





2019년 8월 박사학위논문

# 가상 심전도 신호 생성을 이용한 앙상블 합성곱 신경망 기반 사용자 인식 시스템에 관한 연구

# 조선대학교 대학원 제어계측공학과 김 민 구



## 가상 심전도 신호 생성을 이용한 앙상블 합성곱 신경망 기반 사용자 인식 시스템에 관한 연구

A Study on User Recognition System based on Ensemble Convolutional Neural Networks using Synthetic Electrocardiogram Generation

2019년 8월 23일

조선대학교 대학원

제어계측공학과

김 민 구





## 가상 심전도 신호 생성을 이용한 앙상블 합성곱 신경망 기반 사용자 인식 시스템에 관한 연구

지도교수 반 성 범

이 논문을 공학박사학위신청 논문으로 제출함.

2019년 4월

조선대학교 대학원

제어계측공학과

김 민 구





김민구의 공학박사학위논문을 인준함

		(商屋)
위원장	조선대학교 교 수	김윤태 연
위 원	조선대학교 교 수	관근창 (위)
위 원	조선대학교 교 수	정현두 (원)
위 원	고려대학교 교 수	정용화 (위)
위 원	조선대학교 교 수	반성범 (인)
		the state

2019년 6월

조선대학교 대학원





목 차

제1장 서론
제1절 연구 배경
제2절 연구 목적
제3절 연구 내용 및 방법
제2장 기존 심전도 신호를 이용한 사용자 인식
제1절 특징 검출 방법을 이용한 사용자 인식
제2절 딥러닝 기반 사용자 인식
제3절 신경망 모델을 이용한 데이터 생성
제3장 제안하는 심전도 신호 기반 사용자 인식
제1절 잡음제거 및 심전도 신호 분할을 위한 전처리
제2절 사용자 상태 변화에 강인한 앙상블 네트워크 설계
1. 합성곱 신경망 네트워크 구조
2. 제안하는 다층 구조의 앙상블 네트워크 설계32
제3절 데이터 크기 부적합 문제 해결을 위한 가상 데이터 생성37
제4장 실험 결과 및 분석
제1절 실험 방법
1. 심전도 신호 DB44
2. 생성된 가상 심전도 신호의 유사도 검증 방법47
제2절 생성된 가상 심전도 신호의 유사도 결과 및 분석49
제3절 앙상블 네트워크를 이용한 사용자 인식 성능 분석
제5장 결론
참고문헌





### 표 목차

표	1.	구간 및 진폭별 특징점8
표	2.	심전도 신호 공개 데이터베이스 구성
표	3.	딥러닝 신경망의 구조
표	4.	생성자 및 판별자 모델 구조
표	5.	네트워크별 매개변수 설정
표	6.	네트워크 계층별 출력 결과
표	7.	실험자별 코사인 유사도 측정 결과49
표	8.	교차 상관관계 기반 유클리디언 거리를 이용한 유사도 측정 결과52
표	9.	주기별 가상 심전도 신호를 적용한 데이터 구성
표	10.	. 자체 취득한 심전도 신호 실험 데이터베이스 구성
표	11.	. 동일한 심전도 신호를 반복적으로 사용한 데이터 구성
표	12.	. 사용자 인식 성능 비교를 위한 실험 데이터베이스 구성60





### 그림 목차

그림 1. 등록 데이터와 비교 데이터간의 크기 부적합 문제
그림 2. 심박수 및 파형 변화에 따른 심전도 신호 변화4
그림 3. 특징 검출 방법에 따른 심전도 신호 분할 예
그림 4. 웨이블릿 변환을 이용한 잡음 제거 및 특징 추출 방법9
그림 5. Two-steam 기반 합성곱 신경망 구조의 예14
그림 6. 다중 합성곱 신경망을 이용한 앙상블 네트워크 구조의 예15
그림 7. 합성곱 신경망과 순환 신경망을 이용한 앙상블 네트워크 구조의 예16
그림 8. Variational autoencoder 구조
그림 9. Super resolution GAN의 생성자와 판별자 모델 구조19
그림 10. Personalized GAN의 생성자 모델 흐름도
그림 11. LSTM 네트워크를 이용한 시계열 데이터 생성
그림 12. 데이터 수 증가별 인식률 비교
그림 13. 제안하는 가상 심전도 신호 생성을 이용한 사용자 인식 시스템23
그림 14. 잡음제거 및 신호 분할 흐름도
그림 15. 다중 필터를 이용한 잡음 제거 및 분할 결과
그림 16. 1차원 합성곱 신경망 계층 구조
그림 17. 과적합 문제 확인 방법
그림 18. 데이터 확장 방법을 적용한 1차원 심전도 결과
그림 19. Dropout 예시
그림 20. 제안하는 다층 구조의 앙상블 네트워크 흐름도32
그림 21. 다층 구조의 단일 합성곱 신경망33
그림 22. 재학습을 위한 단일 네트워크

Collection @ chosun



그림 23.	적대적 생성 신경망 구조
그림 24.	적대적 생성 신경망 프레임워크
그림 25.	적대적 생성 신경망의 모드 붕괴 예40
그림 26.	보조 분류기를 사용한 적대적 생성 신경망 구조41
그림 27.	제안한 생성자와 판별자 네트워크 구조42
그림 28.	학습 횟수별 가상 심전도 신호 생성 결과43
그림 29.	심전도 신호 취득 예45
그림 30.	심전도 신호 변화를 위한 사용자 상태 정의46
그림 31.	τ=0일 때 교차 상관관계 ······48
그림 32.	<i>τ</i> =−1일 때 교차 상관관계48
그림 33.	τ=1일 때 교차 상관관계 ······49
그림 34.	심전도 신호 간 교차 상관관계 결과
그림 35.	유클리디언 거리를 이용한 교차 상관관계 유사도 측정
그림 36.	클래스간 교차 상관관계를 이용한 심전도 신호 결과
그림 37.	실제 심전도 신호와 가상 심전도 신호 비교
그림 38.	등록 데이터 크기 설정을 위한 주기별 사용자 인식
그림 39.	사용자 상태 변화에 따른 심전도 신호 변화
그림 40.	사용자 상태 변화에 따른 인식 성능 결과
그림 41.	자체 취득한 심전도 신호를 이용한 기존 연구와 인식 성능 비교57
그림 42.	주기별 가상 심전도 신호를 적용한 인식 성능 결과
그림 43.	동일한 심전도 신호를 반복적으로 적용한 인식 성능 결과60
그림 44.	실제 심전도 신호와 가상 심전도 신호를 적용한 인식 성능 비교61



### ABSTRACT

A Study on User Recognition System based on Ensemble Convolutional Neural Network using Synthetic Electrocardiogram Generation

Kim, Min-Gu

Advisor : Prof. Pan, Sung Bum, Ph.D. Department of Control & Instrumentation Graduate School of Chosun University

As information and communication technology develops, the smart environment is built to which IoT is applied. While identity authentication used in various fields along with the smart environment is very important, researchers have studied biometrics very secure and easy to use. Biometrics is the technical term for user's body measurement and calculation based on physiological and behavioral features to send important information to a security system. Typical biometrics is for measuring faces, fingerprints, iris and voice. However, because using the information in the physiological and physical format exposed superficially can be at risk of forgery and





modification, problems occur where applied to fin-tech, smart health care, and position-based services requiring high levels of security. To address this issue, user recognition using biometric signals, for example, ECG, has been studied. Researchers have studied the ECG signals as one of biometric signals, which do not involve stimulation and are not prone to be forged or modified to use them as a next-generation user authentication technology.

The following problems should be addressed to use the ECG signal-based user recognition in the real environment. While the ECG signals are time-series data acquired as time elapses, it is required to acquire comparative data the same in size as the registered data every time. If the comparative data the same as the registered in size is not acquired, it is impossible to use the data for user recognition because of different data size. Furthermore, the heart rates and waveform of ECG signals change depending on personal physical activities, mental effects, or measured time bands although they are from the same user. If the data acquired while the concerned user state changes is used as a registered data. data regularization occurs result in overfitting lowering to recognition performance for the new data acquired.

Therefore, this study suggests a network model of GAN(Generative Adversarial Network) based on an auxiliary classifier able to generate synthetic ECG signals to address the different data size issue. GAN is a method for making the generative model creating data confront the discriminative model discriminating between real data and generated data to improve performance each other. As the number of neural network layers increases, the generative model does not generate data similar to the real



- 6 -



ECG signal, and the values of generated ECG signals because of data loss in the training process are distributed on the contrary. In this study, the generative model is designed to have an architecture of 9 convolutional layers, 2 pooling layers and a fully-connected layer. Because the discriminative model simply discriminates the real ECG signal and class information from the synthetic ECG signal and class information, it is designed to be a single convolutional network repeating convolutional operations not deeper than the generative model. Cosine similarity and Cross correlation are used to examine the similarity of synthetic ECG signals. The examination shows that cosine similarity for 89 participants was measured, which lied between 0.974 and 0.998 inclusive, and the average similarity was 0.991. The similarity measured by using the Euclidean distance based on cross correlation lied between 0.136 and 0.364 inclusive, and the average similarity was measured 0.25. This addressed the different data size issue by examining generation of synthetic ECG signals similar to the real ECG signals to create synthetic data although the registered data is not the same as the comparative data in size.

Moreover, the multi-layer ensemble network is suggested to address the overfitting issue lowering recognition performance because of user state changes. First, the ECG signals are used as input data into the convolutional neural network in multi-layer architecture while the data showing heart rates and waveform changes are measured from participants before/after physical exercises and while they lie on the bed and stand. Respective convolutional neural networks were set up to have parameters different for each network to detect different features. The resultant ECG



- 7 -



signals from each network were classified for each participant, and were integrated into one database to be used as a registered data for re-training. Using the result of low recognition rate resulting from parameters and wrong network design as the registered data contributes rather to lowering recognition performance. The registered data is configured by integrating only the ECG signals in the top-3 network showing good performance, not all result acquired from each network to correct the issue. User recognition is conducted for the reconfigured registered data by retraining the comparative data independent of time for the convolutional neural network.

A comparative experiment was conducted by applying the real ECG signals acquired for this study to the single convolutional neural network using 2-dimensional ECG images, the one-dimensional convolutional neural network and the multi-layer ensemble network suggested in this study to address the conventional overfitting problem. In the experiment. the sinale convolutional neural network using 2-dimensional ECG images and the multi-layer convolutional neural network showed 94.4% and 95.7% of accuracy. respectively. The multi-layer convolutional ensemble neural network suggested in this study showed 98.5% of accuracy, implying better recognition performance than prior studies. Overfitting which occurs when the ECG signal acquired user state changes is used as a comparative data is addressed by the multi-layer ensemble neural network suggested in this study.

Because it is hard to acquire a comparative data the same as the registered data in size in the real environment, and heart rates and



- 8 -



waveform change as user state changes, recognition performance is lowered. Therefore, the synthetic ECG signals generated to address the different data size issue from the acquired ECG signal in the real environment were made into various combinations for each period to make the comparative data. It was then applied to the multi-layer ensemble network suggested in this study to conduct the user recognition experiment.

The experiment showed 98.5% of recognition performance while using 5 periods of the real ECG signals, and 98.7% and 97% of accuracy, respectively, while repeating one synthetic ECG signal period and the last fourth period for the last period of the 4 real ECG signal periods. While using 2 synthetic ECG signal periods for the real 3 ECG signal periods, it showed 97.2% of accuracy, and the accuracy while repeating the last 3 periods for 3 real ECG signal periods was 96% which is 1.2% lower than the performance by using synthetic ECG signals. Therefore, although the registered data is different in size from the comparative data, the different data size and overfitting issues were addressed by applying the synthetic ECG signals generated as user state changes to the multi-layer ensemble network to demonstrate applicability to the real environment.



- 9 -



### 제1장 서론

#### 제1절 연구 배경

정보화 사회로의 급격한 변화와 다양한 시스템 및 기기들의 증가로, 개인의 신 원 확인을 위한 연구들이 활발하게 이루어져 실제 생활에 사용되고 있다. 실생활 에 사용되고 있는 기존 사용자 인식 방법은 패스워드와 같은 지식기반 사용자 인 식 방법, OTP와 같은 소유기반 사용자 인식, 얼굴·지문과 같은 생체정보 기반 사 용자 인식 방법이 있다[1]. 지식 및 소유 기반 사용자 인식 방법은 사용자가 가지 고 있는 지식이나 소유물을 확인하여 인식하는 방법으로 다른 인식 시스템에 비해 저렴한 비용으로 사용이 가능하다. 그러나 이러한 방법은 사용자가 패스워드를 잊 어버리거나 OTP, ID카드 등을 분실하는 경우 관리 비용이 추가로 발생하며 보안이 취약한 문제점이 있다[2][3].

- 보편성(Universality) : 개인 식별을 위해 모든 사람들에게 부여된 정도
- 특이성(Distinctiveness) : 개인별 뚜렷한 특징으로 구성되어 있는 정도
- 영구성(Permanence) : 주어진 기간 동안 절대 변화하거나 변경되지 않은 정도
- 획득성(Collectability) : 생체특성정보 추출 및 정량화가 용이한 정도
- 정확도(Performance) : 개인 식별의 정확성 정도
- 용인성(Acceptability) : 실생활에서 사용자에게 거부감이 없는 정도
- 강건성(Circumvention) : 신뢰도 높은 보안을 제공하여 기만하기 쉬운 정도

생체정보를 이용한 사용자 인식 방법은 지문, 홍채, 얼굴, 음성 등과 같은 신 체의 특징이나 걸음걸이, 서명 등과 같은 사용자의 행동 패턴과 같은 특징을 정보



- 1 -

로 사용자를 인식한다. 이러한 속성들이 사용자 인식으로 사용되기 위해 다음의 몇 가지 특성을 갖고 있어야 한다[4]. 지문·얼굴과 같은 생체정보 기반 사용자 인식 기술은 분실 위험이 없으며 낮은 거부감으로 이미 실생활에 적용되고 있다. 그러나 외형적으로 표출된 해부학적, 물리학적 형태의 정보를 이용하는 것으로 위·변조 문제에 취약하며 사용자의 협조가 요구되는 대면 방식으로 반드시 사용 자가 개입해야 하는 단점이 있다. 또한 생체정보 기반 사용자 인식은 일반 비밀번 호와 달리 유출 시, 변경이 어려우며 인종, 병력 등 부가적인 정보 추출이 가능하 고 사용자의 동의없이 수집이 가능하기 때문에 사용자의 개인 정보 유출과 함께 금전적 손실로 이어지는 사회적인 문제점이 발생하고 있다.

최근 사용자 인식 기술로 연구되고 있는 심전도와 같은 생체신호 기반 사용자 인식 방법은 신체 내에서 발생하는 고유 특성의 신호를 사용하여 거부감이 적어 차세대 사용자 인식 방법으로 연구되고 있다. 생체신호는 살아있는 모든 사람에게 서 측정이 가능하며, 시간이 지나도 신호의 파형이 크게 변하지 않아 등록을 자주 해주지 않아도 되고, 생리학적 요인에 의해 개인 고유의 특성을 가지기 때문에 개 인 간의 구별이 뚜렷하다. 또한, 외형적으로 표출된 해부학적, 물리학적 형태를 이용하는 생체정보에 비해 생체신호는 신체 내부에서 발생하는 신호로 외부적으로 보이지 않으며 신호가 복잡하여 위·변조의 위험성이 낮아 보안 측면에서도 강점 을 나타낸다[5][6]. 심전도 신호는 반복적이고 반 주기성(Semi-periodic)을 갖는 신호로서 특정한 특징 점들이 존재하며, 특징점들을 적절히 이용함으로써 사용자 인식을 위한 특징 추출이 가능하다. 일반적으로 심전도 신호의 한 주기는 심방의 탈분극에 의해 발생하는 P파, 심실의 탈분극에 의해 발생하는 QRS파, 그리고 심실 의 재분극에 의한 T파로 구성된다. 따라서 개개인의 고유한 특징을 이용하여 개인 식별이 가능하며, 위치한 장소에 제한없이 측정되는 심전도 신호를 이용하여 사용 자를 인식할 수 있다[7].



#### 제2절 연구 목적

현재 상용화 되고 있는 사용자 인식 방법의 도난, 복제, 분실, 위·변조와 같 은 문제점으로 인해 낮은 거부감과 높은 편의성 및 보안성에 대한 요구가 증가하 여 생체신호를 이용한 사용자 인식 시스템에 대한 연구가 활발히 진행되고 있다. 사용자 인식 방법에 연구되고 있는 생체신호 중 심전도 신호는 심장의 위치, 크 기, 구조, 나이, 성별 등의 요인들에 따라 자율적으로 발생하는 신호의 특징들이 개인마다 고유하게 나타나는 생체신호이다[8]. 심전도 신호는 주로 질병 검출을 위해 임상적 진단을 목적으로 사용되었으나, 2001년에 심전도 신호를 이용한 사용 자 인식 기술이 처음 제안되었다. 그 후 사용자 인식 알고리즘과 심전도 신호의 측정 채널 수 및 측정 상태에 따른 연구가 진행되어 심전도 신호를 이용한 사용자 인식 가능성을 보여주었다[9][10].



그림 1. 등록 데이터와 비교 데이터간의 크기 부적합 문제



그러나 기존 심전도 신호를 이용한 사용자 인식 연구에 사용되는 데이터베이스 는 초기 실험환경 설정에서 등록 데이터와 비교 데이터를 동일한 크기로 구성하고 있다. 심전도 신호는 시간변화에 따라 취득되는 시계열 데이터로 충분한 시간을 갖고 비교 데이터를 취득할 경우 사용자 인식에 적용 가능하지만, 비교 데이터 취 득 시간이 부족하여 등록 데이터와 동일한 크기가 아닐 경우 데이터 크기 부적합 문제가 발생하여 사용자 인식에 적용할 수 없다. 예를 들어 얼굴 영상과 같은 2차 원 데이터는 취득 장비와 사용자간의 거리에 따라 다른 크기의 비교 데이터를 취 득할 경우, 이미지 확대·축소 및 보간법과 같은 정규화를 통해 데이터 크기 부적 합 문제를 해결할 수 있다. 그러나 기존의 데이터 정규화 방법을 시계열 데이터인 심전도 신호에 적용하여 동일한 크기의 데이터로 변환할 경우, 그림 1과 같이 P, QRS, T파의 시간 정보, 진폭, 간격 등 중요한 특징 정보가 손실되어 사용자 인식



그림 2. 심박수 및 파형 변화에 따른 심전도 신호 변화

또한, 기존 심전도 기반 사용자 인식 연구들은 대부분 심박수(Heart rate) 및 파형 변화의 영향을 최소화하기 위해 동일한 상태의 데이터만을 사용하거나, 시간 에 독립적인(Time-independent) 심전도 데이터만을 이용하기 위해 하루 동안 1회 측정한 데이터를 가지고 인식 알고리즘에 적용한 경우가 대부분이다[13][14]. 그 러나 심전도 신호는 개인의 신체적 활동이나 측정 시간대 또는 정신적 영향에 의 해 심박수 및 파형이 변화하며, 이에 따라 파형이 크게 변화하는 구간과 상대적으 로 변화가 적은 구간이 발생한다. 실제 그림 2와 같이 운동 전 상태의 심전도 신 호와 운동 후 상태의 심전도 신호 파형을 비교할 경우, P파와 T파가 QRS 구간에 더 가까이 발생하는 것을 볼 수 있다. 즉, 동일한 환경에서 취득된 심전도 신호가 아닌 사용자 상태 변화에 따라 취득된 심전도 신호를 비교 데이터로 사용할 경우, 사용자 인식 성능의 저하 원인으로 나타난다.

따라서 등록 데이터와 비교 데이터의 크기가 일치하지 않더라도 사용자 인식 시스템에 적용하기 위해 데이터 크기 부적합 문제를 해결하고 사용자 상태 변화에 따라 취득된 데이터를 적용할 수 있는 인식 알고리즘을 통해 실생활 환경에서 높 은 사용자 인식 성능을 나타내는 연구가 필요하다.

#### 제3절 연구 내용 및 방법

심전도 신호는 시간 변화에 따라 취득되는 시계열 데이터로 등록 데이터의 크 기와 동일한 크기의 비교 데이터를 취득하지 못할 경우, 데이터 크기 부적합 문제 로 인해 사용자 인식 방법에 적용할 수 없다. 따라서 실제 심전도 신호와 유사한 가상 심전도 신호를 생성하여 등록 데이터와 동일한 크기로 구성하며 높은 인식 성능을 나타내야 한다. 본 논문에서는 등록 데이터와 비교 데이터 간의 크기 부적 합 문제를 해결하기 위해 데이터 생성에서 뛰어난 성능을 보이는 적대적 생성 신 경망(GAN : Generative adversarial network)을 이용한다[15]. GAN은 데이터를 생



- 5 -



성하는 생성자(Generator)와 이 모델에서 생성된 데이터와 실제 데이터를 구분하 기 위한 판별자(Discriminator)로 구성되어 학습과정에서 대립관계를 통해 서로의 성능을 향상시키는 방법이다. 그러나 GAN은 불안정한 학습과정으로 인해 다양한 데이터를 생성하지 못하는 문제점이 있다[16]. 따라서 클래스 정보를 보조 분류기 (Auxiliary classifier)로 사용한 ACGAN을 설계하여 실제 심전도 신호와 유사한 가상 심전도 신호를 생성하는 방법을 제안한다[17].

다음으로 사용자 상태 변화에 따라 취득된 데이터를 입력받기 위해 기존에는 많은 데이터 처리가 가능한 딥러닝을 이용한 단일 네트워크 기반 사용자 인식 방 법이 연구되고 있다. 그러나 딥러닝 기반 단일 네트워크에 사용자 상태 변화에 따 라 취득된 데이터를 입력 받을 경우, 많은 데이터에 대한 데이터 일반화로 인해 새로운 데이터에 대해 인식 성능이 저하되는 과적합 문제가 발생한다. 따라서 본 논문에서는 심박수 및 파형 변화를 나타내는 운동 전·후 그리고 누워있는 상태, 서있는 상태에서 취득된 데이터를 처리하기 위한 다층 구조의 앙상블 네트워크 구 조를 제안한다. 앙상블 방법은 성능 향상을 위해 서로 다른 모델들을 조합하는 방 법으로 본 논문에서는 성능 향상뿐만 아니라 과적합 문제를 해결하기 위해 다수의 단일 네트워크 모델을 설계한 후, 각 네트워크에서 출력된 데이터를 하나의 등록 데이터로 구성한다. 각 네트워크에서 출력된 데이터들로 구성된 등록 데이터는 동 일한 구조의 단일 네트워크로 설계된 합성곱 신경망에 재학습을 진행하여 비교 데 이터에 대해 사용자 인식 성능 결과를 확인한다.

본 논문의 구성은 다음과 같다. 1장의 서론에 이어 2장에서는 기존 심전도 신 호를 이용한 사용자 인식 및 가상 데이터 생성 방법에 대해 소개한다. 3장에서는 본 논문에서 제안하는 가상 심전도 신호 생성을 이용한 앙상블 합성곱 신경망 기 반 사용자 인식 방법에 대해 세부적으로 설명한다. 4장에서는 가상 데이터 생성 및 사용자 인식 성능 결과를 분석하고 5장에서 본 논문의 결론과 향후 연구 방향 을 제시한다.



### 제2장 기존 심전도 신호를 이용한 사용자 인식

#### 제1절 특징 검출 방법을 이용한 사용자 인식

심전도 신호를 이용한 기존 연구들은 크게 기준점 기반 사용자 인식 방법과 비 기준점 기반 사용자 인식 방법으로 나눌 수 있다. 기준점 기반 연구 방법은 심전 도 파형 특징인 P, QRS T파 등과 파형간의 여러 가지 거리 조합 등을 통해 이루어 진 특징 값을 이용한다. 비 기준점 기반 연구 방법은 심전도 파형의 형태학적 특 성에 대한 위상 공간 분석이나 신호 변환 방법 등을 통해 출력된 특징 값을 이용 한다.



(a) P, QRS, T파 특징을 이용한 기준점 검출 예
 (b) 형태학 특징을 이용한 비 기준점 검출 예
 그림 3. 특징 검출 방법에 따른 심전도 신호 분할 예

Israel은 심전도 신호를 이용한 사용자 인식을 위해 전처리, 특징 추출, 분류 방법으로 구성된 심전도 신호 기반 시간적 특징을 이용한 사용자 인식 시스템을 제안하였다. 1.1~40Hz에서의 시간적 특징 추출하기 위해 필터를 적용하고, 잡음 속성을 갖는 스펙트럼 요소 부분을 제거하였다. 제거된 심전도 신호에 대해 P, QRS, T 파를 검출한 후, 평균, 스펙트럼 차이, 푸리에 대역 통과 필터를 적용하여 15개의 특징을 추출하였다. 분류 방법에는 선형 판별 분석을 이용하여 분류를 수





행하였다. 29명의 피험자에 대해 실험한 결과 100% 피험자 인식률과 82%의 심전도 비트 인식률의 결과를 보였다. Wang은 심전도 신호로부터 시간, 진폭과 R 파형의 특징들을 결합하여 이용하는 방법을 제안하였다. 전처리된 심전도 신호를 시간과 진폭 거리를 측정하기 위해 기준점 검출을 수행하였고, 주성분과 선형판별분석으 로 형태적 특징들을 추출하여 수행하였다. 두 가지 타입의 특징들을 결합하여 수 행하였을 경우, 13명의 피험자에 대해 100%의 피험자 인식률과 98.9%의 인식률을 보였다. 비교적 높은 인식 결과를 보였지만, 적은 인원의 실험자를 대상으로 수행 하였다[18].

	Features	
P wave onset	R wave amplitude	QRS wave deflection
P wave duration	S wave amplitude	P+wave amplitude
QRS wave onset	R'wave amplitude	P-wave amplitude
QRS wave duration	S'wave amplitude	R wave notch existence
Q wave duration	ST segment amplitude	Q wave amplitude
R wave duration	2/8 ST segment amplitude	T wave morphology
S wave duration	3/8 ST segment amplitude	QRS wave peak to peak amplitude
R' wave duration	T+wave amplitude	Delta wave confidence
S' wave duration	T-wave amplitude	ST segment slope
P+wave duration	QRS wave area	T wave onset

#### 표 1. 구간 및 진폭별 특징점

Shen은 Lead-I을 사용하여 개인 인식에 관한 연구를 진행하였다. 공용 데이터 베이스인 MIT-BIH 데이터베이스를 사용하며, 총 인원은 20명으로 구성되어있다. 전처리 과정에서 기저선 변동 잡음, 근잡음, 전력선 잡음 등을 제거한 후, QRS파 구간으로 정의된 7개의 특징을 추출하여 분류 방법인 템플릿 매칭과





DBNN(Decision based neural networks)방법에 적용하였다. 실험 결과, 심전도 신 호의 형태적 차이를 비교한 템플릿 매칭을 적용한 결과 95%와 DBNN방법에 적용한 결과 80%의 인식 결과를 보였다. 템플릿 매칭 결과 값을 DBNN에 적용할 경우, 100%의 인식 성능을 나타냈다[19]. Biel은 심전도 신호의 기준점 추출을 이용한 사용자 인식 방법을 제안하였다. 표준 12 Lead 시스템을 통해 다양한 연령층 20명 을 대상으로 정확한 전극의 위치와 전극 배치 방법에 따라 다양한 실험을 수행하 였다. 실험 결과, 표 1과 같이 30개 기준점 특징을 추출하였고, 임상 진단적 특징 에서 상관 행렬의 검사 등을 통해 10개의 특징점을 사용하였다. QRS파와 T파의 진 폭, P파 구간 등과 같은 파형의 특성을 포함하는 10개의 특징을 Soft independent modeling of class analogy 분류기를 이용하여 100%의 인식 결과를 보였다. 실험 을 통해 높은 인식률을 보였지만 분류단계에서 많은 특징 출력하기 때문에 실시간 인식 시스템에 적합하지 않은 문제점이 있다.

Boumbarov는 주성분 분석과 선형 판별 분석 방법을 이용하여 특징점을 검출한 후, HMM-GMM(Hidden markov model with gaussian mixture model), HMM-SGM(Hidden markov model with single gaussian model)과 CRF(Conditional random field) 신 경망 모델에 적용하여 분류하였다. 9명의 실험자에 대해 86.1%의 인식률을 보였다 [20].



그림 4. 웨이블릿 변환을 이용한 잡음 제거 및 특징 추출 방법





Chan은 웨이블렛 변환 거리를 포함하는 거리 측정 세트를 이용한 특징 추출 프 레임워크를 제안하였다. 손가락 사이에 전극을 통해 50명의 피험자로부터 데이터 를 취득하였다. 사용자 인식 방법에는 웨이블렛 변환 거리 방법을 적용함으로써 89%의 인식률을 나타내었다. 이전 실험에 비해 많은 인원을 대상으로 수행하였으 나 낮은 인식률을 나타내었다[21].

Chiu는 웨이블렛과 유클리디언(Euclidean) 분류기를 이용한 개인 식별 방법을 제안하였다. 45명의 실험자를 대상으로 심전도 신호를 취득하고, 웨이블렛 변환을 이용하여 특징을 추출하여 유클리디언 거리를 이용하였다[22]. 비교적 간단한 과 정을 수행하였지만, 90.5%의 낮은 인식 결과를 나타냈으며, Loong는 Linear predictive coding 계수를 심전도 신호 분류에 이용하였다[23]. Fatemian은 심전 도 신호 분류를 위해 웨이블릿 변환을 이용한 잡음 제거 및 특징 추출 방법을 제 안하였다. 템플릿을 생성하기 위해 심전도 신호의 표본화, 정규화, 평균화를 수행 하였으며, 상관관계 분석을 통해 템플릿 차원을 축소하였다. 총 13명에 대한 성능 인식은 99.6%를 달성하였다[24].

앞서 설명하였듯이, 기존 심전도 신호를 이용한 연구는 표 2와 같이 공개 데이 터베이스를 이용하여 주파수 분석, 웨이블릿 변환, 필터뱅크, 은닉 마르코프, 휴 리스틱방법, 서포트 벡터 머신 등 다양한 방법으로 연구가 진행되었다. 이러한 기 존의 방법들은 심전도 신호에 대한 경험적 지식을 바탕으로 특징 추출 및 분류가 진행된다. 그리고 해당 방법들의 적용 방법은 제한적이며, 1회 측정된 데이터를 사용하여 새로운 심전도 신호를 인식할 경우 성능이 유지되지 않는 단점을 갖고 있다. 또한, 이러한 방법들은 특징 추출이 중요하여 해당 특징들의 무결성을 필요 로 하는 경우도 있다. 그러나 심전도 신호의 특징 요소가 항상 잘 정의되지 않아 추출이 모호해 질 가능성이 높다[25][26].



#### 표 2. 심전도 신호 공개 데이터베이스 구성

구분	인원	측정 횟수	특징
MIT-BIH Normal Sinus Rhythm Database	18	1	<ul> <li>보스턴 Beth israel hospital 부정맥 연구소에서 공개한 데이터</li> <li>20~55세 사이 건강한 18명(남성 5명, 여성 13명)의 장기 간 측정한 심전도 데이터</li> </ul>
MIT-BIH Arrhythmia Database	47	1	<ul> <li>1975~1979년 BIH arrhythmia laboratory 연구소에서 취 득한 심전도 신호 데이터</li> <li>2채널 신호는 리드2(ML2) 및 V1(때때로 V2, V4, V5에 배 치)</li> <li>피실험자는 32~89세 25명 남성, 23~89세 22명 여성</li> <li>0.1-100Hz 대역통과 필터 사용, 360Hz 샘플링</li> <li>DelMarAvionics model을 이용해 취득</li> <li>두 명의 심장 전문의에 의해 부정맥 분류</li> <li>N(부비동 모드에서 발생하는 비트, beats originating in the sinus mode), S(상심 실성 이소성 비트, supraventricular ectopic beats), V(심실 박동 비트, ventricular ectopic beats), F(결합 비트, fusion beats), Q(분류 불가능한 비트, unclassifiable beats) 로 구성되어 있는 신호</li> </ul>
The PTB Diagnostic ECG Database	294	1	<ul> <li>17~87세 사이의 294명에게 측정한 데이터</li> <li>294명 중 병이 없는 건강한 사람은 52명</li> <li>심근 경색증, 심근병증, 부정맥의 환자 데이터가 포함</li> <li>0~1kHz 대역폭에서 측정</li> <li>기존 12리드(i, ii, iii, avr, avl, avf, v1, v2, v3, v4, v5, v6)와 함께 Frank lead(vx, vy, vz)에서 1,000 sampling rate로 취득</li> </ul>
European ST-T Database	79	1	<ul> <li>ST 및 T파 변화 분석 알고리즘 평가에 사용하기 위한 데이터</li> <li>30-84세 사이의 남성 70명과, 55-71세 사이의 8명 여성</li> <li>심근 국소 빈혈이 진단 및 의심된 사람에게서 취득</li> <li>2시간 동안 250 Sampling rate로 취득한 신호</li> </ul>
The Long-Term ST Database	80	1	<ul> <li>Ischemic 및 Non-ischemic을 구별하기 위해 취득한 데이터</li> <li>개별 기록시간은 21~24시간 사이, 2개~3개의 심전도 신호 포함</li> <li>12비트 분해능으로 초당 250 Sampling rate로 취득</li> </ul>





#### 제2절 딥러닝 기반 사용자 인식

기존 연구들의 문제점을 해결하기 위해 최근 심전도 신호를 답러닝 방법에 적 용한 연구들이 진행되고 있다. 답러닝은 기존 머신러닝의 다층 퍼셉트론을 시작으 로 다양한 타입의 계층들이 추가되고 깊어진 계층들로부터 최적의 값을 출력하는 방법이다. 대표적으로 심층 신경망(Deep Neural Network)[27], 합성곱 신경망 (Convolutional neural network)[28], 순환 신경망(Recurrent neural network)[29], 심층 신뢰 신경망(Deep belief network)[30], 심층 Q-네트워크 (Deep Q-networks)[31] 등이 있다.

방법	신경망 구조	
심층 신경망 (DNN)	Hidden Input Input Input	
합성곱 신경망 (CNN)	Input     Filer     Filer     Output       Breach     Filer     Filer     Filer       Convolution     Pooling     Convolution     Pooling       Layer     Layer     Layer	
순환 신경망 (RNN)	Input Hidden Output	
심층 신뢰 신경망 (DBN)	RBM Model Input Hidden Output RBM Model RBM Model RBM Model RBM Model	

표 3. 딥러닝 신경망의 구조



영상처리에서 가장 두드러지는 방법 중 하나가 합성곱 신경망으로 다양한 특징 추출 필터들을 자동으로 학습하고 분류하도록 설계된 신경망이다. 기존 특징 검출 은 사람에 의해 추출되고 분류만 기계학습으로 진행했다면, 합성곱 신경망은 컴퓨 터가 자동으로 특징 검출과 분류를 진행한다. 표 3은 다양한 딥러닝 알고리즘 구 조를 보여준다. ECG신호를 딥러닝에 적용한 기존 방법에는 Ubeyli는 고유 벡터 기 반의 특징 추출 방법을 사용하여 순환 신경망을 이용해 부정맥을 검출하는 방법을 제안했다. 실험 결과, 이 모델은 4 가지 다른 부정맥으로 평균 정확도 98.06%를 보였다[31]. Zubair은 9개 계층의 합성곱 신경망을 설계하여 92.7%의 정확도를 보 였고[32], Zhai은 심전도 파형의 이중화를 통해 2차원 이미지로 변환하였으며, 이 를 합성곱 신경망에 적용하여 특정 파형 검출에 대해 98.6%와 97.5%의 정확도를 보였다[33]. Acharya는 9개 계층의 합성곱 신경망을 설계하여 잡음 제거한 파형과 제거하지 않은 파형에 대해 각각 94.03%, 93.49%의 정확도를 보였다[34].

Kiranyaz는 ECG 부정맥 분류를 위해 1차원 CNN을 적용했다. 2 차원 심전도 영 상에 CNN을 적용하는 방법과 달리 Kiranyaz방법은 1차원 심전도 신호에 CNN을 적 용하여 우수한 성능을 나타냈다[35]. Rajpurkar는 Kiranyaz의 CNN 모델보다 더 깊 고 많은 데이터를 사용하는 1-D CNN 모델을 제안했다. 그러나 더 많은 ECG 데이터 를 사용함에도 불구하고 검출 성능은 낮게 나타냈다[36]. 실험에 사용된 ECG신호 의 경우, 데이터 세트의 크기가 증가하더라도 입력으로 사용되는 심전도 신호가 1 차원이기 때문에 깊은 네트워크는 성능 향상에 영향을 미치지 않았다.

기존의 단일 네트워크를 이용한 사용자 인식 방법은 많은 양의 데이터 처리를 위해 빠른 학습 속도를 보이지만, 학습 데이터에 대해 과적합 문제에 있어 상대적 으로 낮은 정확도를 나타낸다. 이러한 단점을 보완하기 위해 여러 방법을 결합한 앙상블 구조의 사용자 인식에 관한 연구가 진행되고 있다. 앙상블 모델은 하나의 인식 모델을 사용하는 것이 아니라 다수의 인식 모델을 설계하여 출력된 특징 및 결과를 조합하는 인식 모델로 단일 모델보다 더 높은 인식 성능을 보인다.







그림 5. Two-steam 기반 합성곱 신경망 구조의 예

Xiao는 질병 진단을 위해 먼저 KNN, SVM, Random forest, Decision trees, Gradient boosting decision 와 같은 다양한 기계학습 방법을 단일 분류기로 사용 한 후, 분류된 결과를 하나의 학습 데이터로 융합했다. 다음으로 융합된 학습 데 이터를 단일 심층 신경망을 설계하여 융합된 학습 데이터의 분류를 진행했다. 실 험 데이터에는 폐암, 위암, 유방암에 대해 정상과 비정상을 판단하도록 구성했다. 실험결과, 실험에 사용된 기계학습 방법을 단일 분류기로 사용한 성능에 비해 에 제안한 앙상블 모델의 성능이 폐암, 위암, 유방암 데이터에 대해 98.8%, 98.78%, 98.41%로 가장 높은 성능을 나타냈다[37]. Fan은 심전도 신호를 이용하여 일반적 인 정상 신호와 비정상 신호인 부정맥 신호를 분류하기 위해 그림 5와 같이 2층 구조의 다중 스케일 합성곱 신경망 모델을 제안했다. 서로 다른 스케일의 특징을 검출하기 위해 각 층에 사용된 필터 크기를 다르게 설계한 구조로 20초 간격으로 구성된 심전도 신호를 데이터베이스를 적용하였다. 실험결과, 제안한 다중 스케일 합성곱 신경망 모델은 98.13%의 분류 결과를 나타내 단일 네트워크와 VGGnet에 적 용한 결과인 89.58%, 98.03%보다 우수한 분류 성능을 나타냈다[38].





그림 6. 다중 합성곱 신경망을 이용한 앙상블 네트워크 구조의 예

Liu는 12-Lead의 심전도 신호를 사용하여 심근 경색 신호 검출을 위해 그림 6 과 같이 다중 합성곱 신경망과 단일 순환 신경망 구조를 결합한 앙상블 네트워크 를 제안했다. 서로 다른 12-Lead의 신호를 입력받기 위해 독립적인 다중 합성곱 신경망 구조를 설계하였으며 각 네트워크에서 출력된 특징들은 단일 순환 신경망 의 입력 데이터로 사용된다. 또한, 다중 합성곱 신경망과 단일 순환 신경망 사이 에 Lead random mask를 적용하여 과적합 문제를 해결했다. Lead random mask는 Drop-out과 동일한 방법으로 무작위로 선택된 데이터 사용하여 학습과정에서 많은 데이터들을 처리하기 위해 발생하는 일반화 문제를 해결한다. 실험결과, 심근 경 색 신호와 정상 신호 검출 성능은 99.9%의 높은 검출결과를 나타냈으며, 실험자에

아는 5가지 부정맥 진단을 위해 그림 7과 같은 구조의 단일 합성곱 신경망과 단일 순환 신경망을 이용한 앙상블 네트워크 모델을 제안했다. 단일 합성곱 신경 망은 분류기가 공간적 특징 추출을 위해 설계되었으며, 검출된 특징은 시간정보에 따라 데이터를 입력받는 단일 순환 신경망에 적용하여 부정맥 신호를 검출했다. 부정맥 신호의 다양한 공개 데이터베이스를 적용한 결과, 98.1%의 높은 검출률을 보였다[40].





그림 7. 합성곱 신경망과 순환 신경망을 이용한 앙상블 네트워크 구조의 예

이와 같이 심전도 신호를 이용한 사용자 인식에 관한 선행 연구들은 모두 높은 정확도를 보여 기존 인식 방법을 대체하는 차세대 사용자 인식 방법으로 주목 받 고 많은 연구가 진행되고 있다. 그러나, 심전도 신호는 환경, 시간, 사용자 등 다 양한 요소로 인해 신호의 변동성이 있지만, 기존 심전도 신호 관련 연구는 동일한 환경 및 시간에 취득한 데이터를 사용하여 연구를 진행하였다. 즉, 기존 심전도 신호 기반 사용자 인식 방법은 사용자 상태 및 환경 변화를 고려하지 않아 재현성 검증을 기반으로 진행된 연구는 부족한 상태이다.

또한, 초기 데이터 구성 단계에서 학습 및 실험 데이터를 동일한 크기로 구성 하여 사용자 인식 연구를 진행하였지만, 실제 취득한 실험 데이터는 학습 데이터 와 크기가 다를 수 있으므로 사용자 인식 시스템에 적용하기 어렵다. 그러므로 본 논문에서는 기존 심전도 신호를 이용한 사용자 인식 방법의 문제점을 보완하기 위 해 사용자 상태 변화에 따라 취득한 심전도 신호를 이용하여 사용자 인식이 가능 하도록 앙상블 네트워크를 제안한다. 또한, 가상 데이터 생성하여 실생활 적용 가 능한 심전도 신호 기반 사용자 인식 방법을 제안한다.



#### 제3절 신경망 모델을 이용한 데이터 생성

빅 데이터 기술이 주목받은 후 대규모 데이터를 마이닝한 예측 모델을 개발하 여 성공한 사례가 매우 많으며, 대규모 데이터의 확보가 용이한 영상, 음성, 문헌 등의 분야에 집중되어 있다. 그러나 개인의 생체정보를 이용한 의료분야에서는 개 인정보보호 및 확보 비용 등의 제약으로 대규모 데이터 구축이 어렵기 때문에 불 균형 빅 데이터(Imbalanced big data) 문제가 발생한다. 불균형 빅 데이터는 다른 클래스에 비해 상대적으로 많은 데이터를 포함하는 다수 클래스(Majority class) 와 대조적으로 다른 클래스에 비해 적은 데이터를 포함하는 소수 클래스(Minority class)로 구성된다. 불균형 빅 데이터를 사용하여 기계학습 모델을 학습시킨다면 다수 클래스로 편향되기 때문에 소수 클래스에 대해 낮은 인식 성능을 나타내거 나, 새로 입력된 데이터에 대해 소수 클래스로 인식 될 가능성이 저하되는 문제가 발생한다. 이러한 문제를 해결하기 위해 신경망을 이용한 다양한 데이터 생성 방 법이 연구되고 있다.

Autoencoder는 학습된 모델로부터 소수 클래스의 데이터를 입력값으로 사용하고, 생성된 값을 소수 클래스의 새로운 데이터로 사용하는 과정을 반복하여 데이 터를 생성해낸다. Autoencoder 방법 중 가장 좋은 성능을 나타내며 활용된 신경망 으로는 VAE(Variational Autoencoder)가 있다[41].



그림 8. Variational autoencoder 구조

- 17 -





VAE는 기본적으로 Autoencoder의 특성을 사용하지만, 잠재변수(Latent variable)인 z는 연속적인 분포를 갖는 확률 변수(Random variable)로 간주하는 점에 차이가 있다. 그림 8과 같이 VAE는 크게 인코더와 디코더로 나눌 수 있으며, 인코더에서는 입력 x가 주어졌을 때 z의 확률 분포를 구해야 하는데 이는 사후 확 률이기 때문에 이 값을 직접 계산하기 어렵다. 이때 변분 추론(Variational inference)이라는 방법을 사용하여 데이터간 분포 근사화를 진행한다. VAE의 디코 더는 잠재변수 z로부터 x를 만들어내는 또 다른 신경망으로 출력인 x의 확률 분 포인 p(x)를 알기 위해 p(x|z)를 학습해야 한다. 이때 디코더는 정규분포를 전제로 하며 인코더가 만들어낸 z의 평균과 분산을 모수로 한다. 따라서 VAE의 인코더는 학습 데이터를 잠재변수인 z로 압축하며 디코더는 인코더에서 출력된 z로부터 데 이터를 재구성을 진행하여 데이터를 생성한다. 그러나 생성자 모델만 존재하는 VAE는 오차 손실을 최소화하는 조건만 충족하도록 설계되어 데이터 특징이 흐려지 는 문제점이 있다.

적대적 생성 신경망은 심층 학습을 이용한 대표적인 생성 모델의 방법으로써 영상 생성, 해상도 개선, 자연어 처리 등 다양한 분야에서 우수한 성과를 보이고 있다. GAN은 데이터를 생성하는 생성자 모델과 생성된 데이터가 실제 데이터인지 생성된 데이터인지를 구분하는 판별자로 구성되어 있다. 생성자와 판별자의 대립 구조를 이용하여 서로의 성능을 점차 개선해 나가는 것이 주요 학습 방법이다. GAN은 학습 데이터의 분포를 찾아낸 후, 생성된 데이터가 그 분포를 따르도록 유 도하여 VAE보다 선명한 데이터를 생성해낸다. 이러한 특징을 이용하여 Christian 은 GAN기반 고해상도 방법인 Super resolution GAN을 제안했다. 손실 함수를 평균 제곱오차(Mean squared error)로 사용한 기존 방법들의 경우 데이터별로 모든 가 능한 해의 평균값을 추정하기 때문에 데이터 블러 현상이 발생한다. 그러나 GAN은 개별 속성을 유지하며 최대한 학습 데이터와 가까워지도록 학습이 진행되기 때문 에 보다 선명한 데이터를 생성해 낼 수 있다[42].





그림 9. Super resolution GAN의 생성자와 판별자 모델 구조

최근에는 2차원 데이터 생성뿐만 아니라 시계열 데이터 생성에 관한 연구가 진 행되고 있다. Hartmann은 Wasserstein GAN을 이용하여 시계열 데이터인 뇌전도 신 호 생성 방법에 다양한 업 샘플링 및 다운 샘플링 방법을 적용했다. Wasserstein GAN은 기존의 손실함수인 Kullback-Leibler DivergenceL Jensen-Shannon Divergence를 사용하는 대신 Wasserstein Distance의 개념을 손실함수에 사용하여 기존의 GAN의 불안정한 학습을 개선했다. Wasserstein Distance란 두 확률분포 간 의 거리를 측정하는 지표로써 어떤 확률 분포 모양이 다른 확률분포 모양을 가지 도록 사용되는 최소 비용을 의미한다. 또한 판별자 모델에 사용된 업 샘플링 방법 은 최근접 이웃(Nearest-neighbor) 보간법, 선형(Linear) 보간법, 그리고 3차 회 선(Cubic) 보간법을 적용했으며, 생성자 모델에 사용된 다운샘플링은 평균 풀링을 적용하여 데이터 생성에 미치는 영향을 확인했다. 표 4는 논문에서 사용된 생성자 와 판별자 모델의 구조를 나타냈다[43].



Collection @ chosun



#### 표 4. 생성자 및 판별자 모델 구조

Tomer는 MIT-BIH 부정맥 데이터를 이용하여 환자별 실제 심전도 신호와 유사한 심전도 신호 P, QRS, T파 특징을 생성하기 위해 Personalized Generative Adversarial Networks를 제안했다. 생성자 모델의 입력 데이터는 가우시안 분포 잡음에서 임의의 100개의 샘플을 사용했으며, 역합성곱 계층에 배치 정규화(Batch normalization)와 활성 함수인 수정된 선형 유닛(Rectified linear unit)을 적용 했다. 생성된 심전도 신호는 그림 10과 같이 1주기가 아닌 3주기의 심전도 신호를 생성하여 가운데 1주기를 판별자의 입력 데이터로 사용한다. 나머지 2주기는 P, QRS, T파를 검출한 후, 판별자 모델에서 사용되는 손실 함수인 평균 제곱 오차의 입력 데이터로 사용한다. 생성된 환자별 심전도 신호를 이용하여 분류 성능을 확 인하기 위해 LSTM 모델에 적용한 결과, 0.95 AUC의 성능을 나타내어 생성된 환자

- 20 -



CHOSUN UNIVERS





그림 10. Personalized GAN의 생성자 모델 흐름도

Haradal은 시계열 데이터인 심전도 신호와 뇌전도 신호를 생성하여 데이터 수 를 증가시키기 위해 LSTM 네트워크로 구성된 GAN기반 데이터 생성 방법을 제안했 다. 제안한 데이터 생성 모델의 구조는 그림 11과 같다. 생성자 모델의 입력 데이 터는 유니폼 잡음에서 임의의 178샘플을 사용했으며, 다층의 LSTM 네트워크를 설 계했다. 판별자 모델은 생성자 모델에서 입력받은 실제 신호와 생성된 신호를 구 분하기 위해 단일 LSTM 네트워크, 완전연결계층 그리고 평균 풀링 계층으로 설계 했다[45].



그림 11. LSTM 네트워크를 이용한 시계열 데이터 생성



학습 데이터에 사용되는 심전도 신호의 원본 데이터 수는 클래스 당 20개, 뇌 전도 신호의 경우 클래스 당 460개로 구성되어 있으며, 원본 데이터 이외에 생성 된 데이터는 추가적인 학습 데이터로 사용했다. 제안한 방법의 우수한 성능을 확 인하기 위해 기존 데이터 생성 방법인 잡음 추가, 보간법, 은닉 마르코프 모델을 통해 데이터를 생성한 후, 학습 데이터 수를 증가함에 따라 인식 성능을 비교했 다. 그림 12는 데이터 수 증가별 인식 성능 결과로써, 심전도 신호를 이용한 인식 성능의 경우 데이터 수를 증가시키더라도 실험 데이터의 수가 36개로 기존 방법들 과 성능 차이를 나타내지 않았다. 그러나 뇌전도 신호의 실험 데이터 수는 1,656 개로 학습 데이터 수가 증가함에 따라 인식 성능이 향상됨을 확인할 수 있다.






# 제3장 제안하는 심전도 신호를 이용한 사용자 인식

본 장에서는 데이터 크기 부적합 문제를 해결하기 위해 적대적 생성 신경망을 이용한 가상 데이터 생성 방법을 제안하고 사용자 인식 성능 향상을 위해 사용자 상태 변화에 따라 취득한 데이터를 적용할 수 있는 앙상블 네트워크에 대해 설명 한다. 그림 13은 본 논문에서 제안하는 가상 심전도 신호 생성을 이용한 다층 구 조의 앙상블 합성곱 신경망 기반 사용자 인식 시스템에 관한 전체적인 흐름도를 나타낸다.



그림 13. 제안하는 가상 심전도 신호 생성을 이용한 사용자 인식 시스템

먼저 등록 데이터는 사용자 상태 변화에 따라 취득된 심전도 신호를 입력 데이 터로 사용한다. 다음으로 심전도 신호 취득 과정에서 발생하는 잡음 제거 및 신호 분할과 같은 전처리 과정을 진행한다. 심전도 신호에서 발생하는 잡음은 발생 원 인에 따라 다른 주파수 대역을 나타내기 때문에 고역 통과 필터, 특정 대역 제거 필터 등과 같은 다중 필터를 이용하여 잡음을 제거한다. 전처리 과정의 마지막 단 계는 Pan&Tompkins 방법을 이용한 심전도 신호 분할 과정을 거친다. 다음으로 등





록 데이터와 비교 데이터 간의 크기 부적합 문제를 해결하기 위해 데이터 생성에 서 뛰어난 성능을 보이는 GAN을 이용한다. 그러나 GAN은 불안정한 학습과정으로 인해 다양한 데이터를 생성하지 못하는 문제점이 있다. 따라서 본 논문에서는 클 래스 정보를 보조 분류기로 사용한 ACGAN을 설계하여 가상 심전도 신호를 생성하 는 방법을 제안한다. 마지막으로 단일 네트워크에서 발생하는 데이터 손실 및 과 적합 문제는 본 논문에서 제안한 다층 구조의 앙상블 합성곱 신경망을 설계하여 사용자 인식에 적용한다.

### 제1절 잡음제거 및 심전도 신호 분할을 위한 전처리

인체에서 출력되는 여러 형태의 전기적 신호는 각각의 신체활동과 관련된 중요 한 정보를 담고 있다. 이러한 전기적 신호들 중 심전도 신호에서 발생하는 잡음은 개인을 인식하는 과정에서 불필요하며, 잘못된 정보를 제공할 수 있는 원인이기 때문에 잡음제거가 필수적이다.



그림 14. 잡음제거 및 신호 분할 흐름도

그림 14는 본 논문에서 잡음 제거 및 신호분할을 포함한 전처리 과정의 흐름도 이다. 심전도 취득시 발생하는 잡음의 종류에는 심전도 신호의 취득 장비에 의해 발생되는 전력선 잡음(Power line interference), 측정자의 움직임에 의해 발생하 는 근 잡음(Motion artifacts), 불규칙적인 근육 활동에 의한 근육 수축 잡음





(Muscle contraction), 호흡에 의한 기저선 변동 잡음(Baseline drift)등이 있다 [46]. 본 논문에서 사용된 고역 통과 필터는 특정 주파수 신호보다 높은 주파수 신호를 통과시켜 특정 주파수보다 낮은 주파수로 신호를 감소시키는 필터이다. 각 각의 주파수에 대한 감소 정도는 필터의 설계 및 파라미터에 따라 달라진다. 0.5Hz의 차단 주파수를 가지는 고역 통과 필터를 사용하여 저주파수 대역인 기저 선 변동 잡음을 제거한다.

전력선 잡음은 접지가 부적절하거나 고압선, 변압선 근처에서 발생하는 잡음으 로, 일반적으로 60Hz로 나타난다. 전력선 잡음은 심전도 신호를 분석할 때 다른 파형에 비해 진폭이 작은 P파와 R파에 영향을 주어 부정맥과 심근 경색진단에 오 류를 발생시키기도 하고, 심전도 신호를 왜곡시켜 QRS 구간 또는 QT구간 측정에 성능을 저하시킨다. 이러한 전력선 잡음을 제거하기 위해 60Hz 대역의 특정 대역 제거 필터(Notch filter)를 적용한다.

마지막으로 잡음제거 과정을 거친 심전도 신호를 분할하기 위해 Pan&Tompkins 방법을 이용하여 R파 정점 검출을 진행한다. Pan&Tompkins 방법은 크게 전처리 과 정과 적응형 이중 임계값(Threshold)를 사용한 QRS 구간 검출 과정으로 나눌 수 있다. 본 논문에서는 앞서 설명한 고역 통과 필터, 대역 제거 필터와 같은 잡음제 거 방법을 이용하여 Pan&Tompkins 방법의 전처리 과정을 진행한다. 이렇게 전처리 과정을 거친 전체 심전도 신호의 정점을 연산한 후, 이중 임계값을 적용하여 QRS 구간을 검출한다. Q파 정점을 검출하기 위해 R파 정점의 위치에서 좌측 방향으로 일정한 범위내의 신호차이를 연산할 경우 R파 정점과 최대 차이를 보이는 지점이 발생하게 된다. 이 지점을 Q파 정점으로 검출하며, 마찬가지로 S파 정점 검출은 Q 파 정점의 위치에서 우측 방향으로 일정한 범위를 지정하고 R파 정점과 최대 차이 를 보이는 지점을 S파 정점으로 검출한다. 그림 15는 본 논문에서 사용한 심전도 신호에 다중 잡음 제거 필터를 적용한 결과 및 신호 분할에 대한 결과를 나타낸 다.







- 26 -



## 제2절 사용자 상태 변화에 강인한 앙상블 네트워크 설계

답러닝의 경우 신경망의 구조에 따라 다양한 알고리즘이 개발되었다. 우선 가 장 기본적으로 입력 계층과 출력 계층 사이에 복수개의 은닉층으로 이루어진 인공 신경망인 심층 신경망은 일반적인 인공 신경망과 마찬가지로 복잡한 비선형 관계 들을 모델링할 때 사용되며, 점진적으로 모여진 하위 계층들의 특징들을 규합하여 적은 수의 노드만으로도 복잡한 데이터를 모델링할 수 있다. 여러 개의 합성급 계 층과 일반적인 신경망 계층으로 구성된 합성곱 신경망은 다층 퍼셉트론의 한 종류 로 하나 또는 복수 개의 합성곱 계층과 일반적인 신경망 계층으로 구성된다. 학습 과정이 간편하고 적은 수의 매개변수를 사용한다는 장점이 있어, 다른 딥러닝 구 조에 비해 영상, 음성 분야에서 모두 좋은 성능을 보인다. 순환 신경망은 유닛 (Unit)사이의 연결이 순환구조(Directed cycle)로 구성되며 은닉 노드에 자기 자 신을 가리키는 가중치 값이 추가된 알고리즘으로 처리하는 정보의 순서와 이전에 처리한 정보가 현재 처리하고 있는 정보에 영향을 미치는 경우 피드백 작용을 준 다. 주로 음성이나 자연어 처리에 분야에 활용된다. 제한 볼츠만 머신을 이용한 다층화를 고안한 심층 신뢰 신경망은 레이블 된 데이터 세트가 충분하지 않은 경 우 적당한 방법으로 사전학습을 사용해 근접한 가중치를 얻는데 활용한다.

#### 1. 합성곱 신경망 네트워크 구조

합성곱 신경망은 심층 신경망에 합성곱 계층과 풀링 계층이 결합된 신경망 구 조로 일반적인 구조는 다음과 같다. 합성곱 계층은 입력데이터를 다양한 필터와 합성곱하여 특징 맵을 얻고 활성화 함수(Activation function)를 적용한다. 특징 맵을 얻기 위해 합성곱 계층의 연산은 식 (1)로 표현 가능하다. 행렬로 이루어진 입력 데이터 *x* 값에 입력과 마찬가지로 특징 맵 *w*을 1:1로 곱해진 후, 이 값들을

- 27 -





Collection @ chosun

모두 더해서 얻어진 결과인 특징 맵 F를 생성한다. 주변 값을 이용하여 목적 값을 출력하는 것이 핵심이다.

$$F[i,j] = (x^*w)[i,j] = \sum_{m} \sum_{n} x[m,n]w[i-m,j-n]$$
(1)

합성곱 신경망은 여러개의 합성곱 계층과 풀링 계층을 거친 후 추출된 특징 맵 은 크기가 작아지면서 데이터 전체를 대표할 수 있는 강한 특징들만 남게 된다. 이렇게 얻어진 특징 맵은 1차원 벡터로 변환된 후, 다른 심층 신경망처럼 완전연 결계층(Fully connected layer)의 입력으로 사용된다. 완전연결계층은 추출된 특 징들로 최종 결과를 출력하고 클래스 분류 시 Softmax 함수를 통해 확률 값으로 변환한다.

활성화 함수는 얻은 특징을 비선형 값으로 바꾸어 주는데 대표적으로 0에서 1 사이의 범위를 나타내는 시그모이드(Sigmoid)함수가 있다. 목적함수로 Cross entropy함수와 사용할 때 학습 속도에서 좋은 성능을 보인다. 그러나 인공 신경망 에 학습을 진행하는 과정에서 기울기 손실(Gradient vanishing) 문제가 발생한다. 기울기 손실 문제는 출력층과 멀어질수록 출력오차가 반영되지 않아 가중치가 발 산하거나 곡선의 기울기가 0이 되는 현상이다. 이러한 기울기 손실 문제를 해결하 기 위해 수정된 선형 유닛(Rectified Linear unit)함수를 사용한다. 기울기 손실 문제를 해결하기 위해 제안된 ReLU함수는 출력값이 음수일 경우 0으로 반환하고 양수일 경우 그대로 반환하는 함수이다.

본 논문에서 사용된 1D CNN은 시간 특성 추출을 통해 시계열 데이터 분석에 관 한 연구가 진행되고 있다. 1D CNN은 시퀀스에서 로컬 1D 서브 시퀀스 특징 추출하 는데 사용할 수 있으며, Convolution window내에서 로컬 패턴을 식별할 수 있다.





그림 16. 1차원 합성곱 신경망 계층 구조

Convolution window에 의해 동일한 변환 값이 식별된 다른 서브 시퀀스에 적용 되므로, 한 위치에서 학습 된 패턴이 다른 위치에서 인식이 가능하다. 그림 16은 3개 층으로 구성된1D CNN layer에 대한 예시이다[47]. 기본적으로 원본 신호를 처 리하며 MLP계층에서 인식에 사용할 수 있는 특징을 추출하는 방법을 학습한다. 따 라서 특징 추출 및 인식 방법은 모두 인식 성능을 향상시키기 위해 최적화하는 하 나의 모델로 융합된다.

$$x_{k}^{l} = b_{k}^{l} + \sum_{i=1}^{N_{l-1}} conv1D(w_{ik}^{l-1}, s_{i}^{l-1})$$
(2)

식 (2)는 1D CNN 특징 추출 및 인식에 대한 수식으로  $x_k^l$ 는 입력 데이터이며,  $b_k^l$ 는 layer1층에 k번째 바이어스이다.  $s_i^{l-1}$ 는 layerl-1층에 i번째 출력 값이며,  $w_{ik}^{l-1}$ 는 layerl-1의 i번째 뉴런에서 layerl의 k번째 뉴런의 1D filter kernel이다.

이러한 신경망의 층이 깊어질수록 딥러닝은 더욱 많은 정보를 학습할 수 있다. 그러나 층의 깊이가 깊어질수록 과적합(Overfitting)의 문제가 발생하며 학습시간 도 길어지게 된다. 과적합이란 신경망 모델이 학습 데이터 세트에서는 높은 수준 의 정확도를 보이지만, 새로운 데이터에 적용할 경우 성능이 저하되는 문제를 뜻 한다. 지나친 학습 또는 학습 데이터 부족 등으로 인해 일반화 성능이 떨어지게





된다면 그림 17과 같이 학습 진행 정도에 따라 학습 정확도 및 테스트 정확도가 큰 차이를 보이며 이러한 차이로 과적합 발생 또는 진행 정도를 판단할 수 있다 [48].



그림 17. 과적합 문제 확인 방법

이러한 과적합 및 기울기 소실 등의 문제를 해결하기 위해 머신 러닝 분야에서 는 데이터 확장(Data augmentation), 배치 정규화(Batch normalization), 드롭아 웃(Drop out)과 같은 다양한 정규화 기법들을 적용한다. 이와 같은 전처리는 인공 신경망 구조가 깊어질수록 좋은 성능을 갖기 위한 필수 과정이다.

과적합 문제를 해결하기 위한 방법에는 충분한 데이터를 확보하여 학습에 사용 하는 것이다. 그러나 사용할 수 있는 데이터 수에 제한이 있으며, 클래스 별 분류 를 통해 라벨 처리도 어려워 많은 양의 데이터를 학습한다는 것은 결코 쉬운 일이 아니다. 따라서 원본 데이터를 통해 데이터 수를 증가시켜 인위적으로 데이터를 생성하는 방법을 적절히 사용한다. 이는 많은 양의 학습을 통해 사용되는 데이터 와 실험에 적용될 실제 데이터와의 차이를 줄여 일반화(Generalization) 효과를 얻을 수 있다. 원본 데이터의 특징을 유지하면서 데이터 수를 증가시키는 방법에 는 회전, 기울임, 확대 및 축소 등의 스케일 변화, 위치 변화, 밝기 조절, 잡음 추가 등의 다양한 변형을 통해 새로운 데이터를 생성해 낸다.





그림 18. 데이터 확장 방법을 적용한 1차원 심전도 결과

배치 정규화는 활성 함수 변화, 학습률 및 초기값 변경 등의 간접적인 방법으 로 학습 과정을 전체적으로 안정화하여 문제를 해결하는 방법이다. 미니 배치 단 위로 입력되는 값들이 각각의 연속적인 계층을 통과할 때 가지는 분포를 적절하게 조정함으로써 안정적으로 오류률을 수렴시키며 인식 성능을 향상시킨다.



그림 19. Dropout 예시





드롭아웃은 뉴런을 임의로 삭제하면서 학습하는 방법이다. 훈련 때 은닉층의 뉴런을 무작위로 골라 삭제하고 삭제된 뉴런은 신호를 전달하지 않게 하여 일부 특징이 특정 뉴런들에게 고정되는 것을 막아 가중치의 균형을 잡도록 해준다. 훈 련 때는 데이터를 학습 시 삭제할 뉴런을 무작위로 선택하고, 시험 때는 모든 뉴 런에 신호를 전달하여 학습한다. 일반적으로 드롭아웃은 주로 완전 연결 계층같은 다층 퍼셉트론에 사용되며, 무작위로 노드간의 연결을 생략하며 학습하는 방법을 통해 특징이 되는 노드들 간의 동조화 현상(Co-adaptation)을 감소시켜 의미있는 특징을 검출한다. 그림 19는 드롭아웃의 적용 예시를 보여준다.

### 2. 제안하는 다층 구조의 앙상블 네트워크 설계

심전도 신호는 개인의 신체적 활동이나 측정 시간대 또는 정신적 영향에 의해 심박수 및 파형 변화가 발생하는 시계열 데이터이다. 이에 일상생활에서 취득된 심전도 신호는 동일한 사용자일지라도 사용자 상태 및 환경에 따라 다른 파형의 형태를 나타낸다. 이에, 딥러닝 기반 단일 네트워크에 사용자 상태 변화에 따라 취득된 데이터를 입력 받을 경우, 많은 데이터에 대한 데이터 일반화로 인해 등록 데이터에서만 높은 인식 성능을 보이는 과적합 문제가 발생할 수 있다.



그림 20. 제안하는 다층 구조의 앙상블 네트워크 흐름도





또한, 공개 네트워크인 GoogleNet, VGGNet, AlexNet과 같이 매우 깊은 네트워 크를 설계할 경우, 전방 전달 신경망(Feed-forward neural networks)과 오류역전 파(Back propagation)를 반복하는 학습 과정에서 데이터 손실로 인해 인식 성능이 저하되며, 파라미터의 수가 비례적으로 늘어나 오류가 커지는 상황이 발생한다.

최근 소개된 ResNet과 DenseNet은 CNN모델의 깊이가 깊어질수록 최종 출력단계 에서의 이미지의 초기 특징이 손실되는 문제를 해결하기 위해 제안되었다. 그러나 심전도 신호의 경우 복잡한 패턴을 갖는 일반 데이터와 달리 단순한 파형으로 구 성되어 있다[49][50].



그림 21. 다층 구조의 단일 합성곱 신경망

따라서 본 논문에서는 그림 20과 같이 사용자 상태 변화에 따라 취득된 데이터 를 이용한 다층 구조의 앙상블 네트워크 구조를 제안한다. 먼저 그림 21과 같이 사용자 상태 및 환경 변화에 따라 취득된 데이터는 등록 데이터베이스로 구성하여 다층 구조의 1차원 단일 합성곱 신경망에 입력 데이터로 사용한다. 1차원 단일 네 트워크의 구조는 합성곱 연산을 통해 심전도 신호의 고유한 특징을 검출하여 특징





Collection @ chosun

맵(Feature map)으로 변환하는 합성곱 계층과 데이터의 크기를 줄이는 풀링 계층 그리고 입력과 크기를 설정해주는 Dense 계층을 교차적으로 사용한다. 풀링 계층 의 역할은 합성곱 계층에서 출력된 데이터의 크기를 줄여주어 연산량을 감소시키 며, 강인한 성질을 갖는 특징을 추출할 수 있게 한다. 평균 풀링은 활성 함수인 ReLU에 의해 연산결과가 'O'이 다수 출력될 경우, 합성곱 계층에서 출력된 강한 성질의 특징이 줄어드는 효과(Down-scale weighting)가 발생하여 윈도우 내 최고 값을 선택하는 최대 풀링을 사용한다.

	Conv-1	Conv-2	Conv-3	Conv-4	Conv-5	Conv-6
Epoch	500	500	500	500	750	750
Batch-size	512	512	256	256	512	256
Drop-out	0.5	0.6	0.6	0.7	0.5	0.7
Learning rate	0.001	0.001	0.001	0.001	0.001	0.001

표 5. 네트워크별 매개변수 설정

앙상블 방법은 서로 다른 모델들을 조합을 통해 성능 향상시키는 방법으로 각 1차원 단일 네트워크는 다른 특징 검출을 위해 네트워크별 다른 매개변수로 구성 하였으며, 매개변수는 표 5와 같이 설정되어 있다. 학습 횟수는 500회와 750회 반 복 학습을 진행하도록 설정하였으며, 한번 학습에 사용되는 데이터 수인 배치 사 이즈는 256과 512로 설정하였다. 네트워크의 일부를 생략하여 연산 시간 및 연산 량을 줄여주는 드롭아웃은 50%~70%사이로 설정하였으며, 학습률을 일반적으로 많 이 사용하는 0.001로 적용하였다.





그림 22. 재학습을 위한 단일 네트워크

다음으로, 각 네트워크에서 출력된 결과의 심전도 신호는 하나의 데이터베이스 로 융합하여 재학습을 위한 등록 데이터로 사용한다. 그러나 각 네트워크에서 출 력된 심전도 신호를 모두 등록 데이터로 사용할 경우, 매개변수 및 잘못된 네트워 크 설계로 인해 인식률이 낮은 결과까지 등록 데이터로 사용하여 오히려 인식 성 능이 저하되는 문제점이 있다. 이에 출력된 데이터를 전부 사용하지 않고, 우수한 성능을 나타내는 Top-3 네트워크의 결과 데이터를 융합하여 등록 데이터로 구성한 다. 마지막으로 재구성된 등록 데이터는 시간에 독립적인 비교 데이터를 단일 합 성곱 신경망에서 재학습하여 사용자 인식을 진행한다. 표 6은 다층 구조의 단일 네트워크 계층별 출력 결과이다.



표	6.	네트워크	계층별	출력	결과	

Layer(type)	Output shape
Input_1(Input layer)	(None, 880, 1)
block1_conv1(Conv1D)	(None, 880, 32)
block1_conv2(Conv1D)	(None, 880, 32)
block1_pool(Max-pooling1D)	(None, 440, 32)
dropout_1(Dropout)	(None, 440, 32)
block2_conv1(Conv1D)	(None, 440, 64)
block2_conv2(Conv1D)	(None, 440, 64)
block2_pool(Max-pooling1D)	(None, 220, 64)
dropout_2(Dropout)	(None, 220, 64)
block3_conv1(Conv1D)	(None, 220, 128)
block3_conv2(Conv1D)	(None, 220, 128)
block3_pool(Max-pooling1D)	(None, 110, 128)
dropout_3(Dropout)	(None, 110, 128)
block4_conv1(Conv1D)	(None, 110, 256)
block4_conv2(Conv1D)	(None, 110, 256)
block4_pool(Max-pooling1D)	(None, 55, 256)
dropout_4(Dropout)	(None, 55, 256)
block5_conv1(Conv1D)	(None, 55, 512)
block5_conv2(Conv1D)	(None, 55, 512)
flatten(Flatten)	(None, 28160)
fc1(Dense)	(None, 1028)
fc2(Dense)	(None, 1028)
predictions(Dense)	(None, 89)





### 제3절 크기 부적합 문제 해결을 위한 가상 데이터 생성

딥러닝 모델인 GAN은 2014년 lan Goodfellow가 제안한 생성 모델로 발표된 후 데이터 생성, 해상도 개선, 자연어 처리 등 다양한 분야에서 훌륭한 성과를 보이 고 있다. GAN은 서로 다른 두 개의 다층 퍼셉트론으로 구성된 생성자와 판별자의 대립적인 학습을 통해 데이터를 생성해내는 생성 모델이다.



그림 23. 적대적 생성 신경망 구조

생성자는  $\theta_g$ 를 파라미터로 갖는 다층 퍼셉트론으로 이루어진 미분 가능한 함수 이며, 판별자는  $\theta_d$ 를 매개변수로 사용하여 단일 스칼라를 출력하는 다층 퍼셉트론 이다. 생성자는 입력으로 잡음(Noise) 또는 잠재변수(Latent variable)을 입력받 아 이미지를 생성한다. 판별자는 입력된 데이터가 실제 분포에서 온 데이터인지 잠재변수로부터의 데이터인지에 대한 확률을 나타낸다. 랜덤잡음 벡터를 입력받아 초기 데이터를 생성하고 생성된 데이터 진위를 평가하면서 생성자는 실제와 유사 한 데이터를 생성해내며 판별자를 속이게끔 학습되고 판별자는 더 잘 구별해내기 위한 방향으로 학습이 진행되어 서로의 성능을 점차 개선해 나가는 것이 주요 학 습 방법이다. 그림 23은 GAN의 개념적인 구조를 나타내며, 학습 과정에 대해 그림 24로 표현할 수 있다.







그림 24. 적대적 생성 신경망 프레임워크

생성된 데이터가 주어진 실제 데이터와 유사해지기 위해서는 수학적으로 실제 데이터 확률 분포 와 생성된 데이터의 확률 분포가 비슷해야한다. 즉, 실제 데이 터의 확률 분포를 나타낼 수 있다면 생성된 데이터는 실제 데이터와 유사한 확률 분포를 나타낸다. 첫 번째로는 실제 데이터의 확률 분포에 직접적인 접근 방법으 로써, 생성된 데이터의 확률 분포가 실제 데이터의 확률 분포와 유사해지도록 만 드는 방법이다. 실제 데이터의 확률 분포에 대해 정확히 알고 있을 경우, 직접적 인 접근 방법으로 데이터를 생성하는 것이 높은 성능을 나타낼 수 있다. 그러나 일반적으로 실제 데이터의 확률 분포를 파악하기 어려우며 하나의 데이터에 대한 확률 분포를 정하는데 많은 계산량이 필요하다. 그래서 직접적인 접근 방법에서는 가우시안 분포를 이용해 임의의 확률 분포를 가정하여 사용한다. 두 번째 방법으 로는 GAN과 마찬가지로 데이터 확률 분포에 대해 간접적으로 접근하는 방법이다. 실제 데이터의 확률 분포에 대해 임의의 확률 분포를 가정할 필요가 없으며, 학습



과정을 통해 생성된 데이터가 실제 데이터에 가까워지도록 만들 수 있다. GAN은 학습과정에서 판별자가 실제 데이터인지 생성 데이터인지 구별하며, 생성자는 생 성한 데이터를 판별자가 실제 데이터로 판단할 수 데이터를 생성한다.

생성자는 판별자가 올바른 구별을 못하도록 실제 데이터와 유사한 데이터를 생 성하기 위해 학습하고 판별자는 입력된 데이터에 대해 정확한 판단을 할 수 있도 록 학습이 진행된다. 이러한 학습을 위해 식 (3)과 같이 손실함수로 최대최소 문 제를 수행한다.

$$\min_{G} \max_{D} V(D, G) = E_{x \sim p_{1+1}(z)}[\log D(x)] + E_{z \sim p_{1}(z)}[\log(1 - D(G(z)))]$$
(3)

판별자를 통해 출력되는 결과 값이 실제 데이터에 대한 D(x)는 최대화하기 위 해 학습되며, 생성자가 생성한 데이터를 판별하는 D(G(z))에 대해서는 최소화하기 위해 학습이 진행된다. z는 입력되는 랜덤 잡음을 의미한다. 초기 학습단계에서는 구별자의 성능이 월등하지만 충분한 학습단계를 거치면서 생성자는 더욱 실제 데 이터와 유사하게 생성하고, 판별자는 생성된 가상 데이터와 실제 데이터를 구별할 수 없는 시점에 도달하여 D(x)는 1/2의 확률을 갖게 된다.

GAN은 데이터의 생성이 간단하며 학습이 최대 우도와 관계가 없다는 점, 생성 자가 학습 데이터를 보지 않기 때문에 과적합이 발생하지 않는다는 점, 최소값을 찾는데 뛰어난 장점이 있다. 그러나 GAN은 학습과정에서 최소극대화 문제로 접근 하기 때문에 학습의 불안정성 문제를 내포하고 있다. GAN의 모드 붕괴(Mode collapse)가 불안정한 학습의 대표적인 현상이다. 모드 붕괴란 생성자가 다양한 클래스를 생성하지 못하고 손실함수 값에 초점이 맞추어 판별을 잘하기 위한 소수 모드에 집중되어 다양한 클래스에 대해 균등한 데이터를 생성하지 못하는 현상을 말한다. 이는 알고리즘이 최적해로 도달하지 않고, 국부 최적점(Local optimal point)에 빠진 것을 의미한다. 그림 25는 GAN이 학습 과정에서 모드 붕괴된 예이





다. 2차원 가우시안 혼합 모델인 원본 데이터는 8개의 모드가 존재하지만, 생성된 데이터는 한 번에 하나의 모드만 나타내고 있다.



이러한 문제점을 해결하기 위해 GAN을 이용한 많은 연구가 활발히 이루어지고 있다. ACGAN(Auxiliary classifier GAN)은 생성한 데이터를 실제 데이터와 더 유 사하게 만들 수 있도록 보조 분류기(Auxiliary classifier)를 사용한다. 그림 26 과 같이 기존 적대적 생성 신경망에 클래스 정보를 추가하여 신경망의 성능을 향 상시킨다. ACGAN은 입력된 클래스 정보를 이용하여 데이터를 생성하며 생성된 데 이터의 클래스를 보조 분류기를 통해 판별하는 모델이다. 기존의 판별자는 실제 데이터인지 생성된 데이터인지를 판별하도록 학습이 진행되었다면, ACGAN의 경우 데이터의 클래스까지 구별할 수 있도록 학습이 진행된다. 생성자는 판별자를 속이 기 위해 데이터를 생성하는 것이 아니라 생성된 데이터가 정확한 분류 결과를 나 타낼 수 있도록 데이터를 생성한다. 이러한 학습과정을 통해 생성된 데이터는 실





Collection @ chosun

제 데이터와 유사한 결과를 얻을 수 있다. 또한, 클래스 정보를 이용하여 특정 클 래스의 데이터를 생성할 수 있다.



그림 26. 보조 분류기를 사용한 적대적 생성 신경망 구조

본 논문에서 사용된 ACGAN의 구조는 그림 27과 같이 생성자와 판별자를 서로 다른 CNN 모델을 갖도록 설계하였다. 한 주기 심전도 신호 생성을 위해 생성자의 입력 데이터는 생성하고자하는 주기의 크기와 동일한 잡음 및 클래스 정보를 입력 데이터로 사용한다. 1차원 합성곱 연산과 풀링 연산을 반복적으로 사용하여 생성 자 모델에서 생성된 데이터는 클래스 정보와 함께 판별자 모델의 입력 데이터로 사용된다. 생성자 모델은 반복 실험을 통해 계층의 수가 증가할수록 실제 심전도 신호와 유사한 데이터를 생성해내지 못하고, 오히려 학습과정에서 데이터 손실로 인해 생성된 심전도 신호의 값이 발산하는 현상이 나타났다.





Generator

(a) 가상 심전도 신호 생성을 위한 생성자 모델



(b) 실제 심전도 신호 및 가상 심전도 신호 구분을 위한 판별자 모델 그림 27. 제안한 생성자와 판별자 네트워크 구조

따라서 생성자 모델은 9층의 합성곱 계층과 2층의 풀링 계층 및 완전 연결 계 층으로 설계하였다. 판별자 모델은 실제 심전도 신호와 판별자 모델에서 입력받은 가상 심전도 신호 및 클래스를 구분하기 위한 방향으로 학습을 진행한다. 판별자 모델의 구조는 실제 심전도 신호 및 클래스 정보와 가상 심전도 신호 및 클래스 정보를 구분하기 때문에 생성자 모델에 비해 깊지 않은 구조의 합성곱 연산을 반 복하는 CNN 모델로 설계한다. 이에, 생성자 모델과 판별자 모델은 반복 학습을 통 해 실제 심전도 신호와 유사한 가상 심전도 신호를 생성하였다. 그림 28은 학습 횟수별 생성자 모델로부터 생성된 가상 심전도 결과이다. 학습 초기에는 잡음에 가까운 심전도 신호를 생성해내지만, 학습이 진행됨에 따라 실제 심전도 신호와 유사한 파형을 나타내는 것을 확인할 수 있다.

- 42 -











## 제4장 실험 결과 및 분석

본 장에서는 제안하는 가상 데이터 생성 및 다층 구조의 앙상블 네트워크 성능 을 평가하기 위해 사용자 상태 변화에 따라 자체적으로 심전도 신호를 취득한 후, 실제 심전도 신호와 가상 심전도 신호를 조합한 비교 데이터를 구성하여 사용자 인식 성능을 분석한다.

### 제1절 실험 방법

본 논문에서는 가상 데이터 생성 방법을 평가하기 위해 실제 심전도 신호와 생 성된 가상 심전도 신호의 유사도를 확인한다. 평가 방법은 두 신호간 방향의 유사 도를 판단하기 위해 코사인 유사도(Cosine similarity) 검증 방법과 시간 지연에 따른 패턴 분석을 통한 교차 상관관계(Cross correlation) 검증 방법을 사용한다.

#### 1. 심전도 신호 DB

본 논문에서는 실생활 환경에서 발생하는 심박수 및 파형 변화에 따른 사용자 의 심전도 신호 변화를 분석하고 사용자 인식에 적용하기 위해 20대에서 50대 사 이의 다양한 연령층의 성인 89명을 대상으로 자체 심전도 신호 취득을 진행하였 다. 사용자의 상태를 확인하기 위한 설문지 작성하였으며, 그림 29와 같이 측정에 사용한 장비는 BIOPAC 시스템사의 MP160모델로 습식전극을 이용해 Lead-1 심전도 신호를 취득하였다. Lead-1 심전도 신호는 사지유도 방법 중에 왼손과 오른손에 부착된 두 전극 사이의 전위차에 의해 기록되는 신호로써 사용자 인식 시스템에 활용 가능성이 높은 신호이다.







그림 29. 심전도 신호 취득 예

또한, 시간에 독립적인 심전도 신호를 취득하기 위해 1년 이상의 오랜 시간에 걸쳐 측정을 진행하였으며, 실생활에서 쉽게 심전도 신호 변화를 줄 수 있는 4가 지 상황에 대해 아래와 같이 정의하여 심전도 신호를 측정하였다.

- 누워있는 상태 : 충분한 휴식을 주고 가만히 누워있는 상태에서 1분간 취득
- 서있는 상태 : 충분한 휴식을 주고 가만히 서있는 상태에서 1분간 취득
- 운동 전 상태 : 충분한 휴식을 주고 가만히 앉아있는 상태에서 1분간 취득
- 운동 후 상태 : 스텝퍼 운동기구를 통해 심박수 120이상을 유지한 상태에서 운 동을 진행한 후 1분간 취득



(a) 누워있는 상태에서 심전도 신호 취득 예







(b) 서있는 상태에서 심전도 신호 취득 예



(c) 운동 전 상태에서 심전도 신호 취득 예



(d) 운동 후 상태에서 심전도 신호 취득 예그림 30. 심전도 신호 변화를 위한 사용자 상태 정의





심전도 신호에 영향을 줄 수 있는 카페인 등의 음식이나 약물 섭취 등에 제약 을 주었던 기존 연구들과 달리 본 논문에서는 제약사항을 고려하지 않았다. 실험 자의 일정에 따라 심전도 신호 취득은 모두 다른 날(Multi-session)에 2,000Hz Sampling rate로 총 3회에 거쳐 취득하였다.

### 2. 생성된 가상 심전도 신호의 유사도 검증 방법

서로 다른 데이터간의 유사도를 계산하는 방법에는 여러 가지가 있다. 본 논문 에서는 실제 심전도 신호와 생성된 가상 심전도 신호의 유사도를 확인하기 위해 코사인 유사도와 교차 상관관계를 이용하여 유사도를 측정하였다. 먼저 코사인 유 사도는 벡터의 크기가 아닌 방향의 유사도를 판단하는 목적으로 두 심전도 신호 사이의 유사도를 코사인 각도로 나타내는 방법이다. 두 심전도 신호에 대한 유사 도는 -1~1사이의 값으로 표현되며 1에 가까울수록 유사하다는 것을 의미한다. 코 사인 유사도를 구하는 방법은 식 (4)와 같으며, A와 B는 유사도를 구하기 위하여 서로 비교하게 될 데이터의 벡터이다[51].

$$\cos(A, B) = \frac{A \cdot B}{\|A\| \|B\|} = \frac{\sum_{i=1}^{n} A_i \times B_i}{\sqrt{\sum_{i=1}^{n} (A_i)^2 \times \sqrt{\sum_{i=1}^{n} (B_i)^2}}}$$
(4)

교차 상관관계는 두 데이터간의 관련된 정도를 도출하는 방법이며, 한 시계열 데이터와 서로 다른 시계열 데이터간의 유사성을 알기 위해서 사용한다. 교차 상 관관계는 두 시계열 데이터 사이의 상관을 분석하는 과정에서 시간 지연을 할당하 여 패턴을 분석함으로써 상관관계 결과를 분석한다. 두 시계열 데이터의 교차 상 관관계에 대한 수식은 식 (5)와 같다[52].

- 47 -





Collection @ chosun

$$Cross correlation[\tau] = \sum_{i=0}^{n-1} x_i y_{i+\tau}$$
(5)

이 때 *i*은 입력 데이터의 인덱스를 의미하며, *τ*은 입력신호의 이동값으로 데 이터의 범위에 따라 변경 가능하다. 교차 상관관계는 한 데이터를 고정하고, 다른 데이터를 *τ*만큼 이동하면서 두 데이터의 유사성을 측정한다. 입력된 데이터가 같 으며, *τ*=0일 때 교차 상관관계는 최대값을 출력한다. *τ*=0 일 때 교차 상관관계 는 두 시계열 데이터 *x<sub>i</sub>*, *y<sub>i</sub>를* 고정시킨 후, 각 변수를 곱해서 더한다.



au = -1 일 때 교차 상관관계는 그림 32와 같으며 한 데이터  $x_i$ 는 고정시키고 비교 데이터  $y_i$ 를 왼쪽으로 한 칸 이동시킨 후, 각 변수를 곱해서 더한다.



그림 32.  $\tau = -1$ 일 때 교차 상관관계

au=1 일 때 교차 상관관계는 그림 33과 같으며 한 데이터  $x_i$ 는 고정시키고 비 교 데이터  $y_i$ 를 오른쪽으로 한 칸 이동시킨 후, 각 변수를 곱해서 더한다.





### 제2절 생성된 가상 심전도 신호의 유사도 결과 및 분석

생성된 가상 심전도 신호와 실제 데이터와의 유사도를 검증하기 위해 본 논문 에서는 코사인 유사도와 교차 상관관계를 이용하여 유사도를 측정한다. 먼저 실제 심전도 신호와 가상 심전도 신호간 방향 유사도를 확인하기 위해 실험자 89명의 코사인 유사도 검증 결과를 확인하였다.

Class	1	2	3	4	5	6	7	8	9
Result	0.998	0.996	0.996	0.995	0.996	0.991	0.99	0.997	0.994
Class	10	11	12	13	14	15	16	17	18
Result	0.99	0.989	0.988	0.991	0.979	0.991	0.974	0.995	0.994
Class	19	20	21	22	23	24	25	26	27
Result	0.993	0.991	0.992	0.99	0.989	0.994	0.992	0.994	0.98
Class	28	29	30	31	32	33	34	35	36
Result	0.995	0.996	0.993	0.99	0.979	0.996	0.989	0.996	0.995
Class	37	38	39	40	41	42	43	44	45
Result	0.993	0.987	0.99	0.989	0.996	0.995	0.995	0.975	0.987
Class	46	47	48	49	50	51	52	53	54
Result	0.988	0.984	0.93	0.994	0.994	0.994	0.985	0.986	0.997
Class	55	56	57	58	59	60	61	62	63
Result	0.995	0.998	0.978	0.998	0.996	0.98	0.996	0.995	0.993
Class	64	65	66	67	68	69	70	71	72
Result	0.982	0.996	0.996	0.992	0.995	0.993	0.988	0.995	0.995
Class	73	74	75	76	77	78	79	80	81
Result	0.992	0.995	0.994	0.99	0.992	0.987	0.994	0.996	0.989
Class	82	83	84	85	86	87	88	89	AVG
Result	0.994	0.996	0.996	0.989	0.995	0.992	0.995	0.998	0.991

표 7. 실험자별 코사인 유사도 측정 결과





Collection @ chosun

코사인 유사도는 -1에서 1까지 출력 범위로 1에 가까울수록 두 신호간의 높은 유사도를 나타내며, -1에 가까울수록 다른 파형의 신호를 의미한다. 표 7은 실험 자별 코사인 유사도 측정 결과로 최소 0.974유사도부터 최대 0.998유사도를 나타 냈으며, 89명의 평균 코사인 유사도는 0.991유사도 결과를 나타냈다.



현재 심전도 신호 주기 다음 심전도 신호 주기 두 신호간의 교차 상관관계 (a) 동일한 실험자의 실제 심전도 신호 간 교차 상관관계 결과



현재 심전도 신호 주기 가상 심전도 신호 주기 두 신호간의 교차 상관관계 (b) 동일한 실험자의 실제 심전도 신호 및 가상 심전도 신호 간 교차 상관관계 결과



A 실험자의 심전도 신호 주기 B 실험자의 심전도 신호 주기 두 신호간의 교차 상관관계 (c) 서로 다른 실험자 간 실제 심전도 신호 교차 상관관계 결과 그림 34. 심전도 신호 간 교차 상관관계 결과





다음으로 신호처리 분야에서 서로 다른 두 신호에 대해 얼마나 유사한지를 상 관분석을 통해 정량화하는 교차 상관관계를 이용하여 유사도 결과를 확인하였다. 교차 상관관계는 두 시계열 데이터 사이의 상관을 분석하는 과정에서 시간 지연을 할당하여 패턴을 분석함으로써 상관관계 결과를 분석한다.

그림 34(a)는 동일한 실험자에 대해 현재 심전도 신호 주기와 다음 심전도 신 호 주기를 교차 상관관계를 분석한 결과의 예이다. 그림 34(b)는 동일한 실험자에 대해 현재 심전도 신호 주기와 가상으로 생성한 심전도 신호 주기를 교차 상관관 계를 분석한 결과의 예이다. 그림 34(c)는 서로 다른 실험자간의 실제 심전도 신 호 주기에 대해 교차 상관관계를 분석한 결과의 예이다. 그림 34(a), 34(b)와 같 이 동일한 사람으로부터 출력된 실제 심전도 신호 간의 교차 상관관계 파형은 유 사함을 확인할 수 있다. 그러나 서로 다른 실험자의 심전도 신호 주기를 이용한 교차 상관관계를 확인한 결과 그림 34(c)와 같이 다른 형태의 교차 상관관계 파형 을 출력함을 확인할 수 있다. 따라서 그림 35와 같이 현재 심전도 신호 주기와 다 음 심전도 신호 주기로부터 출력된 교차 상관관계 파형에 현재 심전도 신호 주기 와 가상으로 생성된 심전도 신호의 교차 상관관계 파형을 오버럽한 후, 유클리디 언 거리를 이용하여 두 신호간의 유사도를 수치적으로 나타냈다.



그림 35. 유클리디언 거리를 이용한 교차 상관관계 유사도 측정



두 교차 상관관계의 유클리디언 거리는 0에 가까울수록 동일한 실험자의 실제 심전도 신호와 유사한 가상 심전도 신호 생성을 나타내며, 0에서 멀어질수록 서로 다른 실험자간의 실제 심전도 신호와 가상 심전도 신호의 교차 상관관계 결과를 의미한다. 표 8은 실험자별 교차 상관관계 기반 유클리디언 거리를 이용한 유사도 측정 결과로 최소 0.136유사도부터 최대 0.364유사도를 나타냈으며, 89명의 평균 유클리디언 거리는 0.25유사도 결과를 나타냈다.

Class	1	2	3	4	5	6	7	8	9
Result	0.264	0.352	0.166	0.247	0.212	0.31	0.178	0.242	0.36
Class	10	11	12	13	14	15	16	17	18
Result	0.136	0.254	0.223	0.176	0.198	0.261	0.36	0.163	0.227
Class	19	20	21	22	23	24	25	26	27
Result	0.325	0.298	0.271	0.35	0.221	0.259	0.197	0.362	0.296
Class	28	29	30	31	32	33	34	35	36
Result	0.27	0.344	0.168	0.19	0.224	0.314	0.356	0.172	0.34
Class	37	38	39	40	41	42	43	44	45
Result	0.198	0.21	0.332	0.281	0.26	0.314	0.171	0.364	0.218
Class	46	47	48	49	50	51	52	53	54
Result	0.323	0.167	0.229	0.284	0.341	0.217	0.29	0.192	0.23
Class	55	56	57	58	59	60	61	62	63
Result	0.276	0.139	0.224	0.261	0.25	0.317	0.163	0.183	0.266
Class	64	65	66	67	68	69	70	71	72
Result	0.189	0.16	0.335	0.238	0.162	0.281	0.318	0.29	0.314
Class	73	74	75	76	77	78	79	80	81
Result	0.195	0.263	0.225	0.242	0.22	0.196	0.329	0.214	0.31
Class	82	83	84	85	86	87	88	89	AVG
Result	0.324	0.161	0.243	0.324	0.212	0.194	0.22	0.139	0.25

표 8. 교차 상관관계 기반 유클리디언 거리를 이용한 유사도 측정 결과





그림 36은 교차 상관관계 기반 유클리디언 거리의 최소 유사도와 최대 유사도 를 나타낸 심전도 신호 결과이다. 최소 유사도를 보인 그림 36(a)의 가상 심전도 신호는 P, QRS, T파를 포함한 전체적인 파형의 패턴이 실제 심전도 신호와 매우 유사함을 확인할 수 있다. 그림 36(b)의 경우, 실제 심전도 신호와 가상 심전도 신호의 패턴은 유사하지만 P, QRS, T파 값의 차이가 발생하여 그림 36(a)에 비해 낮은 성능의 유사도 결과를 나타냈다.



실험결과, 보조 분류기를 이용한 적대적 생성 신경망은 다양한 특징의 데이터 생성 확인하였으며, 특히 본 논문에서 제안한 네트워크를 사용한 결과 그림 37과 같이 실제 심전도 신호와 매우 유사한 방향성 특징 및 실험자별 서로 다른 상관관 계 파형을 갖는 가상 심전도 신호 생성 결과 나타냈다. 이는 실제 심전도 신호와 유사한 가상 심전도 신호를 생성하는 것을 의미하며, 등록 데이터와 비교 데이터 간의 크기가 일치하지 않더라도 가상 데이터 생성을 통해 데이터 크기 부적합 문 제를 해결했다.







그림 37. 실제 심전도 신호와 가상 심전도 신호 비교

# 제3절 앙상블 네트워크를 이용한 사용자 인식 성능 분석

본 논문에서 심전도 신호를 이용한 사용자 인식은 1:N 인식 방법으로써 데이터 베이스에 저장된 심전도 신호 중 가장 유사한 첫 번째 심전도 신호를 인식 결과로 사용한다. 또한 본 논문에서는 1주기부터 n주기까지 주기별 인식 성능을 확인하였 을 때, 5주기 이상부터 일정한 성능이 수렴되어 등록 데이터의 크기를 5주기로 설 정한다.







Collection @ chosun

또한 사용자 상태에 따라 인식 성능을 확인하기 위해 자체 취득한 심전도 신호 를 분석한 결과 그림 39와 같이 누워있는 상태, 서있는 상태, 운동 전 상태의 경 우 심박수 및 파형의 차이가 크게 나타나지 않았다.



(b) 운동 후 상태의 심전도 신호 그림 39. 사용자 상태 변화에 따른 심전도 신호 변화

그러나 신체적 활동이 발생한 운동 후 상태의 심전도 신호는 P, QRS, T파 구간 이 상대적으로 더 가까이 발생하는 것을 확인하였다. 이에 사용자 상태에 따라 가 장 큰 차이의 심박수 변화를 나타내는 누워있는 상태, 서있는 상태, 운동 전 상태 를 학습 데이터로 사용하고 운동 후 상태를 비교 데이터로 사용하여 사용자 인식 실험을 진행했다. 실험 결과 그림 40과 같이 최소 78.2%부터 최대 83.7%의 인식 성능을 나타내 동일한 실험자로부터 취득된 심전도 신호를 사용하더라도 사용자 상태 변화에 따라 취득된 새로운 심전도 신호를 비교 데이터로 사용할 경우 인식 성능이 저하됨을 확인했다.





이러한 과적합 문제를 해결하기 위해 본 논문에서 제안한 다층 구조의 앙상블 네트워크에 자체 취득한 실제 심전도 신호를 적용했다. 데이터 구성은 누워있는 상태, 서 있는 상태, 운동 전·후 상태에서 처음 취득한 심전도 신호를 등록 데이 터로 사용했으며, 두 번째 취득한 심전도 신호는 검증 데이터, 세 번째 취득한 심 전도 신호를 비교 데이터로 사용했다. 과적합 문제 해결을 위한 기존 연구인 2차 원 심전도 영상을 이용한 단일 합성곱 신경망 방법 및 다층 구조의 1차원 합성곱 신경망 방법과 비교 실험을 진행했다.

Jun et al.(2018)이 제안한 2차원 심전도 영상을 이용한 단일 합성곱 신경망은 1차원 심전도 신호를 2차원 영상으로 변환하여 단일 합성곱 신경망에 적용하는 방 법이다. 합성곱 신경망 구조는 6개의 합성곱 계층과 3개의 최대 풀링 계층으로 설 계되었으며, 각 층에 배치 정규화를 적용했다. Zhang et al.(2018)이 제안한 다층 구조의 1차원 합성곱 신경망은 입력 데이터인 심전도 신호를 웨이블렛 변환한 후, 자기 상관계수를 통해 서로 다른 특징을 추출했다. 추출된 특징들은 각 단일 네트 워크의 입력 데이터로 사용되며 완전 연결 계층에서 각 특징들을 융합하여 사용자 인식을 진행한다. 제안한 합성곱 신경망 구조는 5개의 합성곱 계층과 4개의 최대



풀링 계층, 2개의 완전 연결 계층으로 설계되었다. 그러나 다층 구조의 네트워크 수가 정의되지 않아 본 논문과 동일하게 6개의 네트워크를 설계했다.



그림 41. 자체 취득한 심전도 신호를 이용한 기존 연구와 인식 성능 비교

그림 41은 기존 연구와의 인식 성능을 비교한 실험 결과로 2차원 심전도 영상 을 이용한 단일 합성곱 신경망 방법과 다층 구조의 1차원 합성곱 신경망 방법은 각각 94.4%, 95.7%의 정확도를 보였다. 본 논문에서 제안한 다층 구조의 앙상블 합성곱 신경망에 적용한 결과 98.5%의 정확도로 기존 연구에 비해 높은 인식 성능 을 보였다. 이는 2차원 심전도 영상의 경우 단순히 심전도 파형 정보만을 특징으 로 사용하며, 단일 합성곱 신경망으로 설계되어 사용자 상태 변화에 따라 취득된 심전도 신호를 인식하지 못해 가장 낮은 인식 성능을 나타냈다. 다층 구조의 1차 원 합성곱 신경망 방법은 동일한 실험자일지라도 사용자 상태에 따라 웨이블렛 변 환 및 자기 상관계수에 따라 출력된 특징의 차이가 발생하여 본 논문에서 제안한 양상블 합성곱 신경망에 비해 낮은 성능을 보였다.





	Test data set					
Real 1+Synthet ic1~4	Real 1	Synthetic1	Synthetic2	Synthetic3	Synthetic4	
Real 1~2+Synthet i c1~3	Real 1	Rea12	Synthetic1	Synthetic2	Synthetic3	
Real 1~3+Synthetic1~2	Real 1	Rea12	Real3	Synthetic1	Synthetic2	
Real1~4+Synthetic1	Real 1	Rea12	Real3	Real4	Synthetic1	

표 9. 주기별 가상 심전도 신호를 적용한 데이터 구성

실생활 환경에서 일정한 주기의 심전도 신호를 취득하기 어렵기 때문에 표 9와 같이 사용자 상태 변화에 따라 자체 취득한 실제 심전도 신호와 생성한 가상 심전 도 신호의 주기별 다양한 조합으로 비교 데이터를 구성하여 사용자 인식 실험을 진행했다.

	학습 데이터	검증 데이터	비교 데이터	총 데이터 수
Day-1	200	_	_	53,400
Day-2	_	200	_	17,800
Day-3	_	_	200	17,800

표 10. 자체 취득한 심전도 신호 실험 데이터베이스 구성

실험에 사용된 데이터 수는 표 10에서 보시는 바와 같이 89명의 실험자로부터 3회에 걸쳐 취득한 데이터는 개인 당 600개로 학습 데이터는 데이터 확장 방법을 통해 53,400개를 사용하였으며, 검증 데이터와 비교 데이터는 17,800개 설정하였 다.




실험 결과 그림 42와 같이 실제 심전도 신호와 가상 심전도 신호를 조합한 실 험 결과에 대해 비교적 높은 인식 성능을 나타냈다. 그러나 주기별 가상 심전도 신호 적용 여부와 관계없이 각각의 실험 결과에 대해 유사한 인식 성능을 나타낼 것으로 예상했으나, 실제 심전도 신호 1주기와 가상 심전도 신호 4주기를 사용한 경우 96.1% 인식률로 가장 낮은 인식 성능을 보였다. 또한 실제 심전도 신호 4주 기와 가상 심전도 신호 1주기를 사용한 경우 98.7%로 가장 높게 나타나 실제 심전 도 신호 주기가 증가함에 따라 인식 성능이 높아지는 결과를 보였다.

표 11. 동일한 심전도 신호를 반복적으로 사용한 데이터 구성

	Test data set							
Real	Real 1	Real 1	Real1	Real1	Real1			
Synthetic	Synthetic1	Synthetic1	Synthetic1	Synthetic1	Synthetic1			

이러한 결과를 분석하기 위해 표 11과 같이 가상 심전도 신호 1주기를 반복적 으로 사용한 비교 데이터와 실제 심전도 신호 1주기를 반복적으로 사용한 비교 데 이터를 구성하여 실험을 진행했다.







그림 43. 동일한 심전도 신호를 반복적으로 적용한 인식 성능 결과

실험 결과, 실제 심전도 신호와 가상 심전도 신호를 반복적으로 사용할 경우, 96.6%와 95.9% 인식 성능을 보여 실제 심전도 신호 1주기와 가상 심전도 신호 4주 기를 사용한 데이터와 유사한 결과를 보였다. 이는 동일한 심전도 신호를 반복적 으로 사용한 경우, 모두 동일한 P, QRS, T값을 갖게 되지만 실제 심전도 신호는 취득과정에서 다양한 환경 변수로 인해 P, QRS, T값의 차이를 나타낸다. 따라서 실제 심전도 신호 1주기를 이용해 생성된 4주기의 가상 심전도 신호는 P, QRS, T 값의 변화가 나타나지 않아 동일한 심전도 신호를 반복적으로 사용한 결과와 유사 한 성능을 나타냈다.

	Test data set						
Real data1~5	Real 1	Rea12	Real3	Real4	Real5		
Real1~4 + Synthetic1	Real 1	Real2	Real3	Real4	Synthetic1		
Real1~4 + Real4	Real 1	Rea12	Real3	Real4	Real4		
Real1~3 + Synthetic1~2	Real 1	Rea12	Real3	Synthetic1	Synthetic2		
Real1~3 + Real3~3	Real 1	Rea12	Real3	Real3	Real3		
Real1~2 + Synthetic1~3	Real 1	Real2	Synthetic1	Synthetic2	Synthetic3		
Real1~2 + Real2~2	Real 1	Rea12	Real2	Real2	Real2		

표 12. 사용자 인식 성능 비교를 위한 실험 데이터베이스 구성





끝으로 표 12와 같이 주기별 실제 심전도 신호에 가상 심전도 신호 및 반복적 으로 동일한 실제 심전도 신호를 사용한 데이터베이스를 구성하여 제안한 다층 구 조의 앙상블 네트워크에 적용하였다. 실험 결과, 실제 심전도 신호 5주기를 사용 할 경우 98.5%의 인식 성능을 보였으며, 실제 심전도 신호 4주기에 마지막 주기를 가상 심전도 신호 1주기와 마지막 4번째 주기를 반복적으로 사용한 결과 98.7%, 97% 정확도를 나타냈다. 실제 심전도 신호 3주기에 가상 심전도 신호 2주기를 사 용하였을 경우 97.2%의 정확도를 보였으며, 실제 심전도 신호 3주기에 마지막 3번 째 주기를 반복적으로 사용할 경우 가상 심전도 신호를 이용한 성능에 비해 1.2% 낮은 96% 정확도를 보였다. 이는 생성된 가상 심전도 신호를 이용한 성능에 비해 1.2% 다가한 신호로 판단할 수 있으며, 실제 심전도 신호를 반복적으로 사용한 데이터 에 비해 가상 심전도 신호를 조합한 데이터 구성이 우수한 인식 성능을 나타냈다. 따라서 데이터 크기 부적합 문제와 과적합 문제가 발생하더라도 가상 심전도 신호 를 이용한 다층 구조의 앙상블 네트워크를 통해 높은 사용자 인식 결과를 나타낼 수 있다.







## 제5장 결론

기존 심전도 신호를 이용한 사용자 인식 연구들은 초기 실험환경에서 등록 데 이터와 비교 데이터를 동일한 크기로 구성하여 실험을 진행하였다. 심전도 신호는 시간변화에 따라 취득되는 시계열 데이터로 충분한 시간을 갖고 비교 데이터를 취 득할 경우 사용자 인식에 적용 가능하다. 그러나 비교 데이터 취득 시간이 부족하 여 등록 데이터와 동일한 크기가 아닐 경우 데이터 크기 부적합 문제로 인해 사용 자 인식에 적용할 수 없다. 또한, 기존 심전도 기반 사용자 인식 연구들은 대부분 심박수 및 파형 변화의 영향을 최소화하기 위해 동일한 상태의 데이터만을 사용하 거나, 시간에 독립적인 심전도 데이터만을 이용하기 위해 하루 동안 1회 측정한 데이터를 가지고 인식 알고리즘에 적용한 경우가 대부분이다. 그러나 심전도 신호 는 개인의 신체적 활동이나 측정 시간대 또는 정신적 영향에 의해 심박수 및 파형

본 논문에서는 데이터 크기 부적합 문제를 해결하기 위해 실제 심전도 신호와 유사한 가상 심전도 신호 생성이 가능한 보조 분류기 기반 적대적 생성 신경망의 네트워크 모델을 제안하였다. 생성자 모델은 반복 실험을 통해 신경망 계층의 수 가 증가할수록 실제 심전도 신호와 유사한 데이터를 생성해내지 못하고, 오히려 학습과정에서 데이터 손실로 인해 생성된 심전도 신호의 값이 발산하는 현상이 나 타나 9개의 합성곱 계층과 2개의 풀링 계층 및 완전 연결 계층을 설계하였다. 판 별자 모델의 구조는 실제 심전도 신호 및 클래스 정보와 가상 심전도 신호 및 클 래스 정보를 구분하기 때문에 생성자 모델에 비해 깊지 않은 구조의 합성급 연산 을 반복하는 CNN 모델로 설계하였다. 생성된 가상 심전도 신호를 평가하기 위해 본 논문에서는 코사인 유사도와 교차 상관관계를 이용하여 유사도를 측정했다. 실 험 결과 89명의 평균 코사인 유사도는 0.991유사도 결과를 나타냈으며, 교차 상관 관계 기반 유클리디언 거리를 이용한 유사도 측정 결과로 평균 0.25유사도 결과를

- 62 -





나타냈다. 이는 실제 심전도 신호와 유사한 가상 심전도 신호를 생성하는 것을 의 미하며, 등록 데이터와 비교 데이터간의 크기가 일치하지 않더라도 가상 데이터 생성을 통해 데이터 크기 부적합 문제를 해결했다.

또한, 많은 데이터에 대한 데이터 일반화로 인해 새로운 데이터에 대해 인식 성능이 저하되는 과적합 문제를 확인하기 위해 사용자 상태에 따라 큰 차이의 심 박수 및 파형 변화를 나타내는 누워있는 상태, 서있는 상태, 운동 전 상태를 등록 데이터로 사용하고 운동 후 상태를 비교 데이터로 사용하여 사용자 인식 실험을 진행했다. 실험 결과 최소 78.2%부터 최대 83.7%의 인식 성능을 나타내 동일한 실 험자로부터 취득된 심전도 신호를 사용하더라도 사용자 상태 변화에 따라 취득된 심전도 신호를 비교 데이터로 사용할 경우 인식 성능이 저하됨을 확인했다.

따라서 과적합 문제를 해결하기 위한 기존 연구인 2차원 심전도 영상을 이용한 단일 합성곱 신경망 방법 및 다층 구조의 1차원 합성곱 신경망 방법과 본 논문에 서 제안한 다층 구조의 앙상블 네트워크에 자체 취득한 실제 심전도 신호를 적용 하여 사용자 인식 실험을 진행했다. 데이터 구성은 누워있는 상태, 서 있는 상태, 운동 전·후 상태에서 처음 취득한 심전도 신호를 등록 데이터로 사용하였으며, 두 번째 취득한 심전도 신호는 검증 데이터, 세 번째 취득한 심전도 신호를 비교 데이터로 사용하였다. 실험 결과로 2차원 심전도 영상을 이용한 단일 합성곱 신경 망 방법과 다층 구조의 1차원 합성곱 신경망 방법은 각각 94.4%, 95.7%의 정확도 를 보였다. 본 논문에서 제안한 다층 구조의 앙상블 합성곱 신경망에 적용한 결과 98.5%의 정확도로 기존 연구에 비해 높은 인식 성능을 보였다. 이에 사용자 상태 변화에 따라 취득된 심전도 신호를 비교 데이터로 사용할 경우 발생하는 과적합 문제를 본 논문에서 제안한 다층 구조의 앙상블 네트워크를 통해 해결했다.

마지막으로 실생활 환경에서 일정한 주기의 심전도 신호를 취득하기 어렵기 때 문에 사용자 상태에 따라 실생활에서 심박수 및 파형 변화가 발생하는 자체 취득 한 실제 심전도 신호와 생성한 가상 심전도 신호를 주기별 다양한 조합으로 비교

- 63 -



Collection @ chosun

데이터를 구성한 후, 본 논문에서 제안한 다층 구조의 앙상블 네트워크에 적용하 여 사용자 인식 실험을 진행했다.

실험 결과, 실제 심전도 신호 5주기를 사용할 경우 98.5%의 인식 성능을 보였 으며, 실제 심전도 신호 4주기에 마지막 주기를 가상 심전도 신호 1주기와 마지막 4번째 주기를 반복적으로 사용한 결과 98.7%, 97% 정확도를 나타냈다. 실제 심전 도 신호 3주기에 가상 심전도 신호 2주기를 사용하였을 경우 97.2%의 정확도를 보 였으며, 실제 심전도 신호 3주기에 마지막 3주기를 반복적으로 사용할 경우 가상 심전도 신호를 이용한 성능에 비해 1.2% 낮은 96% 정확도를 보였다. 이는 등록 데 이터와 비교 데이터의 크기가 일치하지 않더라도, 사용자 상태 변화에 따라 가상 심전도 신호를 생성함으로써 데이터 크기 부적합 및 과적합 문제를 해결할 수 있 다. 따라서 실제 심전도 신호를 반복적으로 사용한 인식 결과보다 높은 인식 성능 을 나타내 등록 데이터와 비교 데이터의 크기가 일치하지 않더라도, 사용자 상태 변화에 따라 생성된 가상 심전도 신호를 다층 구조의 앙상블 네트워크에 적용함으 로써 데이터 크기 부적합 및 과적합 문제를 해결하여 실생활 환경에 적용 가능성 을 확인했다.

본 논문에서는 실제 심전도 신호와 유사한 가상 심전도 신호 생성에 초점을 맞 취 연구를 진행하였다. 현재는 가상 심전도 신호 생성을 위해 학습과정을 거쳐야 만 실제 심전도 신호와 유사한 가상 심전도 신호를 생성할 수 있다. 이에, 사전에 학습된 사용자 정보를 이용하여 실시간 심전도 신호 생성에 대한 연구를 진행할 예정이다. 또한, BIOPAC 시스템사의 측정 장비인 MP160을 이용해 측정한 심전도 신호를 사용자 인식 방법에 적용했다. 그러나 실생활에 적용하기 위해서는 스마트 폰, 스마트 워치 등의 웨어러블 기기에서 취득된 심전도 신호를 이용하게 될 것이 다. 심전도 신호 측정에 대한 접근은 용이하지만 이로 인해 발생하는 잡음 제거 등 현실적인 접근에 대한 추가적인 연구가 필요하다.



## 참고문헌

- [1] M. Tsutomu, M. Hiroyuki, Y. Koji, and H. Satoshi, "Impact of artificial gummy fingers on fingerprint systems," *Int. Journal of Optical Security and Counterfeit Deterrence Techniques IV*, vol. 4677, pp. 275-289, 2002.
- [2] A. K. Jain, A. Ross, and S. Prabhakar, "An introduction to biometric recognition," *IEEE Trans. on Circuits and Systems for Video Tech*, vol. 14, pp. 4-20, 2004.
- [3] S. Nanavati, M. Thieme, and R. Nanavati, "Biometrics : Identity verification in a networked world," *Wiley Computer Publishing*, 2002.
- [4] K. Dalacm, "A survey of biometric recognition methods," In Proc.
   46th Int. Symposium Electronics in Marine, pp. 16-18, 2004.
- [5] I. Odinaka, P. H. Lai, A. D. Kaplan, J. A. O'Sullivan, E. J. Sirevaag, and J. W. Rohrbaugh, "ECG biometric recognition: a comparative analysis," *IEEE Trans. on Information Forensics and Security*, vol. 7, no. 6, pp. 1812–1824, 2012.
- [6] M. R. Ogiela, L. Ogiela, "On using cognitive models in cryptography," In Proc. Advanced Information Networking and Applications, pp. 1055–1058, 2016.
- [7] F. Agrafioti, D. Hatzinakos, "Fusion of ECG sources for human identification," In Proc. Int. Conf. Communications, Control and Signal Processing, pp. 1542-1547, 2008.
- [8] M. Simoons, P. Hugenholtz, "Gradual changes of ECG waveform during

- 65 -





and after exercise in normal subjects," *Circulation*, vol. 52, no. 4, pp. 570-577, 1975.

- [9] L. Biel, O. Pettersson, L. Philipson, and P. Wide, "ECG analysis: a new approach in human identification," *IEEE Trans. on Instrumentation and Measurement*, vol. 50, no. 3, pp. 808-812, 2001.
- [10] S. A. Israel, J. M. Irvine, A. Cheng, M. D. Wiederhold, and B. K. Wiederhold, "ECG to identify individuals," *Pattern Recognition*, vol. 38, no. 1, pp. 133-142, 2005.
- [11] J. M. Irvine, B. K. Wiederhold, L. W. Gavshon, S. A. Israel, S. B. McGehee, R. Meyer, and M. D. Wiederhold, "Heart rate variability: a new biometric for human identification," *In Proc. Int. Conf. Artificial Intelligence*, pp. 1106-1111, 2001.
- [12] M. M. Tantawi, K. Revett, A. Salem, and M. F. Tolba, "Fiducial feature reduction analysis for electrocardiogram based biometric recognition," *Int. Journal of Intelligent Information Systems*, vol. 40, no. 1, pp. 17-39. 2013.
- [13] M. Kyoso, A. Uchiyama, "Development of an ECG identification system," In Proc. Int. Conf. Engineering in Medicine and Biology Society, 2001.
- [14] J. M. Irvine, S. A. Israel, "A sequential procedure for individual identity verification using ECG," *EURASIP Journal on Advances in Signal Processing*, vol. 2009, no. 1, pp. 1-13, 2009.
- [15] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, and Y. Bengio, "Generative adversarial nets," Int. In Advances in Neural Information Processing Systems,





pp. 2672-2680, 2014.

- [16] A. Srivastava, L. Valkov, C. Russell, M. U. Gutmann, and C. Sutton, "Veegan: reducing mode collapse in gans using implicit variational learning," *Int. In Advances in Neural Information Processing* Systems, pp. 3308-3318, 2017.
- [17] A. Odena, C. Olah, and J. Shlens, "Conditional image synthesis with auxiliary classifier GANs," In Proc. Int. Machine Learning, pp. 2642-2651, 2017.
- [18] Y. Wang, F. Agrafioti, D. Hatzinakos, and K. N. Plataniotis, "Analysis of human electrocardiogram for biometric recognition," *EURASIP Journal on Advances in Signal Processing*, vol. 2008, no. 1, pp. 148-658, 2007
- [19] T. W. Shen, S. C. Chang, C. H. Wang, and T. C. Fang, "A longitudinal and cross section investigation on peritoneal dialysis patients: does the cardiovascular conditions affect on ECG biometrics?," *Computing in Cardiology*, Belfast, Ireland, pp. 497-500, 2010.
- [20] O. Boumbarov, Y. Velchev, and S. Sokolov, "ECG personal identification in subspaces using radial basis neural networks," In Proc. Int. IEEE Workshop on Intelligent Data Acquisition and Advanced Computing Systems, pp. 446-451, 2009.
- [21] A. D. Chan, M. M. Hamdy, A. Badre, and V. Badee, "Wavelet distance measure for person identification using electrocardiograms," *IEEE Trans. on Instrumentation and Measurement*, vol. 57, no. 2, pp. 248-253, 2008.





- [22] C. C. Chiu, C. M. Chuang, and C. Y. Hsu, "A novel personal identity verification approach using a discrete wavelet transform of the ECG signal," *In Proc. Int. IEEE Multimedia and Ubiquitous Engineering*, pp. 201–206, 2008.
- [23] J. L. C. Loong, K. S. Subari, R. Besar, and M. K. Abdullah, "A new approach to ECG biometric systems : a comparative study between LPC and WPD systems," *World Academy of Science, Engineering and Technology*, vol. 68, no. 20, pp. 759-764, 2010.
- [24] S. Fatemian, D. Hatzinakos, "A new ECG feature extractor for biometric recognition," In Proc. Int. Conf. Digital Signal Processing, pp. 1-6, 2009
- [25] K. S. Kim, T. H. Yoon, J. W. Lee, D. J. Kim, and H. S. Koo, "A robust human identification by normalized time-domain features of electrocardiogram," *In Proc. Int. Conf. IEEE Engineering in Medicine* and Biology Society, pp. 1114-1117, 2006.
- [26] F. Agrafioti, D. Hatzinakos, "ECG biometric analysis in cardiac irregularity conditions," *Int. Jounal of Signal, Image and Video Processing*, vol. 3, no. 4, pp. 329-343, 2009.
- [27] C. H. Chang, "Deep and shallow architecture of multi-layer neural networks," *IEEE Neural Networks and Learning Systems*, vol. 26, no. 10, pp. 2477-2486, 2015.
- [28] P. L. Callet, C. Viard-Gaudin, and D. Barba, "A convolutional neural network approach for objective video quality assessment," *IEEE Neural Networks*, vol. 17, no. 5, pp. 1316-1327, Sep. 2006.

[29] L. Mou, P. Ghamisi, and X. X. Zhu, "Deep recurrent neural networks





for hyperspectral image classification," *IEEE Trans. on Geoscience and Remote Sensing*, vol. 55, no. 7, pp. 3639-3655, 2017.

- [30] W. Diao, X. Sun, X. Zheng, F. Dou, H. Wang, and K. Fu, "Efficient saliency-based object detection in remote sensing images using deep belief networks," *IEEE Geoscience and Remote Sensing Letters*, vol. 13, no. 2, pp. 137-141, 2016.
- [31] E. D. Ubeyli, "Combining recurrent neural networks with eigenvector methods for classification of ECG beats," *Int. Digital Signal Processing*, vol. 19, no. 2, pp. 320-329, 2009.
- [32] M. Zubair, J. Kim, and C. Yoon, "An automated ECG beat classification system using convolutional neural networks," *In Proc. Int. Conf. IT Convergence and Security*, pp. 1-5, 2016.
- [33] X. Zhai, C. Tin, "Automated ECG classification using dual heartbeat coupling based on convolutional neural network," *IEEE Access*, vol. 6, vol. 2018, pp. 27465-27472, 2018.
- [34] U. R. Acharya, H. Fujita, S. L. Oh, Y. Hagiwara, J. H. Tan, and M. Adam, "Application of deep convolutional neural network for automated detection of myocardial infarction using ECG signals," *Int. Information Sciences*, vol. 415, pp. 190-198, 2017.
- [35] S. Kiranyaz, T. Ince, and M. Gabbouj, "Real-time patient-specific ECG classification by 1-D convolutional neural networks," IEEE Trans. on Biomedical Engineering, vol. 63, no. 3, pp. 664-667, 2016.
- [36] P. Rajpurkar, A. Y. Hannun, M. Haghpanahi, C. Bourn, and A. Y. Ng, "Cardiologist-level arrhythmia detection with convolutional neural networks," *In Proc. Int. Conf. IEEE Computer Vision and Pattern*





Recognition, 2017.

- [37] Y. Xiao, J. Wu, Z. Lin, and X. Zhao, "A deep learning based multi-model ensemble method for cancer prediction," *Int. Journal of Computer Method and Programs in Biomedicine*, vol. 153, pp. 1-9, 2018.
- [38] X. Fan, Q. Yao, Y. Cai, F. Miao, F. Sun, and Y. Li, "Multiscaled fusion of deep convolutional neural networks for screening atrial fibrillation from single lead short ECG recordings," *Int. IEEE Journal of Biomedical and Health Informatics*, vol. 22, no. 6, pp. 1744-1753, 2018.
- [39] W. Liu, F. Wang, Q. Huang, S. Chang, H. Wang, and J. He, "MFB-CBRNN : a hybrid network for MI detection using 12-lead ECGs," In Proc. Int. Conf. IEEE Journal of Biomedical and Health Informatics, pp. 1-11, 2019.
- [40] S. L. Oh, Y. K. Eddie, R. S. Tan and U. R. Acharya, "Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats," *Computers in Biology and Medicine*, 2018.
- [41] G. E. Hinton, R. R. Salakhutdinov, "Reducing the dimensionality of data with neural networks," *Int. Journal of Science*, vol. 313, no. 5786, pp. 504-507, 2006.
- [42] L. Christian, T. Lucas, H. Ferenc, C. Jose, C. Andrew, A. Alejandro,
  A. Andrew, T. Alykhan, T. Johannes, W. Zehan, and S.
  Wenzhe, "Photo-realistic single image super-resolution using a generative adversarial network," *Computer Vision and Pattern*





Recognition, preprint arXiv:1609.04802, 2016.

- [43] K. G. Hartmann, R. T. Schirrmeister, and T. Ball, "EEG-GAN: generative adversarial networks for electroencephalograhic brain signals," preprint arXiv:1806.01875, 2018.
- [44] T. Golany, K. Radinsky, "PGANs : personalized generative adversarial networks for ECG synthesis to improve patient-specific deep ECG classification," 2019.
- [45] S. Haradal, H. Hayashi, and S. Uchida, "Biosignal data augmentation based on generative adversarial networks," In Proc. Int. Conf. IEEE 40th Engineering in Medicine and Biology Society, pp. 368-371, 2018.
- [46] J. H. Kim, S. M. Lee, and K. H. Park, "Stepwise detection of the QRS complex in the ECG signal," *Journal of Korean Institute of Communications and Information Sciences*, vol. 41, no. 02, pp. 244-253, 2016.
- [47] O. Abdeljaber, O. Avci, M. S. Kiranyaz, B. Boashash, H. Sodano, and
  D. J. Inman, "1-D CNNs for structural damage detection: verification on a structural health monitoring benchmark data," *Int. Neurocomputing*, vol. 275, no. 31, pp. 1308-1317, 2018.
- [48] N. Srivastava, G.Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *Int. Journal of Machine Learning Research*, vol. 15, no. 1, pp. 1929–1958, 2014.
- [49] M. G. Kim, S. B. Pan, "Deep learning based on 1-D ensemble networks using ECG for real-time user recognition," *IEEE Trans. on Industrial Informatics*, 2019. (Published online)





- [50] G. Huang, Z. Liu, L. V. D. Maaten, and K. Q. Weinberger, "Densely connected convolutional networks," *In Proc. Int. Conf. IEEE Computer Vision and Pattern Recognition*, pp.4700-4708, 2017.
- [51] T. Apaydin, H. Ferhatosmanoglu, "Access structures for angular similarity queries," IEEE Trans. on Knowledge & Data Engineering, vol. 11, pp. 1512-1525. 2006.
- [52] J. C. Yoo, and T. H. Han, "Fast normalized cross-correlation," Int. Circuits, Systems and Signal Processing, vol. 28, no. 6, pp. 819, 2019.

