 교 대 학 원  
의 과 학 과  
최 현 화

손목의 스마트 워치에서  
12리드 심전도 생성

지도 교수  
주세경

이 논문을 공학석사학위 논문으로 제출함

2024년 2월

울산대학교 대학원  
의과학과  
최현화

최현화의 공학석사학위 논문을 인준함

심사위원 남기병 인

심사위원 주세경 인

심사위원 김준기 인

울 산 대 학 교 대 학 원

2024년 2월

# 목 차

국문요약 .....	II
그림 목차 .....	III
표 목차 .....	VI
식 목차 .....	VI
서론 .....	1
1. 연구배경 .....	1
2. 인공지능과 딥러닝 .....	7
3. 생성적 적대 신경망(Generative Adversarial Network) .....	11
4. 생성적 적대 신경망 종류 .....	13
연구 방법 .....	15
1. 데이터 수집 .....	15
2. 데이터 전처리 .....	16
3. 모델 .....	18
4. 평가 방법 .....	21
결과 .....	23
고찰 .....	33
한계 .....	36
결론 .....	37
참고문헌 .....	38
영문초록 (Abstract) .....	43

## 국문 요약

스마트워치 시장의 변장은 현대 사회에서 건강에 대한 관심이 높아지면서 가속화되고 있다. 이러한 웨어러블 장치는 특히 피트니스와 건강 모니터링 분야에서 큰 관심을 받고 있으며, 사용자들에게 건강 상태를 실시간으로 관찰하고 관리할 수 있는 강력한 도구로 자리 잡고 있다. 그러나 현재 스마트워치는 전극을 2개만 사용하기 때문에 단일 리드 심전도(ECG) 신호만을 측정할 수 있는 제한이 있다. 이러한 제한으로 인해 심장 건강 및 관련 의료 상태를 감지하기 어려워진다는 문제가 있다.

이에 따라 본 연구는 이러한 제한을 극복하려는 목표를 가지고 진행되었다. 생성적 적대 신경망(GAN)을 활용하여 스마트워치 데이터에서 생성된 12리드 ECG 데이터와 표준 12리드 ECG 데이터를 비교함으로써, 스마트워치를 통해 높은 품질의 ECG 데이터를 확보할 수 있는 가능성을 조사하였다.

스마트워치와 표준 12리드 ECG 장치에서 ECG 데이터를 수집하였고, 생성적 적대 신경망을 활용하여 스마트워치의 단일 리드 ECG 데이터를 12리드 ECG 데이터로 변환하였다. 그 후 생성된 12리드 ECG 데이터와 표준 12리드 ECG 데이터를 상세하게 비교하였다.

연구 결과에서는 스마트워치가 신뢰할 수 있는 ECG 데이터를 제공할 수 있음을 확인하였다. 스마트워치에서 얻은 리드 I 신호와 표준 심전도 사이에 주목할 만한 양의 상관관계가 있었으며, 평균 제곱 오차 값이 상대적으로 작았다. 이러한 결과는 스마트워치로부터 얻은 ECG 데이터와 표준 ECG 데이터 간에 큰 차이가 없음을 보여주며, Fréchet distance 점수 역시 생성된 ECG 신호가 기준 신호와 밀접하게 동기화되었음을 추가로 입증하였다.

이러한 연구 결과를 종합하면, 스마트워치를 사용하여 측정 시계 위치를 변경하지 않고도 포괄적인 12리드 ECG 데이터를 생성할 수 있다는 혁신적인 가능성을 제시하였다. 이러한 혁신은 건강 모니터링 및 진단 분야에서 큰 혁명을 일으킬 수 있으며, 의료 전문가와 개인 모두가 ECG 데이터를 더 쉽게 수집하고 분석할 수 있도록 도와줄 것이다. 이로써 의료 분야에서의 혁신과 환자 친화적인 솔루션을 제공하는 중요한 발전을 이루게 될 것이다. 이러한 연구는 건강과 의료 분야에서 새로운 가능성을 열어주고, 개선된 건강관리와 진단에 기여할 것으로 기대된다.

## 그림 목차

그림 1 심전도

그림 2 아인트호벤의 삼각형과 월슨 중앙 터미널 기준 12리드 심전도 측정 위치

그림 3 웨어러블 기기 시장의 규모 예측

그림 4 Alivecor, 심전도 patch, 애플 워치, 갤럭시 워치

그림 5 스마트 워치 심전도 측정 방법

그림 6 기존의 스마트 워치 심전도 리드 전환 방법

그림 7 머신러닝 훈련 과정

그림 8 딥러닝 훈련 과정

그림 9 생성적 적대 신경망 아키텍처

그림 10 생성적 적대 신경망 모델 종류

그림 11 Pix2pix GAN

그림 12 사용된 심전도 측정기기

그림 13 실험 개요

그림 14 전처리 후 스마트 워치 심전도 데이터 샘플

그림 15 U-net 기반 생성기

그림 16 판별기

그림 17 모델 전체 구조

그림 18 실험 1의 리드 I 데이터 샘플 플롯

그림 19 실험 2의 리드 I 데이터 샘플 플롯

그림 20 측정된 모든 데이터를 포함하는 실험 1과 2에 대한 피어슨 상관 계수 R-값 박스 플롯

그림 21 이상 값 예시

그림 22 실험 1과 2의 Fréchet distance와 평균제곱오차 박스 플롯

그림 23 실험 1의 생성된 신호와 표준 12리드 신호의 비교

그림 24 실험 2의 생성된 신호와 표준 12리드 신호의 비교

그림 25 비동기 데이터(리드 I, 리드 II)를 사용하여 12 리드 심전도를 생성하는 이전 연구의 그래픽 초록

## 표 목차

표 1 손실함수와 활성화 함수 식

표 2 생성적 적대 신경망 손실 함수 수식

표 3 실험 1과 2에 대한 피어슨 상관 계수 R-값

표 4 실험 1과 2의 평균제곱오차 평가 값

표 5 실험 1과 2의 Fréchet distance 평가 값

## 식 목차

식 1 피어슨 상관 계수 공식

식 2 평균제곱오차 공식

식 3 Fréchet distance 공식



# 서론

## 1. 연구 배경

전기 생리학은 신체 내 전기 신호에 초점을 맞춘 연구 분야이다 [1]. 이러한 신호는 주로 신경과 근육 조직에서 생성되며 다양한 생리적 기능을 조절한다. 심전도(ECG)는 전기생리학에서 심장의 전기적 활동을 측정하는데 사용되는 진단 테스트의 한 유형이다. 심장은 심장 근육 세포의 전기적 활동으로 인해 수축하며 이는 전기 신호로 나타난다. 이 신호를 측정해 심장의 건강 상태를 진단하고 부정맥이나 심부전 등의 심혈관 질환을 감지한다 [2]. 따라서 전기생리학에서 심전도는 심장의 건강을 평가하고 심장 문제를 진단하며 적절한 치료를 안내하는데 사용할 수 있는 중요한 진단 도구이다.




그림 1. 심전도

심전도를 얻는 방법에는 홀터 모니터링과 가장 일반적으로 사용되는 표준 12리드 측정 방법을 포함하여 다양한 방법이 있다 [3,4]. 표준 12리드 심전도는 사지 리드와 흉부 리드로 구분된 리드를 사용하며, 각각 심장의 전기 활동을 측정하는데 서로 다른 접근 방식을 사용한다. I, II, III, aVR, aVL 및 aVF를 포함한 사지 리드는 아인트호벤의 삼각형을 사용하여 다양한 각도에서 심장의 전기적 활동을 관찰한다. 이 리드는 전도 이상, 심실 비대 및 기타 상태를 감지하는데 사용된다. V1, V2, V3, V4, V5 및 V6를 포함한 흉부 리드는 가슴 중앙의 가상 기준점인 윌슨 중앙 터미널을 기반으로 한다. 이 리드는 흉벽에 배치되고 수평면에 심장의 전기 활동을 기록한다. 흉부 리드는 심장의 전반적인 기능을 평가하고 심부전, 심근경색, 심실 부정맥과 같은 상태를 진단하는데 특히 유용하다 [5,6]. 이러한 표준 12리드 심전도는 최소한의 비용으로 심장의 전기적 활동을 정확하게 식별할 수 있는 장점 때문에 선호되며 일반적으로 진단 의료 도구로 사용된다.

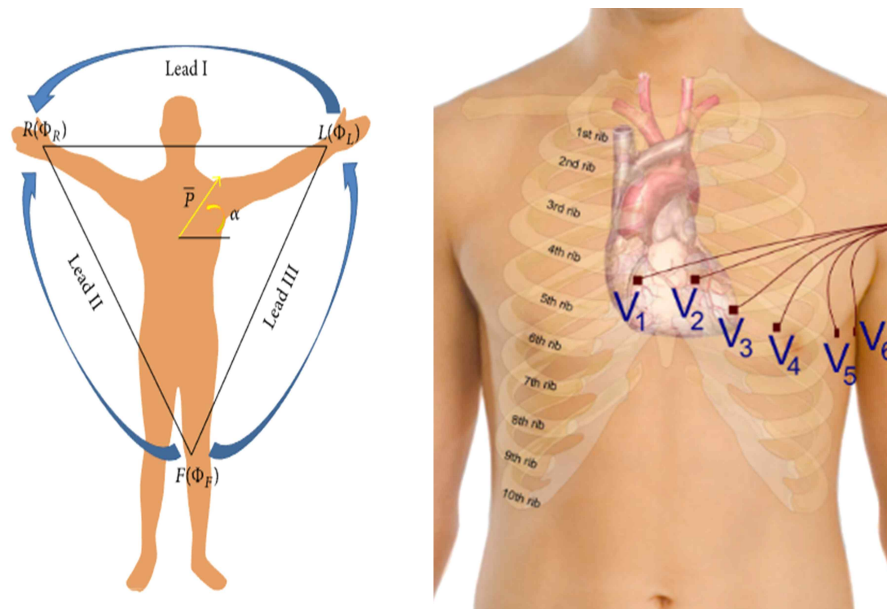


그림 2. 아인트호벤의 삼각형과 윌슨 중앙 터미널 기준 12리드 심전도 측정 위치  
 \*True Unipolar 심전도 Machine for Wilson Central Terminal Measurements

그러나 표준 12리드 심전도 측정을 이용한 심장 활동의 실시간 모니터링은 환자의 심박수나 활동량 변화를 측정하기 어렵기 때문에 제한적이다. 또한, 심전도를 얻기 위해 병원을 방문하는 것은 환자에게 불편할 수 있다. 이에 웨어러블 기기를 활용한 심전도 측정에 대한 관심이 높아지고 있다. 2019년 4분기에만 전 세계적으로 1억 1,890만 개의 웨어러블 기기가 출하되었으며, 시장 가치는 2026년에 1,500억 달러로 더욱 성장할 것으로 예상된다 [7-9]. 그림 3은 2020년부터 2030년까지 웨어러블 기기 시장의 규모를 예측한 것이다. 시간이 지날수록 시장 규모가 커지고 있음을 보여 준다.

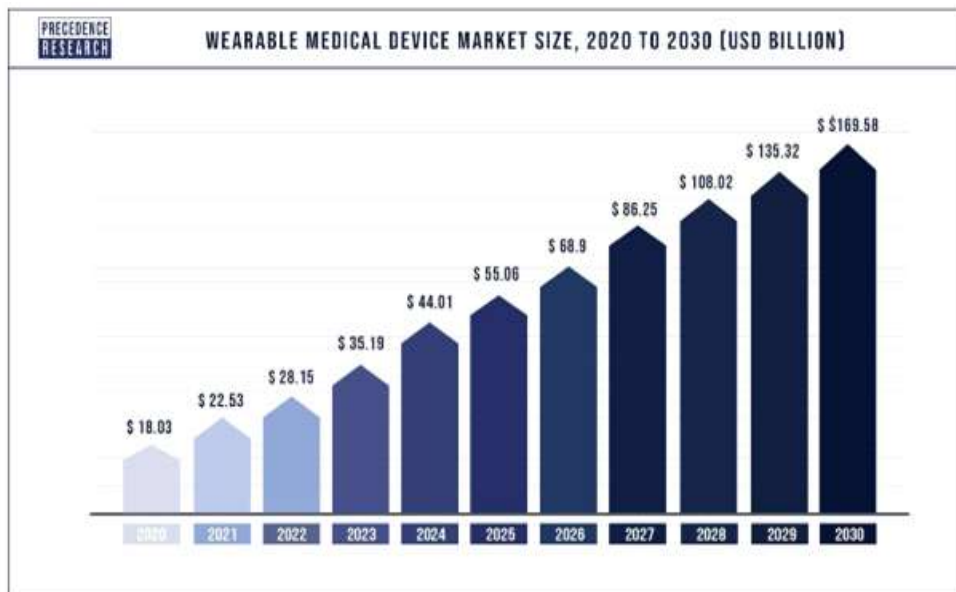


그림 3. 웨어러블 기기 시장의 규모 예측

웨어러블 심전도 장치에는 스마트 워치와 패치가 포함된다 [10]. 패치는 작고 가볍지만, 패치를 가슴에 부착할 때 사용자에게 불편함을 줄 수 있다. 또한, 웨어러블 패치를 피부에 장시간 부착하면 피부에 자극을 주기도 한다. 따라서 패치보다 착용하고 다니기 쉬운 스마트 워치의 인기가 급격하게 높아지고 있다 [11,12].



그림 4. Alivecor, 심전도 patch, 애플 워치, 갤럭시 워치

스마트 워치는 시계 뒷면(+)과 크라운(-)에 전극이 있다. 시계 후면에 있는 전극을 왼쪽 손목에 올리고 오른손 검지를 크라운에 올려놓고 두 전극 사이의 시간에 따른 전압 차이를 기록하여 단일 리드 심전도를 측정한다.



그림 5. 스마트 워치 심전도 측정 방법

최근 많은 연구에서 스마트 워치의 심전도를 사용했다. 스마트 워치에서 획득한 심전도 데이터를 사용하여 높은 정확도로 심방세동 진단을 입증했다 [13-15]. 하지만 스마트 워치는 단일 리드 심전도만 측정하기 때문에 모든 심장질환 진단에 한계가 있다. 따라서 단일 리드만을 사용하는 것 이상으로 사지 리드 및 흉부 리드에서 볼 수 있는 더 많은 심장 질환을 진단하기 위해서는 단일 리드의 심전도만이 아닌 추가적인 리드의 심전도가 필요하다.

이러한 한계를 극복하기 위해 많은 연구가 이루어졌다 [12, 16-18]. 스마트 워치에서는 전극이 두 개뿐이므로 여러 리드의 심전도 데이터에 동시에 측정할 수 없다. 따라서 연구자들은 스마트 워치를 사용하여 여러 리드를 측정하기 위한 다양한 접근 방식을 모색해왔다. 한 가지 접근 방식은 사지리드의 리드 II와 III를 측정하기 위해 시계 위치와 크라운에 올리는 손가락을 변경하는 것이다. 흉부 리드를 측정하기 위한 연구에서는 각 위치에 적합한 위치에 시계를 놓아서 V1, V4, V6를 측정했다. 그러나 이러한 접근 방식은 서로 다른 리드의 심전도를 기록하기 위해 시계를 각 위치로 이동해야 하는 번거로움이 있고, 여러 리드의 데이터를 동시에 수집할 수 없기 때문에 불편하다.




그림 6. 기존의 스마트 워치 심전도 리드 전환 방법

\*Single-Lead ECG Recordings Including Einthoven and Wilson Leads by a Smartwatch: A New Era of Patient Directed Early ECG Differential Diagnosis of Cardiac Diseases?

또 하나의 접근 방식은 생성적 적대 신경망 (GAN)와 같은 딥러닝 알고리즘을 활용하는 것이다 [19-21]. 최근 연구에서는 생성적 적대 신경망을 사용하여 사지 리드의 리드 I 심전도 데이터로부터 12리드 심전도 신호를 생성했다 [22]. 생성적 적대 신경망으로 생성된 심전도 신호의 정확성을 평가하기 위해 실제 12리드 심전도 데이터와 비교되었다. 결과는 생성된 심전도 신호가 실제 12리드 심전도 데이터와 매우 유사하다는 것을 보여주며, 이는 생성적 적대 신경망이 단일 리드 심전도 데이터를 다중 리드 심전도 신호로 정확하게 변환했음을 나타낸다.

따라서 본 연구에서는 생성적 적대 신경망을 사용하여 스마트 워치의 단일 리드 심전도 데이터로부터 12리드 심전도를 생성하는 것을 목표로 했다. 또한 실제 12리드 심전도 신호와 생성된 12리드 심전도 신호의 비교를 통해 스마트 워치에서 얻은 데이터를 검증하는 것을 목표로 했다. 스마트 워치를 착용하면 환자는 언제 어디서나 단일 리드 심전도를 사용하여 12리드 심전도를 생성할 수 있다. 또한, 단일 리드 심전도의 한계를 극복해 더 많은 질병의 진단과 조기 진단이 가능할 것으로 기대된다.

## 2. 인공지능과 딥러닝

인공지능(AI, artificial intelligence)은 컴퓨터를 사용하여 인간의 지적 능력인 사고, 학습 등을 모방하는 기술이다. 이는 인간의 인식, 판단, 추론, 문제 해결 능력을 이해하고 컴퓨터로 구현하는 것을 목표로 하며, 이 개념은 1943년 워런 맥클록(Warren McCulloch)과 월터 피츠(Walter Pitts)가 처음 제안한 것으로, 인간의 신경 구조를 네트워크로 모방한 인공 신경망(artificial neural network)이 이 개념의 시작점이다.

1950년, 앨런 튜링(Alan Mathison Turing)은 기계가 인간과 대화하는 정도를 측정하는 튜링 테스트를 제안했다. 이 테스트는 기계와 사람이 각각 응답자로 출연하여 질의자가 그들의 답변으로 컴퓨터인지 인간인지 판별할 수 없을 때를 테스트 통과로 간주했다. 이러한 테스트는 컴퓨터 인공지능 연구의 중요한 목표가 되었고, 2014년에는 튜링 테스트를 통과한 슈퍼컴퓨터가 등장하기도 했다.

1956년의 다트머스 컨퍼런스에서 인공지능이란 용어가 처음 등장했고, 1957년에 프랑크 로젠블라트(Frank Rosenblatt)가 퍼셉트론(perceptron) 알고리즘을 제안했는데, 이것이 신경망(머신 러닝)의 출발점이 되었다. 퍼셉트론은 여러 입력 신호를 받아 하나의 출력을 내보내며, 각 입력 신호에 가중치를 부여하여 출력을 조절한다. 하지만 이론적으로는 선형 분류는 가능하지만 비선형 분류는 불가능했고, 1970년대에는 메모리와 데이터의 한계로 인공지능이 침체기를 겪었다.

그러나 1986년에 Geoffrey Hinton 연구진이 다층 퍼셉트론(Multi Layer Perceptron, MLP)을 제안하여 비선형 분류 문제를 해결하고, 이후 머신 러닝이 등장하면서 데이터 분석, 학습, 판단, 예측을 위한 알고리즘을 사용하여 컴퓨터에 학습시키는 방향으로 발전했다. 머신 러닝의 핵심은 데이터의 표현(Representation)과 일반화(Generalization)에 있으며, 이러한 방식으로 데이터를 기반으로 컴퓨터가 새로운 상황에 대처할 수 있는 규칙을 학습하게 된다.



1990년에 고성능 하드웨어의 등장으로 대량의 데이터 처리가 가능해져, 머신 러닝이 큰 주목을 받았다. 이는 주로 빅데이터를 활용한 학습 방법으로 진행되었다. 모든 머신 러닝은 데이터를 유용한 표현으로 변환하는 방식을 사용하며, 좌표 변환, 선형 투영, 비선형 투영, 이동 등의 변환 방법이 사용된다. 이를 통해 데이터의 특징을 추출하여 학습 데이터를 생성한다.

양상블, 랜덤 포레스트, 서포트 벡터 머신 등이 머신 러닝의 종류로 알려져 있다. 머신 러닝은 통계와 밀접한 관련이 있지만, 데이터의 복잡성으로 인해 베이시안 분석과 같은 방법의 적용이 어렵고, 데이터 전처리가 수작업으로 이루어져 시간이 많이 소요되며 어려운 작업이라는 단점이 있다.




그림 7. 머신러닝 훈련 과정

딥 러닝은 머신 러닝의 한 분야로, 머신 러닝의 단점을 보완한 알고리즘입니다. 연속된 레이어에서 표현을 학습하는 데 강점을 가지며, 입력으로부터 출력을 도출하기 위해 가중치 값을 찾는 것이 주된 목적이다. 특징 추출이 필요하지 않아 머신 러닝과는 다르게 진행된다. 딥 러닝은 2012년 AlexNet의 개발로 시작되어, 2016년 알파고와 이세돌 9단의 바둑 대결 이후로 많은 관심과 개발이 진행되고 있다. 다양한 분야에서 활용되며, 게임, 의료기기, 자율 주행, 이미지 분류 등에서 딥 러닝을 적용한 연구가 전 세계적으로 이루어지고 있다.

신경망은 각 레이어의 값을 최적화하기 위해 손실 함수를 사용한다. 이 함수는 예측 값과 실제 값의 차이를 수치화해주는데, 이 차이가 클수록 함수 값이 커지고, 작을수록 작아진다. 따라서 목표는 이 손실 함수의 값을 최소화하는 가중치(w)와 편향(b)을 찾는 것이다. 회귀와 분류에 따라 평균 제곱 오차와 크로스 엔트로피와 같은 손실 함수가 사용된다. 딥 러닝 모델



은 학습 과정에서 초기 가중치를 설정하고, 손실 함수를 최소화하기 위해 이 값을 조금씩 조정한다. 이 과정을 충분한 횟수만큼 반복하여 최적의 가중치를 찾아내는데, 이를 통해 입력 값이 활성화 함수에 도달하며 모델이 학습된다. 데이터 연산 시 노이즈와 불필요한 정보를 처리해야 하는데, 이는 무시되어야 할 수 있다. 데이터의 크기가 클 경우 연산 오류가 발생할 수 있다. 이러한 문제를 해결하기 위해 전처리가 사용되지만, 여러 레이어를 거친 연산에서 어떤 일이 벌어질지 예측하기 어렵기 때문에 활성화 함수를 사용하여 데이터의 폭을 조절한다.

요약하면, 활성화 함수는 딥 러닝 모델의 출력을 결정하는 함수이다. 사용되는 함수는 데이터와 모델의 구조에 따라 달라지며, 올바른 함수 선택은 모델 성능에 큰 영향을 미친다.




그림 8. 딥러닝 훈련 과정

<p>평균 제곱 오차 (Mean Squared Error, MSE)</p>	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
<p>Binary Cross entropy</p>	$BCE = - \sum_{i=1}^2 t_i \log(s_i)$
<p>Sigmoid 함수</p>	$\sigma(x) = \frac{1}{1 + \exp(-x)}$
<p>ReLU 함수</p>	$f(x) = \max(0, x)$
<p>Softmax 함수</p>	$y_k = \frac{\exp(a_k)}{\sum_{j=1}^n \exp(a_j)}$

표 1 손실함수와 활성화 함수 식

### 3. 생성적 적대 신경망 (Generative Adversarial Network)

생성적 적대 신경망은 2014년에 소개된 딥 러닝 모델이다. 생성적 적대 신경망은 기계학습과 딥 러닝 분야에서 매우 혁신적이며 성공적인 모델 중 하나로 손글씨, 숫자 생성부터 이미지 생성, 음성 합성, 자연어 생성 등 다양한 분야에서 응용되고 있다.

생성적 적대 신경망은 생성자라는 신경망과 판별자라는 신경망 두개로 구성된다. 이 두 신경망은 서로 대립적인 목표를 가지고 있으며, 경쟁적인 학습을 통해 모델을 향상시키는 방식으로 작동한다. 먼저 생성자는 랜덤한 노이즈 벡터나 다른 입력 데이터를 받아서 실제와 같은 데이터를 생성하는 역할을 한다. 초기에 생성자는 무작위로 생성한 데이터를 출력하며, 이 데이터는 판별자에 의해 거짓으로 분류된다. 학습 과정에서 생성자는 판별자가 진짜 데이터처럼 생성된 데이터를 거짓으로 판단하지 않도록 실제 데이터와 유사한 데이터를 생성하도록 학습한다. 판별자는 생성자가 생성한 데이터와 실제 데이터를 구분하는 역할을 한다. 초기에는 판별자는 실제 데이터와 생성자가 생성한 데이터를 쉽게 구별할 수 있다. 학습과정에서 판별자는 생성자가 생성한 데이터를 실제 데이터와 구별하기 어렵게 만들기 위해 노력하며, 생성자의 성능을 향상시키기 위한 피드백을 제공한다.

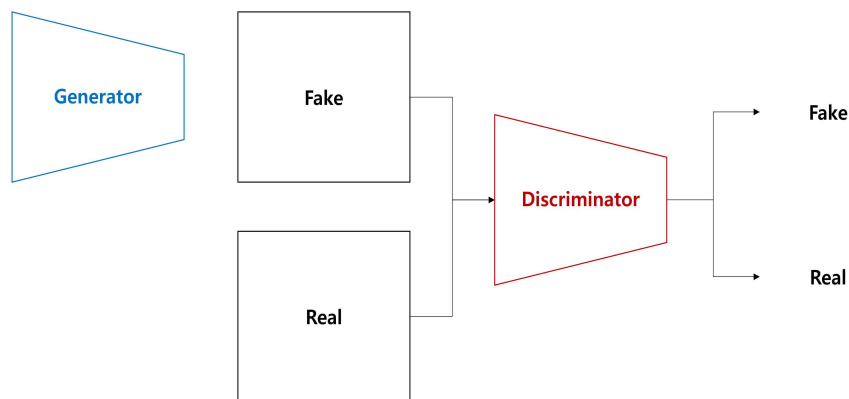


그림 9. 생성적 적대 신경망 아키텍처

생성적 적대 신경망은 생성자와 판별자 간의 이 경쟁적인 학습 과정을 통해 서로를 발전시키는 동적인 시스템이다. 손실 함수를 최적화하여 모델을 훈련한다. 표 1에 생성적 적대 신경망의 minmax 수식이 표현되어 있으며 식별자의 경우에는 주로 L1 손실 함수, 생성자의 경우에는 주로 L2 손실 함수를 사용한다.

이름	수식
minmax	$\min_{\theta_g} \max_{\theta_d} [E_{x \sim p_{data}} \log D_{\theta_d}(x) + E_{z \sim p(z)} \log (1 - D_{\theta_d}(G_{\theta_g}(z)))]$
L1	$L = \sum_{i=1}^n  y_i - f(x_i) $
L2	$L = \sum_{i=1}^n (y_i - f(x_i))^2$

표 2. 생성적 적대 신경망 손실 함수 수식

분류 모델인 판별자와 생성모델인 생성자 간의 경쟁적인 학습 과정은 생성적 적대 신경망의 핵심이다. 이 과정에서 판별자는 위 손실함수의 값을 최대화하려고 노력하며, 생성자는 그 값을 최소화하려고 노력한다.

판별자의 주요 목표는 진짜 데이터와 가짜 데이터를 올바르게 분류하는 것이다.  $D(x)$ 는 진짜 데이터를 입력으로 받았을 때 분류 모델이 이 데이터를 진짜로 판단하는 확률이다.  $D(G(z))$ 는 생성자가 생성한 가짜 데이터를 입력으로 받았을 때 분류 모델이 이 데이터를 진짜로 판단하는 확률이다. 판별자는 가짜 데이터를 가짜로 판별하기 위해 이 값을 최대화하려고 한다. 따라서 판별자는  $D(x)$ 를 1로,  $D(G(z))$ 를 0으로 만들기 위해 훈련된다. 이는 판별자가 진짜 데이터를 진짜로, 가짜 데이터를 가짜로 정확하게 분류하도록 하는 것을 의미한다.

생성자의 주요 목표는 판별자를 속이는 가짜 데이터를 생성하는 것이다.  $D(G(z))$ 는 생성자가 생성한 가짜 데이터를 입력으로 받았을 때 분류 모델이 이 데이터를 진짜로 판단하는 확률이다. 생성자는 가짜 데이터를 진짜로 분류하도록 이 값을 최대화하려고 한다. 따라서 생성자는 판별자를 속이기 위해  $D(G(z))$ 를 1로 만들려 한다. 이는 생성자가 더 현실적인 가짜 데이터를 생성하도록 하는 것을 의미한다.

#### 4. 생성적 적대 신경망 종류

생성적 적대 신경망(GAN)은 다양한 응용 분야와 목적에 맞게 설계된 다양한 모델 아키텍처와 훈련 방법을 갖추고 있다. 몇 가지 주요한 GAN 모델은 다음과 같다. Conditional GAN (cGAN)은 생성자와 판별자에 추가적인 조건 정보를 제공하여 조건부 생성 작업을 수행한다. 예를 들어, 특정 숫자를 생성하도록 생성자에게 지시할 수 있으며, 이것은 숫자 이미지 생성과 같은 작업에 유용하다. CycleGAN은 두 도메인 간의 이미지 변환을 수행하는 모델로, 예를 들어 말 이미지를 얼룩말 이미지로 변환하거나 그 반대로 변환할 수 있다. 이미지 스타일 변환 및 도메인 간 언어 번역과 같은 작업에 사용된다. Wasserstein GAN (WGAN)은 안정적인 훈련과 고품질 이미지 생성을 목표로 하는 변형 중 하나이다. Wasserstein 거리를 사용하여 손실 함수를 정의하며, 모드 붕괴 문제를 줄이는 데 도움이 된다. StyleGAN은 스타일과 다양성을 주입하여 고품질 이미지 생성을 목표로 하는 모델로, 얼굴 이미지 생성과 같은 작업에 주로 사용된다.

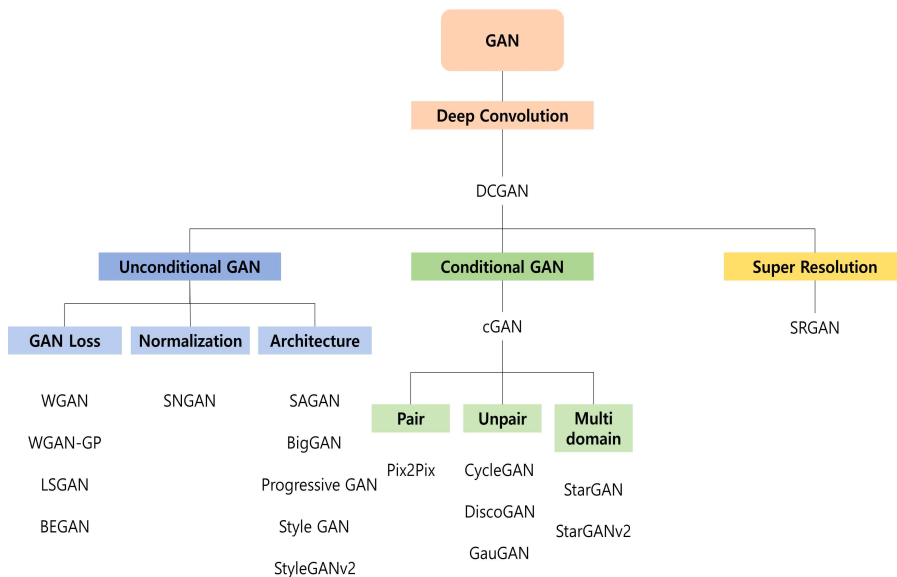


그림 10. 생성적 적대 신경망 모델 종류

연구에서는 Pix2pix GAN을 사용했다. Pix2pix는 이미지 변환 작업에 활용되며, 주로 입력 이미지를 다른 형식의 이미지로 변환하는 것을 목표로 한다. 이는 흑백 사진을 컬러로 변환하거나, 지도 이미지를 실제 사진으로 바꾸는 등의 작업에 쓰인다. 이런 변환 작업은 입력과 출력 이미지간의 직접적인 대응을 학습하는데 중요하다.

Pix2pix GAN은 CGAN의 개념을 확장하여 Paired Image-to-Image translation을 추가했다. 일반적인 GAN과는 다르게 노이즈 벡터 개념을 사용하지 않는다. 이미지가 Generator의 입력으로 들어가고, 변환된 이미지가 출력된다. Discriminator는 Conditional discriminator로 실제/가짜 이미지와 Condition을 입력으로 받는다. 여전히 실제/가짜를 판단하는 역할을 수행한다.

Generator는 U-net 기반으로 구성되어 있어 이미지를 입력으로 받아 오토인코더처럼 작동한다. 이는 인코더와 디코더를 구성되어 있으며, 각 레이어 사이에는 스킵 커넥션을 활용하여 정보를 보존하고, backpropagation 진행 시 vanishing gradient 문제를 방지한다. 이는 다운샘플링 시 손실되는 정보의 보존과 학습 시 그래디언트 소실을 막아 준다.

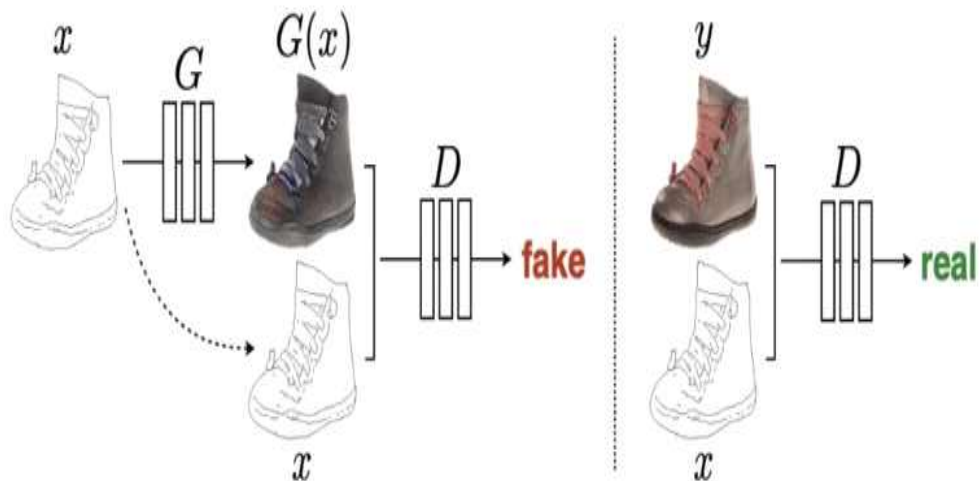


그림 11. Pix2Pix GAN  
\*Image-to-Image Translation with Conditional Adversarial Networks

## 연구방법

### 1. 데이터 수집

표준 12리드 심전도 장치 (Bionet, Cardio7, 대한민국)와 스마트 워치를 동시에 사용하여 심전도를 측정하는 실험을 진행했다. 실험은 참가자가 누워있는 상태에서 표준 12리드 심전도 장치와 스마트 두 기기로부터 심전도 데이터를 동시에 수집하였다. 실험과정에서 심장 전문 간호사가 참가자를 감독하여 안정된 환경에서 데이터를 수집하였다. 표준 12리드 심전도 장치의 전극을 참가자의 몸에 적절한 위치에 부착하고, 표준 12리드 심전도 측정 방법을 따라 심전도 신호를 측정하였다. 또한, 스마트 워치를 왼쪽 손목에 착용하였고, 오른손 검지를 크라운에 올려 단일 리드 심전도 신호를 측정하였다. 실험에는 남자 6명, 여자4명으로 총 10명의 지원자가 포함되었다. 각 참가자에 대해 두 가지 실험을 각각 10회씩 수행했다.

스마트 워치의 심전도 데이터를 평가하기 위해 두 가지 실험을 진행했다. 실험 1에서는 갤럭시 워치 4 Classic (삼성, 대한민국, 서울)과 표준 12리드 심전도 장치를 사용하였고, 실험 2에서는 애플 워치 7 (Apple, USA, Cupertino)과 표준 12리드 심전도 장치를 사용하여 데이터를 수집했다.



그림 12. 사용된 심전도 측정기기

## 2. 데이터 전처리

연구에서는 갤럭시 위치와 표준 12리드 심전도 장치, 그리고 애플 위치의 샘플링 레이트가 서로 다르기 때문에 데이터를 비교하고 분석하기 위해 표준화가 필요했다. 갤럭시 위치와 표준 12리드 심전도 장치의 샘플링 레이트는 500Hz로 동일하지만, 애플 위치는 512Hz로 설정되어 있어 다운 샘플링이 필요했다. 따라서 애플 위치의 데이터를 500Hz로 다운 샘플링하여 일관성 있는 데이터를 얻었다.

또한, 데이터 수집 과정에서 각 기기에서 발생할 수 있는 신호 딜레이를 보정하기 위해 표준 12리드 심전도 장치의 심전도 데이터와 스마트 위치의 심전도 데이터를 R피크를 이용하여 데이터를 동기화하였다. 이렇게 하면 각 기기로부터 얻은 데이터의 타이밍을 일치시켜 비교 가능한 상태로 만들 수 있었다. 뿐만 아니라, 연구에서 사용된 심전도 신호는 베이스라인 드리프트가 0.5Hz 미만으로 유지되었으며, 60Hz의 전력 주파수 간섭이 발생하였다. 이러한 노이즈를 제거하고 데이터의 품질을 향상시키기 위해 Butterworth 3차 0.5-50Hz 대역 통과 필터를 모든 신호에 적용하였다 [23-25]. 해당 실험 개요는 그림에 전처리 과정 후 데이터의 예제는 그림 13에 있다.

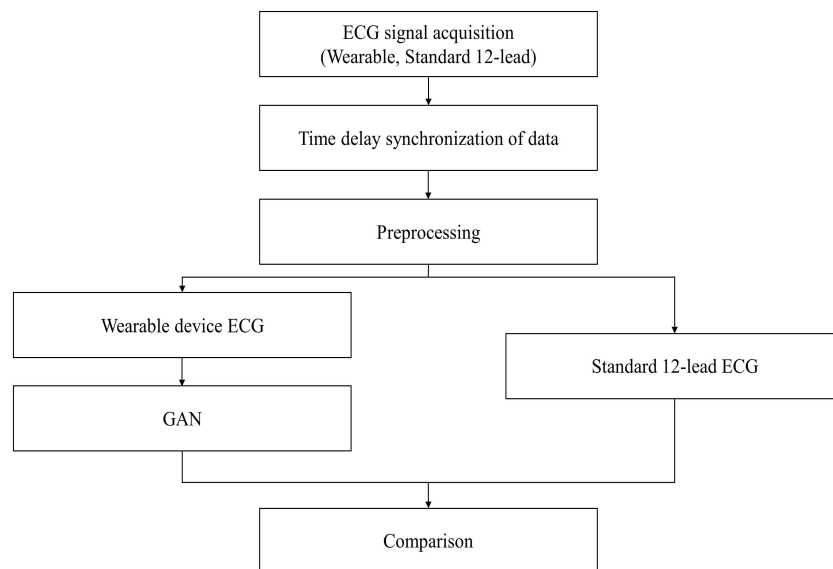


그림 13. 실험 개요






그림 14. 전처리 후 스마트 워치 심전도 데이터 샘플

### 3. 모델

제안된 생성적 적대 신경망은 Pix2pix 모델 [26]을 기반으로 사용된다. 훈련 데이터는 서울아산병원 내부 기록에서 가져온 것이다. 이러한 원시 신호 데이터는 훈련 단계 전에 전처리되었다. 이것은 데이터의 품질과 유효성을 보장하며 모델이 더 효과적으로 학습할 수 있도록 도움을 준다. 데이터는 생성적 적대 신경망 프레임워크를 통해 생성되었으며, 이때 2.5초의 데이터 세그먼트가 4개 모여져 단일 10초 데이터 세그먼트로 결합되도록 구성되었다. 이것은 입력 데이터와 출력 데이터 간의 시간적 일관성을 유지하면서 모델을 훈련하는 데 도움이 된다. 모델의 입력 크기는 (1,1250)이고, 출력 크기도 (1,1250)로 설정되어 있다. 상세한 생성기의 모델은 그림 15에, 판별기 모델은 그림 16에 나와있다.

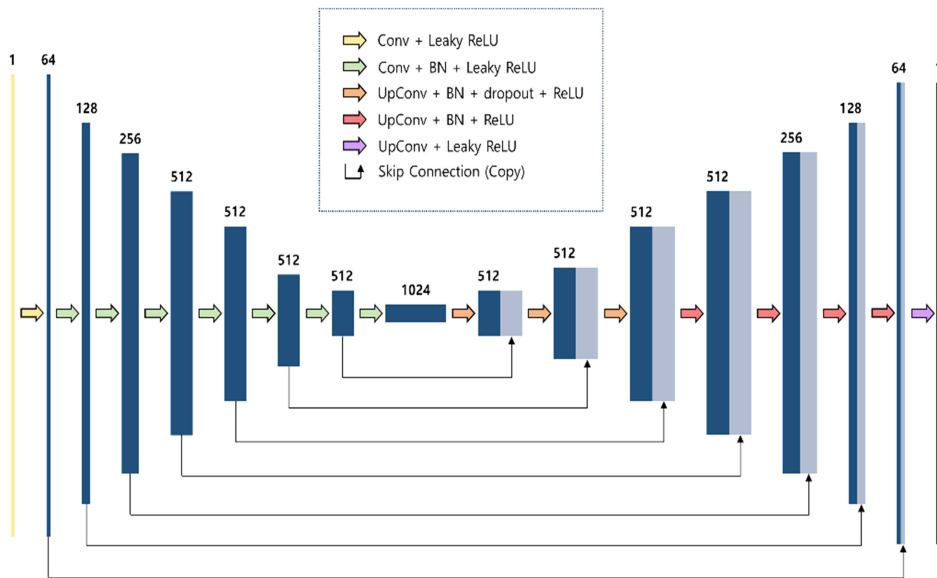


그림 15. U-net 기반 생성기

생성기는 병목 현상을 완화하기 위해 스킵 연결을 사용하는 U-net 기반의 모델이다. 인코더를 위한 7개의 컨벌루션 레이어와 디코더를 위한 7개의 업 컨벌루션 레이어로 구성된다. 레이어에 Leaky ReLU와 ReLU를 적용하였으며, 기울기는 0.2다. 커널 크기와 스트라이드는 각각 4와 2로 설정되었다.

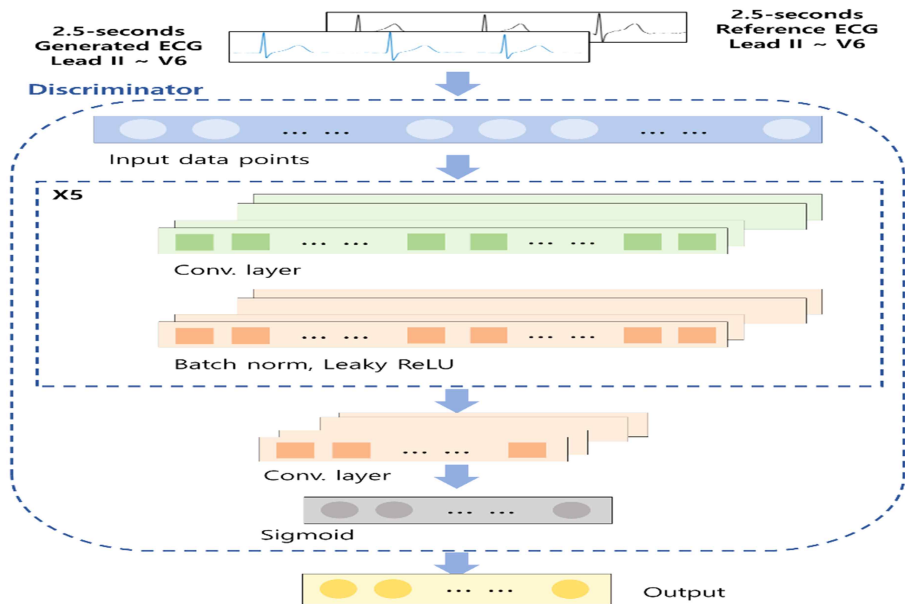


그림 16. 판별기

판별기는 배치 정규화 및 Leaky ReLU 활성화를 갖춘 5개의 컨벌루션 레이어로 구성된다. 출력을 변환하기 위해 마지막 레이어 뒤에 1차원 컨벌루션 레이어를 추가하고 그 뒤에 시그모이드 함수가 온다. 생성기와 판별기의 학습률은 각각 0.00005와 0.00001로 설정되었다. 하이퍼 파라미터는 Adam 옵티마이저를 사용하여 최적화되었으며 배치 크기는 32가 사용되었다. 총 11개의 모델이 훈련되었으며, 각 모델은 11개의 리드 중 하나를 생성하는 역할을 한다.

모델의 전체구조는 그림 17에 나와 있다. 본 연구에서 사용된 훈련 데이터는 서울아산병원 내부의 심전도 데이터이다. 10초 신호를 2.5초로 세그먼트하여 이를 기반으로 학습을 진행한 후, 각 리드별로 11개의 최적화된 모델을 생성한다. 그 다음, 데이터를 입력하고 2.5초 길이의 4개 세그먼트를 결합하여 단일 10초 데이터로 재구성한다. 이를 통해 전체 12리드 심전도를 생성한다.

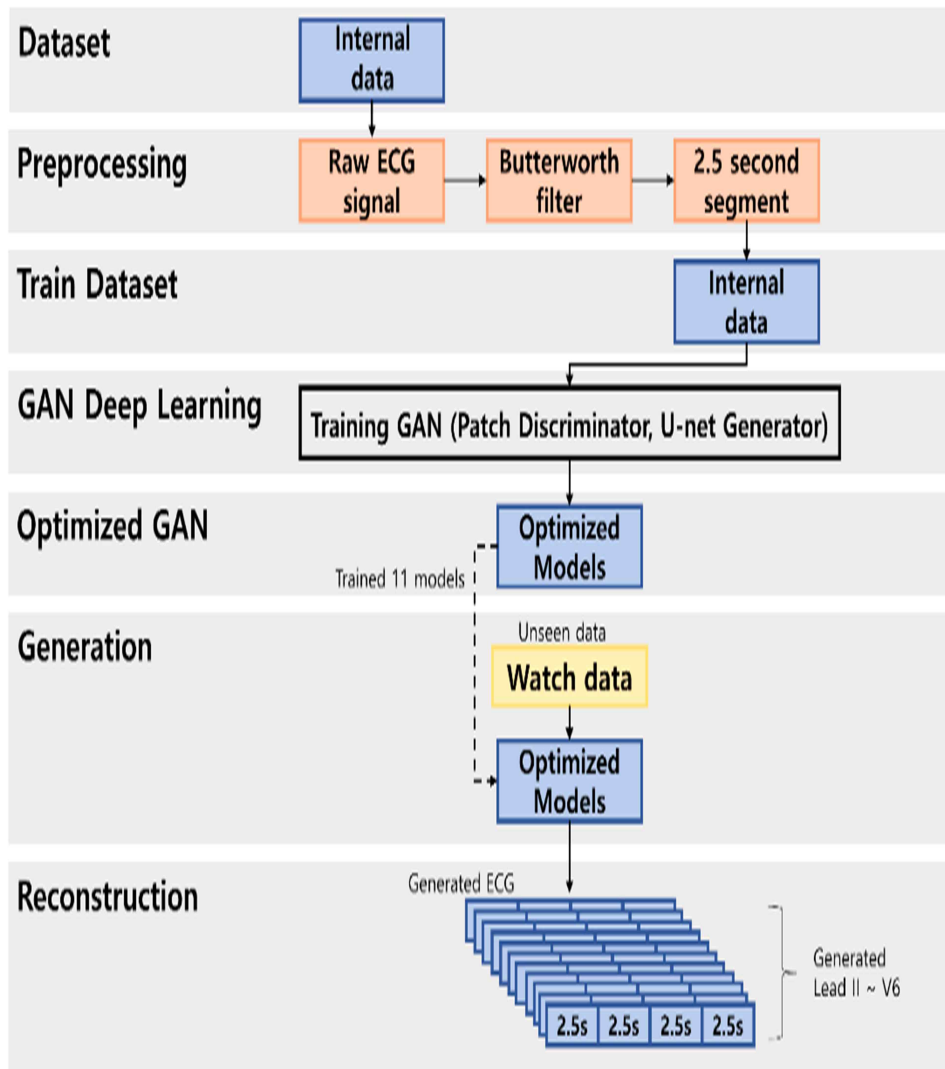


그림 17. 모델 전체 구조

#### 4. 평가 방법

스마트 워치 심전도 데이터를 이용해 생성된 12리드 데이터와 표준 12리드 심전도 장치의 데이터를 비교하고 평가하였다. 총 10초의 데이터 중에 처음 2초의 데이터는 검지를 크라운에 대었을 때 모션 아티팩트가 생기기 때문에 제외되었고, 마지막 2초의 데이터는 참가자가 이완 단계에서 움직임의 영향을 받아 제외해서 6초의 데이터를 분석했다. 데이터 평가 분석은 MATLAB과 Python을 사용하여 수행했다. 모델을 이용한 신호 생성은 Python으로 수행하였고, 신호 처리 및 평가는 MATLAB으로 수행하였다.

생성된 심전도 신호를 평가하기 위해 다양한 방법이 사용된다. 일반적으로 피어슨 상관 계수, 평균제곱오차 (MSE), Fréchet distance (FD) 점수 등의 평가 지표가 많이 사용된다. 따라서 이 세 가지 지표를 사용하여 생성된 심전도 신호를 평가했다.

피어슨 상관 계수는 스마트 워치의 리드 I과 표준 12리드 심전도 장치의 리드 I 간의 유사성을 평가하는데 사용되었다. 이 계수는 두 변수 사이의 선형 상관관계를 측정한다. 값이 1이면 완전한 양의 상관관계를 나타내고 값이 -1 이면 완전한 음의 상관관계를 나타낸다. 높은 상관 계수는 스마트 워치에서 수집된 심전도가 표준 12리드 심전도와 유사하다는 것을 의미한다 [27]. Pearson 상관 계수는 두 변수의 공분산과 표준편차의 곱의 비율로 식1와 같이 표현된다.

$$r_{XY} = \frac{\sum_i^n (X_i - \bar{X})(Y_i - \bar{Y})}{\sqrt{\sum_i^n (X_i - \bar{X})^2 \sum_i^n (Y_i - \bar{Y})^2}}$$

식 1. 피어슨 상관 계수 공식

여기서  $X_i$ 는 표본의 X 변수 값을 나타내고,  $\bar{X}$ 는 X 변수 값의 평균,  $Y_i$ 는 표본의 Y 변수 값을 나타내고,  $\bar{Y}$ 는 Y 변수 값의 평균을 의미한다.

평균제곱오차는 두 신호 간의 평균 차이를 측정하는데 사용되었으며, 이는 두 신호 간의 진폭 차이를 검증하는데 사용할 수 있다. 평균제곱오차 값이 낮을수록 두 신호 간의 차이가 작음을 나타내며, 이는 두 신호 간의 유사성이 더 높다는 것을 의미한다. 평균제곱오차는 식 2와 같이 표현된다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - Y_i)^2$$

### 식 2. 평균제곱오차 공식

여기서  $n$ 은 데이터 포인트 수,  $X_i$ 는 표준 12리드 심전도 값,  $Y_i$ 는 생성된 심전도의 값을 의미한다.

Fréchet distance는 생성된 데이터와 표준 12리드 데이터 곡선 간의 유사성을 평가하는데 사용되었으며 생성된 신호와 표준 12리드 신호의 동기화를 검증할 수 있다 [28]. Fréchet distance는 생성된 이미지를 실제 이미지와 비교하기 위해 이미지 합성 작업에서 일반적으로 사용되는 거리 측정법이다. 생성된 심전도 신호와 표준 12리드 심전도 신호를 비교하는데 사용되었다. Fréchet distance 값이 낮을수록 생성된 신호가 표준 12리드 심전도 신호에 더 가깝다는 것을 의미하며 유사도가 더 높다는 것을 의미한다. Fréchet distance는 생성된 신호와 참조 신호의 특징을 추출하고 해당 신호의 평균과 공분산을 계산한다. 각 특성은 정규 분포를 따르는 것으로 가정된다. Fréchet distance는 식 3과 같이 표현된다.

$$FD(r, g) = \|\mu_r - \mu_g\| + T_r (\sum r + \sum g - 2(\sum r \sum g)^{\frac{1}{2}})$$

### 식 3. Fréchet distance 공식

여기서  $\mu_r$ 과  $\sum r$ 은 각각 참조 데이터에서 추출된 특징의 평균과 공분산이다.  $\mu_g$ 와  $\sum g$ 는 생성된 데이터에서 추출된 특징의 평균과 공분산이다.  $T_r$ 은 대각선 요소의 합이다.

## 결과

생성된 신호를 표준 12리드 신호와 비교하여 두 신호 간의 유사성을 확인했다. 각 스마트 워치에서 얻은 리드 I 신호는 표준 12리드 측정에서 얻은 리드 I 데이터와 비교된다. 실험의 평가 점수는 표3과 같다. 각 값은 10회 측정의 평균이다. 실험 1에서는 갤럭시 워치를 이용하여 리드 I 신호를 획득하였고, 실험 2에서는 애플 워치를 이용하여 리드 I 신호를 획득하였다. Pearson 상관 계수 (R-값)를 사용하여 스마트 워치와 표준 12리드 심전도 간의 유사성을 평가했다. 실험 1과 실험 2의 평균 R 값은 각각 0.9262와 0.9266으로, 두 경우 모두 리드 I 신호와 표준 12리드 심전도 신호 사이에 양의 상관관계가 있음을 나타낸다. 모든 실험에서 P값은 <0.01 이었다. 이러한 결과는 갤럭시 워치와 애플 워치 모두 신뢰할 수 있는 심전도 데이터를 제공할 수 있음을 나타낸다.

	Experiment 1	Experiment 2	Average
Subject 1	0.9842	0.8351	0.9096
Subject 2	0.9112	0.9400	0.9256
Subject 3	0.9332	0.8190	0.8761
Subject 4	0.9700	0.9752	0.9726
Subject 5	0.8929	0.9209	0.9069
Subject 6	0.8278	0.8915	0.8597
Subject 7	0.9129	0.9414	0.9272
Subject 8	0.9661	0.9842	0.9751
Subject 9	0.9571	0.9785	0.9678
Subject 10	0.9069	0.9807	0.9438
Average	0.9262	0.9266	0.9264

표 3. 실험 1과 2에 대한 피어슨 상관 계수 R-값

그림 18은 실험 1에서 얻은 피험자에 대한 데이터 샘플을 시각적으로 나타낸 것이다. 이 그림은 리드 I 데이터를 비교한다. 파란색 선은 스마트워치로 획득한 리드 I 데이터를 나타내고, 빨간색 선은 표준 12리드 장치를 사용하여 얻은 리드 I 데이터를 나타낸다.

이 그림을 통해 두 데이터 세트 간의 유사성과 차이점을 분석할 수 있다. 그림에서 볼 수 있는 것처럼, 두 데이터 세트의 세그먼트와 P-Q-R-S-T 파형은 유사한 패턴을 공유한다. 이는 두 가지 다른 데이터 소스에서 얻은 리드 I 데이터가 서로 비슷한 심전도 신호를 보여주고 있다.




그림 18. 실험1의 리드 I 데이터 샘플 플롯



그림 19는 실험 2에서 얻은 피험자에 대한 데이터 샘플을 시각적으로 나타낸 것이다. 이 그림은 리드 I 데이터를 비교한다. 파란색 선은 스마트워치로 획득한 리드 I 데이터를 나타내고, 빨간색 선은 표준 12리드 장치를 사용하여 얻은 리드 I 데이터를 나타낸다.

이 그림을 통해 두 데이터 세트 간의 유사성과 차이점을 분석할 수 있다. 그림에서 볼 수 있는 것처럼, 두 데이터 세트의 세그먼트와 P-Q-R-S-T 파형은 유사한 패턴을 공유한다. 이는 두 가지 다른 데이터 소스에서 얻은 리드 I 데이터가 서로 비슷한 심전도 신호를 보여주고 있다.




그림 19. 실험 2의 리드 I 데이터 샘플 플롯

그림 20은 실험 1과 실험 2에서 얻은 데이터에 대한 R-값의 분포를 시각적으로 보여준다. 두 실험 모두에서 R-값 분포는 높은 상관관계를 나타낸다. 이는 실험 결과가 특정 변수나 조건 간에 강한 상관성을 가지고 있다는 것을 시사한다. 주목해야 할 점은 두 실험에서 몇 가지 이상 값(outliers)이 나타나고 있다는 것이다. 이상 값은 일반적인 데이터 포인트와는 크게 다른 값을 나타내며 종종 측정 프로세스 중 움직임 또는 기타 외부 요인으로 인해 발생할 수 있다.

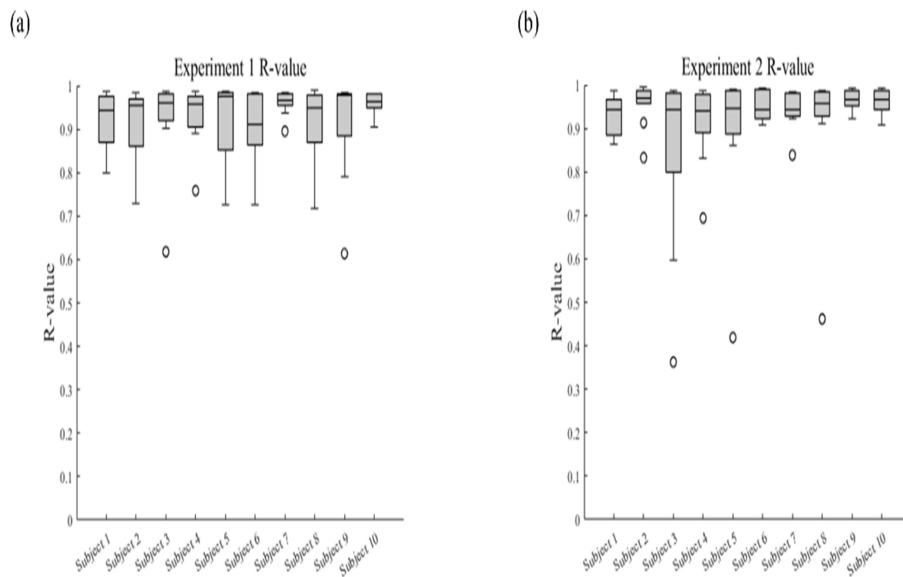


그림 20. 측정된 모든 데이터를 포함하는 실험 1과 2에 대한 피어슨 상관계수 R-값 박스 플롯. 검은색 원은 이상 값을 나타낸다.

그림 21은 LEAD I 신호의 이상치 그림이다. 이상치들은 그림과 같이 스마트 워치의 심전도 데이터에 노이즈가 생겨서 발생하는 것으로 예상할 수 있다.




그림 21. 이상 값 예시

표 4는 각 실험의 평균제곱오차의 평균을 보여준다. 이러한 측정값은 표준 12리드 심전도 값과 비교되었으며, 스마트 워치에서 수집되고 생성적 적대 신경망을 사용하여 생성된 심전도 데이터의 신뢰성을 검증하는데 사용되었다. 평균제곱오차의 평균값은 실험 1과 2에서 각각 0.0528과 0.0545였다. 이러한 값은 스마트 워치에서 얻어 생성된 신호와 표준 12리드 심전도가 약간 다르다는 것을 나타낸다. 그러나 그 값이 상대적으로 작아 차이가 크지 않아, 생성된 심전도 데이터의 신뢰성이 있다는 것을 보여준다.

	<b>Experiment 1</b>	<b>Experiment 2</b>
	<b>MSE (mV)</b>	<b>MSE (mV)</b>
<b>LEAD II</b>	0.0122	0.0117
<b>LEAD III</b>	0.0176	0.0145
<b>aVR</b>	0.0065	0.0072
<b>aVL</b>	0.0045	0.0033
<b>aVF</b>	0.0290	0.0263
<b>V1</b>	0.0395	0.0327
<b>V2</b>	0.1172	0.1159
<b>V3</b>	0.1415	0.1410
<b>V4</b>	0.1300	0.1390
<b>V5</b>	0.0863	0.1091
<b>V6</b>	0.0482	0.0515

표 4. 실험 1과 2의 평균제곱오차 평가 값

표 5는 각 실험의 Fréchet distance의 평균을 보여준다. 평균 FD 점수는 각각 8.7182와 9.0274 였다. FD 점수는 모두 높지 않았다. 이러한 점수는 웨어러블 장치에서 생성된 데이터가 기준 심전도 데이터와 유사함을 나타낸다. 따라서 웨어러블 장치는 신뢰할 수 있는 심전도 데이터를 제공할 수 있으며 생성된 심전도 신호는 기준 신호와 잘 동기화된다는 것을 보여준다.

	<b>Experiment 1</b>	<b>Experiment 2</b>
	<b>FD score (mV)</b>	<b>FD score (mV)</b>
<b>LEAD II</b>	1.8829	1.5633
<b>LEAD III</b>	1.9189	1.7245
<b>aVR</b>	2.3849	2.4649
<b>aVL</b>	0.3773	0.3683
<b>aVF</b>	4.3173	4.0634
<b>V1</b>	4.6941	4.0935
<b>V2</b>	19.3915	19.8396
<b>V3</b>	20.6850	21.3062
<b>V4</b>	21.5723	22.8359
<b>V5</b>	15.4699	16.9971
<b>V6</b>	10.9421	11.9267

표 5. 실험 1과 2의 Fréchet distance 평가 값

그림 22는 실험 1과 2에 대한 Fréchet distance와 평균제곱오차의 분포를 나타낸다. 사지 리드가 흉부 리드에 비해 더 좁은 점수 분포를 나타내는 것으로 나타났다. 표2와 3에서 사지 리드에 대한 평균 평가 점수가 흉부 리드의 평균 평가 점수보다 높음을 볼 수 있고, 이는 생성된 사지 리드 신호가 생성된 흉부 리드 신호에 비해 서로 더 유사함을 나타낸다.

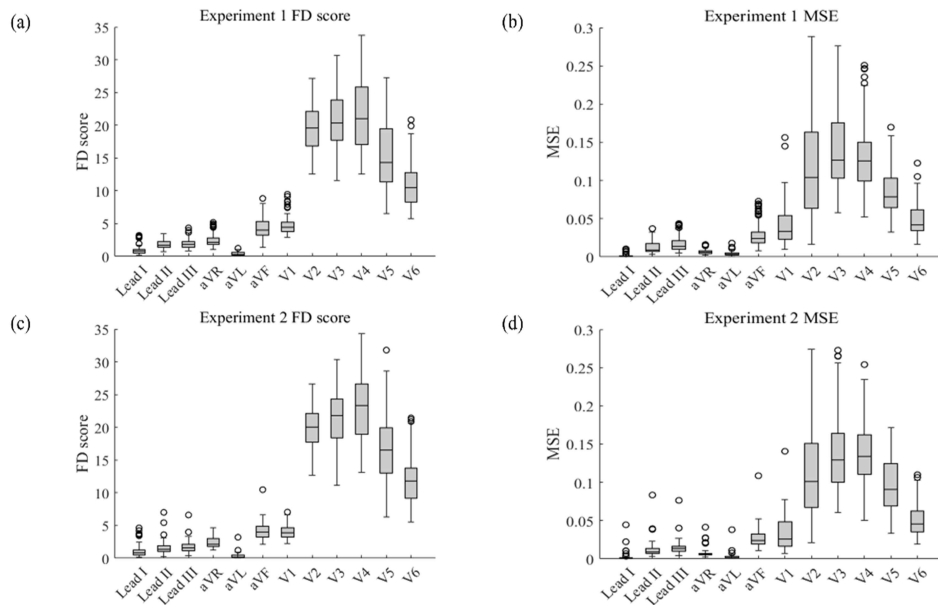


그림 22. 실험 1과 2의 Fréchet distance와 평균제곱오차 박스 플롯

그림 23은 실험 1의 생성된 신호와 표준 12리드 신호를 보여준다. 검은 색 선은 생성된 신호를 나타내고 파란색 선은 표준 12리드 신호를 나타낸다. 생성된 신호는 표준 12리드 신호를 따르며 P-Q-R-S-T 세그먼트도 일치한다.

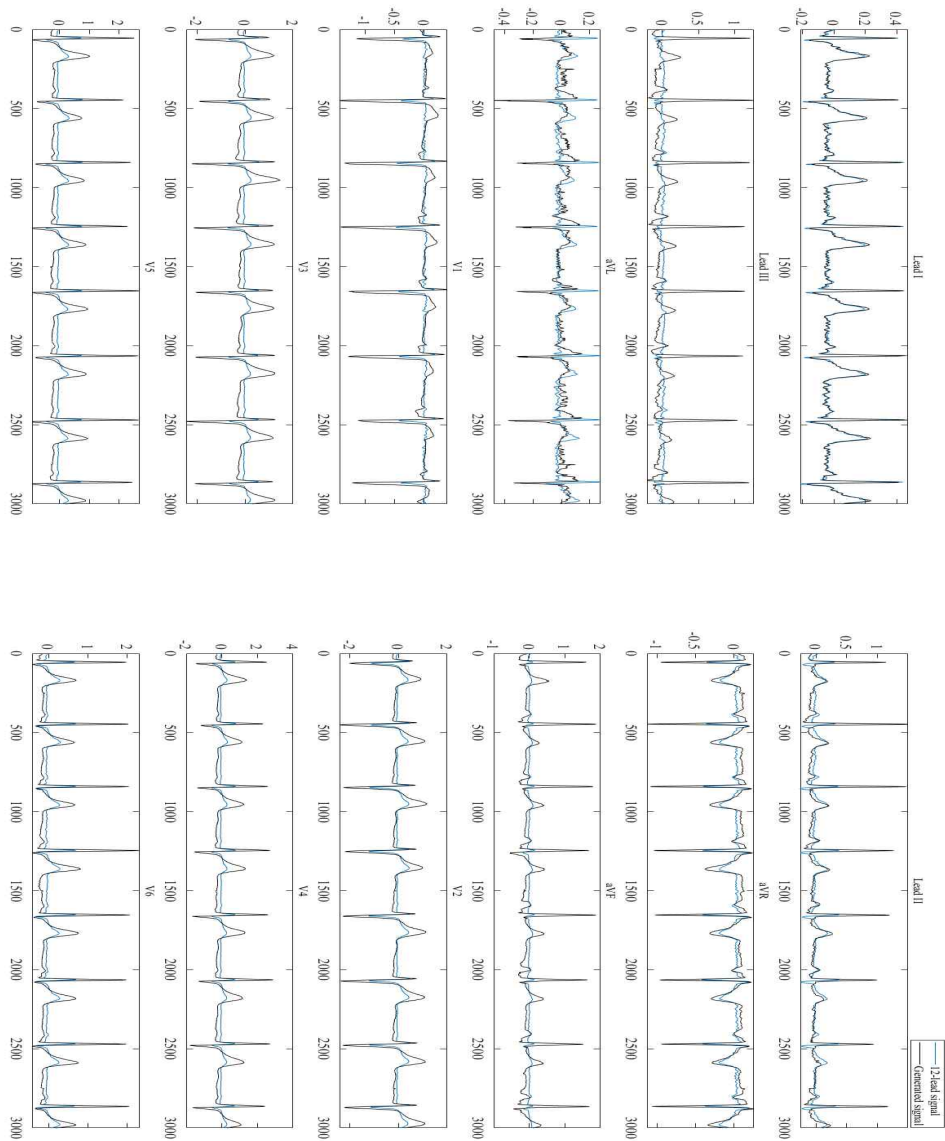


그림 23. 실험 1의 생성된 신호와 표준 12리드 신호의 비교

그림 24는 실험 2의 생성된 신호와 표준 12리드 신호를 보여준다. 검은 색 선은 생성된 신호를 나타내고 파란색 선은 표준 12리드 신호를 나타낸다. 생성된 신호는 표준 12리드 신호를 따르며 P-Q-R-S-T 세그먼트도 일치한다. 실험 1과 실험 2 모두 신호 생성에서 비슷한 점수를 보여 갤럭시 위치와 애플 위치에서 얻은 데이터 간에 큰 차이가 없음을 나타낸다.

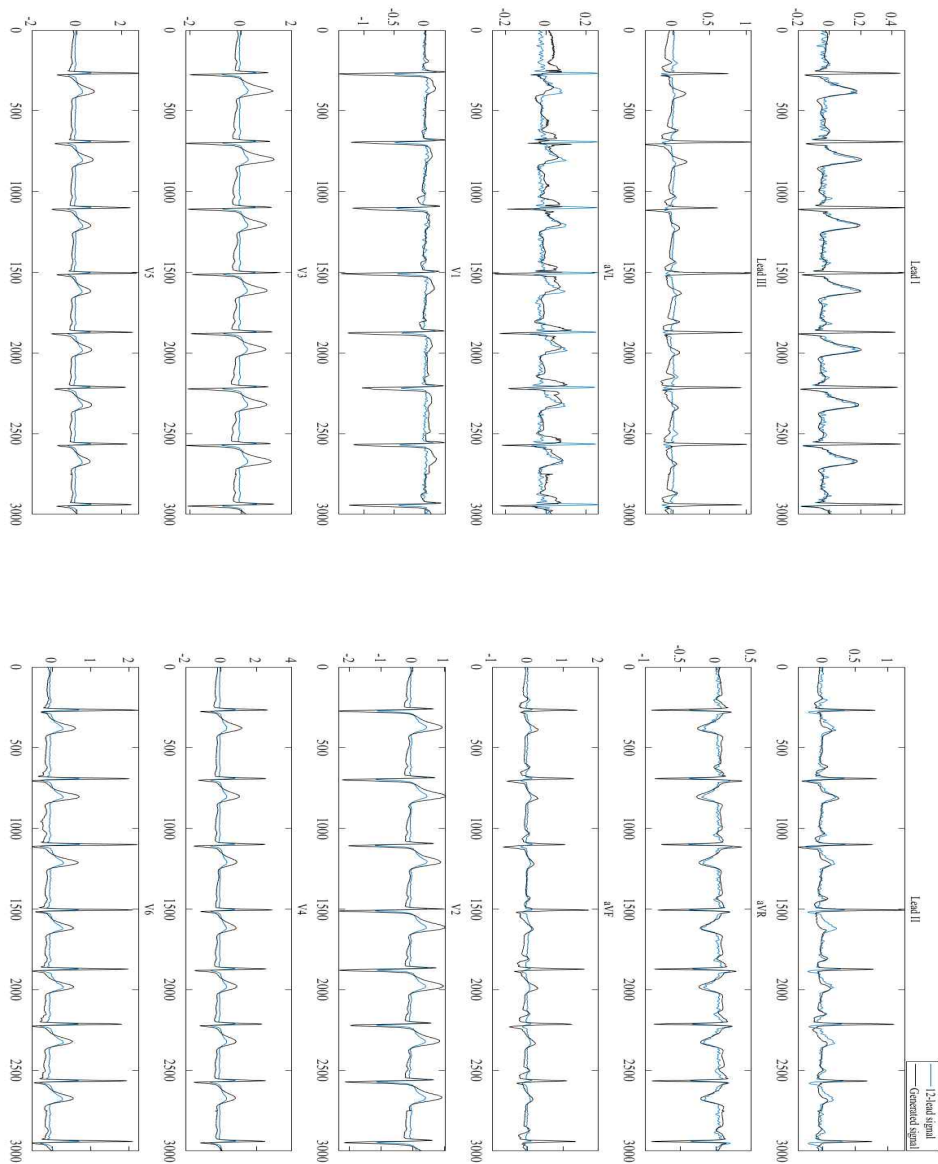


그림 24. 실험 2의 생성된 신호와 표준 12리드 신호의 비교



## 고찰

이전 연구에서는 비동기 데이터, 특히 리드 I 및 리드 II 데이터를 사용하여 12-리드 심전도 신호를 생성했다 [29]. 그러나 리드 I 및 리드 II 데이터를 측정하려면 측정 중에 시계 위치를 움직여야 하므로 번거로울 수 있다. 또한 비동기 데이터의 신호가 일치하지 않아 R-피크 위치나 R-R 간격 등 데이터 지점에 차이가 발생한다. 결과적으로 데이터를 정렬하고 결합하는 과정에서 모델 성능이 저하될 수 있다.

대조적으로, 우리의 연구에서는 리드 I 데이터만 사용하여 보다 정확하고 실용적인 12-리드 심전도 신호를 생성할 수 있었다. 리드 I 데이터에만 초점을 맞추기 때문에 우리 모델은 비동기 데이터를 처리할 필요가 없어 처리가 더 간단하고 정확도가 더 높다. 이 접근 방식을 사용하면 오류가 발생하고 모델의 신뢰성이 저하될 수 있는 복잡한 데이터 통합 기술이 필요하지 않다. 전반적으로 우리 연구에서는 최적의 성능을 달성하기 위해 기계 학습 모델에 대한 데이터를 신중하게 선택하고 처리하는 것이 중요하다는 점을 강조한다. 우리는 생성된 신호가 임상 환경에서 환자 치료와 결과를 개선할 수 있다고 믿는다.

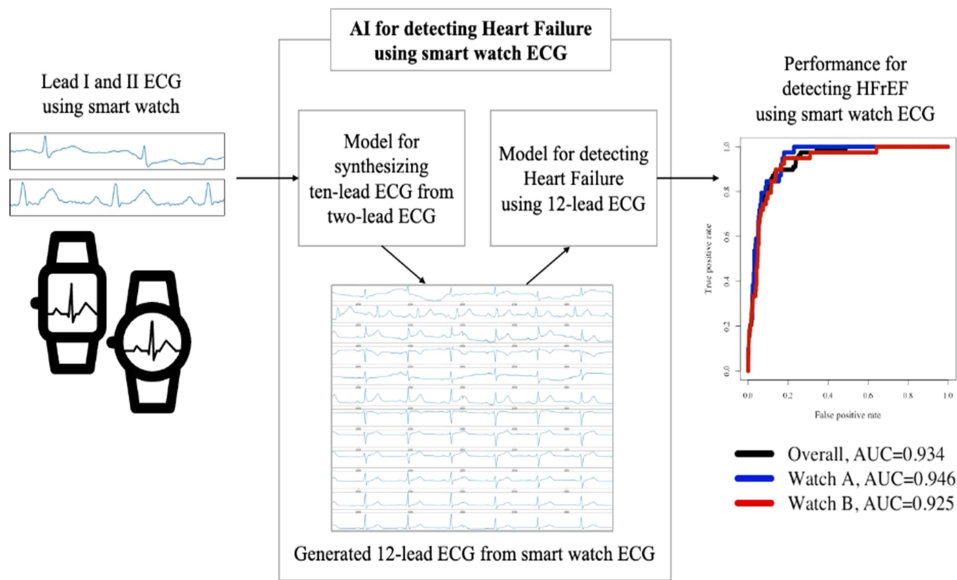


그림 25. 비동기 데이터(리드 I, 리드 II)를 사용하여 12 리드 심전도를 생성하는 이전 연구의 그래픽 초록

\*Artificial intelligence-enhanced smartwatch ECG for heart failure-reduced ejection fraction detection by generating 12-lead ECG

스마트 워치 12리드 심전도 생성의 개발은 웨어러블 건강 모니터링 장치 분야에 중요한 의미를 갖는다. 스마트 워치에서 심전도 신호를 생성하면 기존 심전도 모니터링 장비의 필요성이 줄어들어 심장 건강을 모니터링하는 보다 편리하고 접근 가능한 수단을 제공할 수 있다. 스마트 워치 12리드 심전도 생성의 주요 장점 중 하나는 표준 12리드 심전도 신호와 일치하는 실제적인 심전도 신호를 생성할 수 있다는 것이다. 생성된 신호는 임상적으로 관련이 있으며 의료 진단 및 모니터링에 사용될 수 있다.

또한, 스마트 워치 12리드 생성은 심전도 신호 획득 중에 자주 발생하는 노이즈 및 아티팩트의 영향을 줄여 심전도 신호의 정확도를 향상시킬 수 있는 잠재력을 가지고 있다. 이를 통해 보다 정확하고 신뢰할 수 있는 심전도 판독이 가능하며, 이는 심장 관련 질환을 조기에 발견하고 예방하는데 중요하다 [30-32].

스마트 워치 12리드 심전도 생성에는 여러 가지 다른 이점이 있다. 그 중 하나는 지속적인 심전도 모니터링을 제공하는 기능으로, 이는 표준 심전도 테스트 중에 포착할 수 없는 부정맥이나 불규칙한 심장 박동을 감지하는 데 유용하다. 지속적인 모니터링을 통해 개인은 심박수의 이상에 대해 경고를 받을 수 있으므로 즉시 치료를 받을 수 있다. 스마트 워치가 점점 대중화되고 보편화되면서 개인은 의료 시설을 방문하지 않고도 이동 중에도 쉽게 심장 건강을 모니터링할 수 있다. 이는 이동에 어려움이 있는 개인이나 의료 시설에 접근하기 어려운 외딴 지역에 거주하는 사람들에게 특히 편리할 수 있다. 또한 비싸고 부피가 큰 심전도 모니터링 장비가 필요하지 않아 의료비용을 줄이는 데도 도움이 된다.

단일 리드 심전도에서 생성된 12-리드 데이터를 활용하면 사용자가 신체 활동을 하는 중에도 지속적인 심혈관 모니터링에 유용한 기능을 개발할 수 있어 사용자가 실시간으로 심장 건강을 모니터링하고 필요한 조치를 취할 수 있다. 예를 들어, 사용자가 운동을 하면 심장은 급격한 변화를 경험한다. 스마트 워치는 생성된 12리드 심전도 데이터를 분석해 사용자의 심장 상태를 실시간으로 모니터링하여 비정상적인 신호를 감지하면 사용자에게 경고할 수 있다. 이는 심장이 과로해 생명이 위협받거나 심장질환이 발생했을 때 신속한 대응을 가능하게 한다. 지속적인 심혈관 모니터링은 일상생활에서 유용할 수 있다. 예를 들어, 사용자가 스트레스나 긴장 상태에 있을 때 스마트 워치는 심장의 변화를 모니터링하고 비정상적인 신호를 감지하여 사용자에게 즉시 경고할 수 있다.

이러한 잠재적 이점에도 불구하고 스마트 워치 12리드 심전도 생성의 개발 및 구현에는 여전히 해결해야 할 과제가 있다. 그러한 과제 중 하나는 이러한 장치에서 수집된 심전도 데이터의 개인정보 보호와 보안을 보장하는 것이다. 모든 형태의 건강 데이터와 마찬가지로 심전도 데이터도 무단 액세스 또는 사용을 방지하기 위해 기밀로 안전하게 유지되어야 한다.

스마트 워치 12리드 심전도 생성은 심장 건강 모니터링의 접근성, 정확성 및 편의성을 향상시킬 수 있는 큰 잠재력을 가지고 있다. 이 기술의 한계를 해결하고 임상 진단 및 모니터링에 안전하고 효과적인 사용을 보장하려면 추가 연구 개발이 필요하다. 향후 연구에서는 환자 데이터를 제안된 방법에 통합하여 12-리드 심전도 생성 및 다양한 유형의 심장 질환 진단을 가능하게 할 계획이다. 또한 데이터 추출 없이 실시간 심전도 분석을 생성하고 수행할 수 있는 스마트 워치 내 애플리케이션을 개발할 계획이다.

## 한계

이 연구에는 건강한 개인 10명만 포함된 작은 표본 크기와 같은 몇 가지 제한 사항이 있다. 작은 표본 크기는 다양성이 부족하고 잠재적으로 특정 측면에 대한 과대평가 또는 과소평가로 이어질 수 있으므로 전체 모집단을 정확하게 나타내지 못할 수 있다. 결과적으로 전체 모집단에 대한 작은 표본에서 얻은 결과를 일반화하는 것은 제한적일 수 있다. 따라서 다양한 심장 관련 질환을 진단할 때 생성된 신호의 임상적 효과와 신뢰성을 완전히 결정하기 위해서는 추가 연구가 필요하다.

또한 스마트 워치 12리드 심전도는 아직 개발 단계에 있으며 임상적으로 사용하려면 추가 최적화가 필요하다. 이 연구에서는 심장 건강을 지속적으로 모니터링하는데 중요한 생성된 신호의 장기적인 신뢰성과 정확성을 평가하지 않았다. 이러한 한계에도 불구하고 스마트 워치 12리드 심전도의 개발은 심장 건강 모니터링의 접근성과 정확성을 향상시킬 수 있는 잠재력을 가지고 있다.

사지 리드에서 수집된 심전도 데이터로 인해 흉부 리드의 평가 값이 사지 리드의 평가 값보다 비교적 좋지 않았으나 생성 모델의 구조를 더욱 개선하고 훈련을 개선하면 더 나은 결과를 얻을 수 있다.

심전도의 P-Q-R-S-T 형태는 동일하게 생성되지만 진폭은 동일하게 생성되지는 않는다. 각 환자마다 진폭 값이 상이하며, 데이터 내의 노이즈로 인해 진폭 값이 변하는 것으로 보인다.

## 결론

스마트 워치 12리드 심전도 생성의 개발은 심장 건강을 모니터링하는 편리하고 접근 가능한 수단을 제공함으로써 웨어러블 건강 모니터링 분야에 혁명을 일으킬 가능성이 있다. 생성된 심전도 신호는 표준 12-리드 심전도 신호와 높은 유사성을 나타내며, 이는 생성된 신호가 임상적으로 관련이 있고 의료 진단 및 모니터링에 사용될 수 있음을 나타낸다. 스마트 워치 12리드 심전도 생성은 심장 관련 상태를 조기에 감지하고 예방하는 데 필수적인 심전도 판독의 정확성과 신뢰성을 향상시켜 기존 심전도 모니터링 장비가 필요하지 않게 해준다. 스마트 워치 12리드 심전도 생성의 휴대성과 편의성이 결합된 지속적인 심전도 모니터링 기능은 의료비용을 절감하고 심장 건강 모니터링의 접근성을 향상시키는 데 도움이 될 수 있다.

## 참고문헌

- [1] Macheimer, H., Electrophysiology. Paramecium, 1988: p. 185-215.
- [2] Black, N., et al., Circadian rhythm of cardiac electrophysiology, arrhythmogenesis, and the underlying mechanisms. Heart rhythm, 2019. 16(2): p. 298-307.
- [3] Kennedy, H.L., Ambulatory (Holter) electrocardiography technology. Cardiology Clinics, 1992. 10(3): p. 341-359.
- [4] DiMarco, J.P. and J.T. Philbrick, Use of ambulatory electrocardiographic (Holter) monitoring. Annals of internal medicine, 1990. 113(1): p. 53-68.
- [5] Geselowitz, D.B., On the theory of the electrocardiogram. Proceedings of the IEEE, 1989. 77(6): p. 857-876.
- [6] Sattar, Y. and L. Chhabra, Electrocardiogram, in StatPearls [Internet]. 2022, StatPearls Publishing.
- [7] Mück, J.E., et al., Market and patent analyses of wearables in medicine. Trends in biotechnology, 2019. 37(6): p. 563-566.
- [8] Shirer, M., R. Llamas, and J. Ubrani, Shipments of Wearable Devices Reach 118.9 Million Units in the Fourth Quarter and

336.5 Million for 2019, According to IDC. International Data Corporation (IDC), 2020. 10.

[9] Commission, E., Smart wearables: reflection and orientation paper. 2016, European Commission Brussels, Belgium.

[10] Sana, F., et al., Wearable devices for ambulatory cardiac monitoring: JACC state-of-the-art review. *Journal of the American College of Cardiology*, 2020. 75(13): p. 1582-1592.

[11] Samol, A., et al., Patient directed recording of a bipolar three-lead electrocardiogram using a smartwatch with ECG function. *JoVE (Journal of Visualized Experiments)*, 2019(154): p. e60715.

[12] Samol, A., et al., Recording of bipolar multichannel ECGs by a smartwatch: modern ECG diagnostic 100 years after Einthoven. *Sensors*, 2019. 19(13): p. 2894.

[13] Rajakariar, K., et al., Accuracy of a smartwatch based single-lead electrocardiogram device in detection of atrial fibrillation. *Heart*, 2020. 106(9): p. 665-670.

[14] Chon, K.H. and D.D. McManus, Detection of atrial fibrillation using a smartwatch. *Nature Reviews Cardiology*, 2018. 15(11): p. 657-658.

[15] Wasserlauf, J., et al., Smartwatch performance for the

detection and quantification of atrial fibrillation. *Circulation: Arrhythmia and Electrophysiology*, 2019. 12(6): p. e006834.

[16] Behzadi, A., et al., Feasibility and reliability of smartwatch to obtain 3-lead electrocardiogram recordings. *Sensors*, 2020. 20(18): p. 5074.

[17] Spaccarotella, C.A.M., et al., Multichannel electrocardiograms obtained by a smartwatch for the diagnosis of ST-segment changes. *JAMA cardiology*, 2020. 5(10): p. 1176-1180.

[18] Cobos Gil, M.Á., Standard and precordial leads obtained with an Apple watch. *Annals of internal medicine*, 2020. 173(3): p. 249-250.

[19] Mirza, M. and S. Osindero, Conditional generative adversarial nets. *arXiv preprint arXiv:1411.1784*, 2014.

[20] Goodfellow, I., et al., Generative adversarial networks. *Communications of the ACM*, 2020. 63(11): p. 139-144.

[21] Karras, T., S. Laine, and T. Aila. A style-based generator architecture for generative adversarial networks. in *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*. 2019.

[22] Seo, H.-C., et al., Multiple electrocardiogram generator with single-lead electrocardiogram. *Computer Methods and Programs*



in Biomedicine, 2022. 221: p. 106858.

[23] Mendenhall, G.S. and S. Saba, 12-lead surface electrocardiogram reconstruction from implanted device electrograms. *Europace*, 2010. 12(7): p. 991-998.

[24] Jingwei, D. and J. Wenwen. Design of digital filter on ECG signal processing. in 2015 Fifth International Conference on Instrumentation and Measurement, Computer, Communication and Control (IMCCC). 2015. IEEE.

[25] Ladrova, M., R. Martinek, and R. Jaros. Power line interference elimination in ECG signals. in *Journal of Biomimetics, Biomaterials and Biomedical Engineering*. 2019. Trans Tech Publ.

[26] Isola, P., et al. Image-to-image translation with conditional adversarial networks. in *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017.

[27] Cohen, I., et al., Pearson correlation coefficient. *Noise reduction in speech processing*, 2009: p. 1-4.

[28] Eiter, T. and H. Mannila, Computing discrete Fréchet distance. 1994.

[29] Kwon, J.-m., et al., Artificial intelligence-enhanced smartwatch ECG for heart failure-reduced ejection fraction detection by generating 12-lead ECG. *Diagnostics*, 2022. 12(3): p.

654.

[30] Wang, X., et al., An ECG Signal Denoising Method Using Conditional Generative Adversarial Net. IEEE Journal of Biomedical and Health Informatics, 2022. 26(7): p. 2929-2940.

[31] Antczak, K., A generative adversarial approach to ecg synthesis and denoising. arXiv preprint arXiv:2009.02700, 2020.

[32] Singh, P. and G. Pradhan, A new ECG denoising framework using generative adversarial network. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2020. 18(2): p. 759-764.

## 영문초록 (Abstract)

**Objective:** The thriving smartwatch market has opened up exciting possibilities in the field of fitness and health monitoring through wearable devices. However, a limitation arises when using only two electrodes in smartwatches, allowing for the acquisition of only a single-lead electrocardiogram (ECG) signal. This limitation poses constraints on ECG data acquisition, which, in turn, impacts the detection of heart diseases. To address this limitation, this study aims to compare the 12-lead ECG data generated from smartwatch data using a generative adversarial network (GAN) with standard 12-lead ECG data.

**Methods:** In this study, we collected ECG data from both smartwatches and a standard 12-lead ECG device. Leveraging the power of generative adversarial networks, we employed a GAN to generate 12-lead ECG data from the single-lead smartwatch ECG data. Subsequently, we conducted a detailed comparison between the generated 12-lead ECG data and the standard 12-lead ECG data.

**Results:** The results of our investigation revealed that smartwatches can indeed provide reliable ECG data. We observed a notable positive correlation (average = 0.9264) between the lead I signals obtained from smartwatches and the reference ECG. Furthermore, the mean squared error values (average = 0.05365) were found to be relatively small, indicating that there were no significant differences between the signals. The Fréchet distance scores (average = 8.8728) further substantiated that the generated ECG signal closely synchronized with the reference signal.

**Conclusion:** In conclusion, our study demonstrated that the standard 12-lead ECG signal and the generated ECG signal from smartwatches exhibited a high degree of similarity. This suggests

that the inconvenience associated with changing the placement of the watch for measurements can be eliminated. Consequently, it becomes feasible to generate comprehensive 12-lead ECG data using a single smartwatch, potentially revolutionizing the field of health monitoring and diagnostics. This innovation has the potential to simplify and enhance the way we collect and analyze ECG data for medical purposes, making it more accessible and convenient for both healthcare professionals and individuals.