



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](#)

2021년 2월

박사학위논문

정규화된 심전도를 이용한 분해능
조정된 2D 스펙트로그램 기반
사용자 인식에 대한 연구

조선대학교 대학원

제어계측공학과

최규호

정규화된 심전도를 이용한 분해능
조정된 2D 스펙트로그램 기반
사용자 인식에 대한 연구

A Study on User Recognition based on Resolution
Adjusted 2D Spectrogram using Normalized ECG

2021년 2월 25일

조선대학교 대학원

제어계측공학과

최규호

정규화된 심전도를 이용한 분해능
조정된 2D 스펙트로그램 기반
사용자 인식에 대한 연구

지도교수

반성범

이 논문을 공학 박사학위신청 논문으로 제출함






2020년 10월

조선대학교 대학원

제어계측공학과

최규호

최규호의 박사학위논문을 인준함

위원장	조선대학교	교수	김윤태	
위원	조선대학교	교수	곽근창	
위원	고려대학교	교수	정용화	
위원	윌리엄패터슨대학교	교수	임기호	
위원	조선대학교	교수	반성범	

2020년 12월

조선대학교 대학원

목차

제1장 서론	1
제1절 연구 배경	1
제2절 연구 목적	4
제3절 연구 내용 및 방법	7
제2장 심전도 신호를 이용한 사용자 인식	9
제1절 사용자 인식 시스템	9
제2절 기존 심전도 정규화 방법	14
1. 정적인 상태에서 심전도를 이용한 정규화	15
2. 동적인 상태에서 심전도를 이용한 정규화	19
제3절 기존 특징 추출 방법	25
제3장 제안한 방법을 이용한 사용자 인식	31
제1절 심전도 신호처리	33
제2절 이상적인 심전도 정규화	37
제3절 분해능 조정된 2D 스펙트로그램 특징 추출을 이용한 사용자 인식 시스템	45
제4장 실험 조건별 성능 분석	52
제1절 실험 방법	52
1. 심전도 DB	52
2. 정규화 및 사용자 인식 평가 방법	55
제2절 정규화된 심전도 유사도 결과 및 분석	58
제3절 분해능 조정된 2D 스펙트로그램을 이용한 사용자 인식	66
제5장 결론	76
참고문헌	78

표 목차

표 1. 정적 상태의 심전도 공개 데이터베이스	10
표 2. 동적 상태의 심전도 공개 데이터베이스	11
표 3. 측정 상태에 따른 심전도 신호처리	12
표 4. 이상적인 심전도의 P, Q, R, S, T파 정점 수식	38
표 5. 취득 상태에 따른 정규화 후 심전도 주기 수 분석	43
표 6. 학습 반복 횟수에 따라 생성한 심전도 주	44
표 7. 원도 이동 변수 조정에 따른 스펙트로그램	47
표 8. CNN 네트워크 구조	51
표 9. 심전도 측정 규약	53
표 10. 복합적 상태에서 취득된 심전도 신호	54
표 11. 유클리디언 거리에 의한 평균 유사도 비율 비교 분석	60
표 12. 마할라노비스 거리에 의한 평균 유사도 비율 비교 분석	62
표 13. 코사인 유사도에 의한 평균 유사도 비율 비교 분석	64
표 14. 분해능 조정 전과 후의 인식 성능 비교	67
표 15. 2D 스펙트로그램을 이용한 사용자 인식 시스템 성능 평가	74

그림 목차

그림 1. 생체정보 및 신호를 이용한 바이오인식	2
그림 2. 심전도 주기의 형태학적 특징과 취득 위치	3
그림 3. 양 손목으로부터 심전도 lead-I 취득	3
그림 4. 정적 및 동적 상태에 따른 심전도 신호	4
그림 5. 심전도를 이용한 사용자 인식 시스템 구조	9
그림 6. 측정 상태 변화에 따른 심전도 측정	11
그림 7. 기준점 분할 정규화 흐름도 예	15
그림 8. 리샘플링 정규화 흐름도 예	16
그림 9. 유사도에 따른 필터 정규화 흐름도 예	18
그림 10. 높은 유사도부터 낮은 유사도의 심전도 신호 예	20
그림 11. 심전도 신호의 CC 정규화 전과 후	20
그림 12. 운동 전과 후 심전도 신호의 주파수 대역	21
그림 13. 심전도 신호의 OBPF 정규화 전과 후	22
그림 14. 심전도 신호의 위상 궤적 정규화 전과 후	23
그림 15. 심전도 신호의 IMF와 파워 스펙트럼	27
그림 16. 심전도의 MFC 변환 흐름도	27
그림 17. 단일 네트워크 구조 예	29
그림 18. 다중 네트워크 구조 예	30
그림 19. 제안하는 정규화된 심전도를 이용한 사용자 인식 시스템	31
그림 20. 잡음이 제거된 심전도 신호	33
그림 21. 심전도 신호의 기저선 추정 과정	35

그림 22. 0점으로 조정된 심전도	36
그림 23. 심전도 정규화 흐름도	37
그림 24. 이상적인 심전도의 주기 생성	39
그림 25. 적응형 유사도 필터 과정	40
그림 26. T_h 에 따라 필터 되는 심전도	41
그림 27. 피형자에 따라 정규화된 심전도	42
그림 28. 피형자마다 심전도 한 주기를 이용한 스펙트로그램 변환	46
그림 29. 2D 리사이즈된 스펙트로그램	48
그림 30. 사용자 인식을 위한 합성곱 신경망	50
그림 31. 정규화 전 각 상태의 유클리디어 거리 유사도	58
그림 32. 각 정규화 방법에 따른 유클리디어 거리 유사도	59
그림 33. 정규화 전 각 상태의 마할라노비스 거리 유사도	60
그림 34. 각 정규화 방법에 따른 마할라노비스 거리 유사도	61
그림 35. 정규화 전 각 상태의 코사인 유사도	63
그림 36. 각 정규화 방법에 따른 코사인 유사도	63
그림 37. TO 변화에 따른 인식 성능	68
그림 38. 주파수 성분 수 변화에 따른 인식 성능	69
그림 39. 영상 크기 조정에 따른 인식 성능 및 학습 경과 시간	69
그림 40. 맥스 풀링 필터 조정에 따른 인식 정확도	70
그림 41. 정규화 전 기존, 제안한 특징을 이용한 인식 성능 비교	71
그림 42. 정규화 후 기존, 제안한 특징을 이용한 인식 성능 비교	72
그림 43. 인식 시스템 성능 비교	73

ABSTRACT

A Study on User Recognition based on Resolution Adjusted 2D Spectrogram using Normalized ECG

Choi, Gyu Ho

Advisor : Prof. Pan, Sung Bum, Ph.D.

Department of Control & Instrumentation

Graduate School of Chosun University

Recently, security technologies that prove personal identity are being upgraded to biometrics systems using bio-signals that are resistant to forgery and alteration. Research-based on user recognition systems using the representative electrocardiogram(ECG) signals are actively underway among bio-signals. To measure and recognize ECG considering the real-life environment, a recognition system using ECG signals acquired in a complex state is required. In order to apply a user recognition system using an ECG in real life, the purpose of this study is to solve the problem with decline recognition performance due to motion artifacts generated when ECG signals are acquired in a dynamic state, low recognition accuracy due to multidimensional features, and high time complexity due to complex networks.

Existing normalization methods do not consider morphological features or are

complicated in the operation process. Existing multidimensional feature extraction methods are designed with low recognition accuracy and complex network structures. In this study, an adaptive similarity filter-based normalization was developed to consider individual morphological features in the preprocessing stage of the recognition system. Besides, a resolution adjusted 2D spectrogram multidimensional features by optimization were utilized as a single convolution neural network(CNN) designed with a low hidden layer structure. Accordingly, the problem with decline recognition performance caused by artifacts was solved with a similarity filter considering individual morphological features. The low recognition accuracy due to the multidimensional features was solved with a resolution-adjusted 2D spectrogram. The problem of high time complexity caused by the complex network was solved with a resized input image and a single network. Therefore, in this study, ECG in static and dynamic states was acquired and built as Chosun University database(CU-DB). This was applied with adaptive similarity filter-based normalization and resolution-adjusted 2D spectrogram. The method proposed in this study consists of a step for removing noise from an ECG signal and a step for analyzing feature data in a user recognition system.

In consideration of real life, the static states for acquiring an ECG in the CU-DB includes sitting, lying down, and sitting after exercise. The dynamic states are phone touch, door opening and closing, and stepper exercise. The performance of the proposed normalization method and multidimensional feature extraction method was compared with existing methods and analyzed using the public databases MIT-BIH normal sinus rhythm(NSR), QT, European, and Arrhythmia. The average similarity rate of the proposed normalization method was analyzed to be 4.18%, 1.36%, 6.81% higher in Euclidian distance than the existing time(cross correlation), frequency (optimized band pass filter), and phase normalization method. In addition, in the Mahalanobis distance, 2.86%, 0.96%, and 2.87% cosine similarity were analyzed to be 4.08%, 1.58%, and 5.99% higher than the existing method. Accordingly, the ECG morphological features of

the static and dynamic states normalized based on the adaptive similarity filter were closer than the existing normalization method, and the recognition performance was improved by an average of 2% compared to before normalization. The problem of low accuracy was solved as the recognition performance using the proposed resolution-adjusted 2D spectrogram was analyzed 2% and 0.4% higher in CU-DB than the existing multidimensional feature extraction methods of ensemble empirical mode decomposition and Mel frequency cepstrum coefficients. Recognition performance using the proposed 2D spectrogram was analyzed as 97.1% in CU-DB, 100% in MIT-BIH NSR DB, 98.1% in QT DB, and 98.7% in European DB. This was analyzed to be 1.4% higher in the maximum European DB and 0.1% in the minimum Arrhythmia DB than the existing single-dimensional, multidimensional, and network methods. Recognition performance using a 2D spectrogram of 1/4 image size was maintained in a single network CNN and the elapsed learning time was shortened by 6 seconds.

In this thesis, a user recognition system-based study was conducted using an ECG acquired in a complex state considering real life. Because it was verified through the ECG DB in a complex state, it is expected that it can be applied using an ECG signal acquired in real life. In the future, I plan to study a biometrics system that will be applied to the driving environment for intelligent vehicles. I also plan to increase the number of training data, optimize networks, and conduct research on lightweight network design to further improve the recognition performance using ECG in deep learning-based networks.

제1장 서론

제1절 연구 배경

최근 4차 산업혁명과 더불어 개인 신분을 증명하는 보안 기술이 진화하고 있다[1]. 기존 지식 및 소유 기반의 물리적인 보안을 넘어 소프트웨어를 활용한 보안으로, 개인의 생체정보를 인식해 간편하고 분실 위험이 없는 바이오인식 보안으로 나아가고 있다[2]. 바이오인식 기술이 적용되었던 초기에는 출입통제(도어락, 출입·근태관리) 영역에서 주로 사용되었지만, 서비스 및 솔루션 인증에 적용되면서 전자 금융(온라인 banking, ATM 현금인출)부터 정보통신(휴대폰 인증, PC·인터넷 로그인), 의료(원격의료, 의료진·환자 신원 확인), 사회복지(미아 찾기, 복지기금관리), 행정(무인 민원발급, 전자조달), 출입국심사(전자여권, 승무원·승객 신원 확인), 엔터테인먼트까지 다양한 영역으로 확대되고 있다[3]. 바이오인식 기술은 개인 고유의 신체적·행동적 특징들을 정보화하여 실시간 분석으로 등록하고 인식하는 기술이다. 신체적 특징은 신체의 외부 정보인 지문, 얼굴, 홍채, 정맥 등이 있으며, 행동적 특징은 신체 외부 신호인 음성, 걸음걸이, 필체, 키보딩, 서명과 신체 내부 신호인 심전도, 근전도, 뇌전도 등이 그림 1처럼 구성된다.

신체 외부 신호들을 이용한 바이오인식은 사용자가 인증할 때 생체정보보다 낮은 인식 성능으로 높은 오류율이 발생하는 문제점이 있다[4]. 생체정보를 이용한 바이오인식 기술은 높은 인식 성능으로 분석되지만 위·변조 사건, 사고에 의해 사회적으로 문제가 제기되어 왔다[5]. 이는 3D프린터로 실리콘 위조 지문을 제작하여 근태관리 악용, 불법 부동산 명의 이전, 스마트 금융 금융사고가 발생했으며 고해상도 사진으로부터 독일 국방부 장관과 러시아 대통령의 지문과 홍채를 복제하여 해킹하는 사고 등이 발생했었다. 이

에 따라 주요 선진국들은 높은 인식 성능과 위·변조에 강한 신체 내부 신호를 이용한 바이오인식 시스템 연구 및 개발 중이다[6][7][8].



그림 1. 생체정보 및 신호를 이용한 바이오인식

신체 내부 신호는 개인마다 다른 고유성(Uniqueness)과 특정 기간 변하지 않는 불변성(Permanence)의 특징으로 신체에서 전위차에 의해 발생하는 생체 신호이다[9]. 생체신호는 기존 생체정보 및 신체 외부 신호와 달리 일상생활에서 취득 장치 및 센서를 신체에 착용하고 부착할 경우 사용자가 무자각 또는 비개입으로 등록된 개인 생체정보를 갱신뿐만 아니라 비대면 인증 방식으로 차세대 바이오인식 기술에 적용되고 있다[10]. 생체신호 중 대표적인 심전도는 심장의 전기 생리학적 요인과 심장의 위치, 크기, 신체적 조건 등에 의해 개인의 고유한 특징을 가지고 있다[11].

심전도 신호는 반 주기성 신호로 심장으로부터 펄스처럼 발생하는 광용적 맥파(PPG, Photoplethysmogram)와 달리 심방의 탈분극에 의해 발생하는 P파, 심실의 탈분극에 의해 발생하는 QRS Complexes, 심실의 재분극에 의해 발생

하는 T파의 형태학적 특징으로 그림 2처럼 구성된다.




그림 2. 심전도 주기의 형태학적 특징




그림 3. 양 손목으로부터 심전도 lead- I 취득

국제 표준유도에 의해 I, II, III 신호, 사지 유도에 의해 aVR, aVL, aVF 신호와 흉부 유도에 의해 V1, V2, V3, V4, V5, V6 신호로 심전도를 각각 취득할 수 있다. 그림 3처럼 심전도의 12 유도 신호 중 피험자로부터 양 손목에서 편리하게 취득할 수 있는 lead-I 신호와 심전도 lead-I의 형태학적 특징들을 이용하여 사용자 인식 연구가 활발히 진행되고 있다[12][13].

제2절 연구 목적

기존 바이오인식에 대한 문제와 범유행(Pandemic)으로 포스트 코로나19를 준비하는 기업들의 비대면 인증 방식에 대한 요구가 증가함에 따라 생체신호를 이용한 보안 시스템의 수요가 증가하고 있다. 비대면 인증이 가능한 심전도 기반 사용자 인식 시스템의 초기 연구는 피험자의 측정 상태 분류와 심장 질환의 종류를 분류하기 위해 보고되어왔다[14][15]. 점진적으로 심전도 상태 및 질환 분류 성능 향상과 사용자 인식 가능성이 확인되면서 피험자 수 증가와 정적인 상태에서 취득하고 단 채널 신호만을 이용한 인식 시스템이 제안되어왔다[16].

일상생활에서도 심전도를 측정하고 인식하기 위해 정적인 상태뿐만 아니라 복합적인 상태에서도 고려해야 한다. 특히, 심전도 신호는 행동적 특징에 의해 발생하는 전기적 신호이기 때문에 외부 환경에 민감하여 잡음이 많이 포함된다. 심전도 신호에 포함되는 대표적인 잡음은 측정 장비 때문에 발생하는 60Hz 전력선 잡음, 피험자 호흡 때문에 발생하는 기저선 변동 잡음, 피험자 움직임에 의해 발생하는 아티팩트(Artifact)가 있다[17].

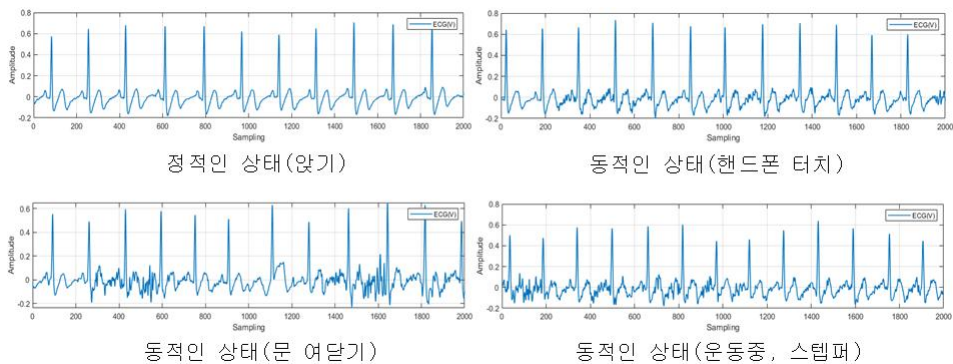


그림 4. 정적 및 동적 상태에 따른 심전도 신호

그림 4는 여러 상태일 때 피험자로부터 측정된 심전도 신호를 보여준다. 피험자의 동적인 상태 변화에 따라 발생하는 아티팩트 잡음은 다른 잡음들보다 심전도 신호에 가장 영향을 많이 주며 포함된다. 피험자의 동적 상태에서 심전도를 취득할 때 부착된 전극 위치에서 근전도 간섭이 발생하고 모션 아티팩트로 심전도 신호에 근전도 신호가 포함된다[18][19]. 정적인 상태에서 측정된 심전도의 형태학적 특징은 뚜렷하게 유지되는 반면, 동적인 상태에서 측정된 심전도의 형태학적 특징은 잡음에 의해 일그러지고 뚜렷하지 않은 신호로 나타난다. 아티팩트 잡음에 의해 형태학적 특징이 뚜렷하지 않은 신호들을 제거하기 위해 복합적 상태에서 측정된 심전도 신호의 전처리 과정이 필요하다. 심전도 신호의 잡음들은 일반적으로 주파수 필터, 웨이블릿 분해, 평균 이동 필터를 이용하여 제거된다. 주파수 필터를 이용한 방법은 0.05Hz 부터 100Hz까지 심전도 신호의 주파수 대역이 분포하기 때문에 심전도 주파수 대역 이외의 영역을 차단한다[20]. 60Hz 전력선 잡음을 고려하여 60Hz 미만으로 주파수 대역을 통과시키며 고역 통과 필터, 저역 통과 필터, 대역 통과 필터 기반 버터워스, 체비쇼프, 노치 필터 등을 이용한다[21]. 웨이블릿 분해는 심전도 신호를 웨이블릿 변환함수에 의해 변환 후 압축 단계마다 나누어지고 잡음 요소는 나누어진 단계에서 잡음 요소 계수들을 제외하여 잡음을 제거한다[22]. 평균 이동 필터는 심전도 신호에 미세하게 존재하는 잡음을 제거하기 위해 형태학적 특징 구간들을 제외한 영역에서 전위차들의 변화를 평균값으로 연산한다[23].

이와 같은 방법으로 심전도의 잡음을 제거하고 있지만, 정적인 상태만을 고려하여 전처리가 진행되는 단점이 있다. 위 방법으로 복합적 상태의 심전도 신호처리를 진행할 경우, 형태학적 특징들이 일정하게 정규화된 값들로 분포되지 않거나 필터를 높게 설정하면 심전도의 형태학적 특징들이 왜곡되

는 문제가 있다. 왜곡된 심전도의 형태학적 특징들을 이용할 경우, 사용자 인식 성능을 저하하는 문제가 발생한다.

이처럼 심전도의 왜곡된 형태학적 특징은 사용자 인식률을 저하하는 요인 때문에 일정한 형태학적 특징값들로 정규화되는 전처리가 중요하다. 정적인 상태 이외의 상태에서 정규화를 위한 연구가 진행되고 있지만, 단일 상태만을 고려하여 연구가 진행되고 있다. 즉, 일상생활에서 심전도를 이용한 사용자 인식을 위해 복합적 상태에서 취득된 심전도의 형태학적 특징들이 일정하게 정규화되는 전처리 연구가 필요하다.

제3절 연구 내용 및 방법

심전도를 이용한 사용자 인식 시스템은 크게 심전도 신호의 전처리 단계와 인식 단계로 나눌 수 있다. 전처리 단계는 심전도 신호의 잡음 제거와 형태학적 특징 기반 정규화를 고려하여 인식을 위한 심전도 데이터를 생성하는 과정이다. 일반적인 잡음 제거 방법은 정적인 상태의 심전도 신호에만 적용되어왔으며, 복합적인 상태의 심전도 신호에 적용되어도 잡음이 제거되지 않는다. 다양한 상태를 고려하여 심전도 신호의 형태학적 특징 기반 정규화 단계가 하나의 독립적인 연구 분야로 다루어지고 있지만, 아직 초기 연구 단계로 단일 상태만을 고려하여 정규화가 진행되는 중이다. 인식 단계는 심전도 신호의 형태학적 특징으로부터 인식을 위한 특징 데이터 추출 과정과 최종 클래스 분류 과정으로 구성된다. 높은 인식 성능을 위해 특징 데이터 추출과 클래스 분류 과정이 연구되는 중이며 다차원 영역에서의 특징 추출과 딥러닝의 네트워크층에 의한 학습 과정으로 인식 시스템이 연구되어왔다. 최근까지 딥러닝에 의해 특징 추출 단계와 클래스 분류 단계가 하나의 과정으로 진행되고 인식 성능을 향상하기 위해 네트워크층과 학습 과정의 파라미터에 의존되어왔다. 이는 심전도 신호의 특징 데이터를 고려하지 않고 정적인 상태에서 고려된 맞춤형 딥러닝의 네트워크 구조이다. 또한, 성능 향상을 위해 단일 네트워크의 복잡한 다층 구조, 다중 네트워크에 의한 많은 연산이 요구되는 구조로 구성된다.

본 논문에서는 전처리 단계에서 정적인 상태뿐만 아니라 복합적 상태에서 정규화하는 방법과 인식 단계에서 심전도 신호의 맞춤형 다차원 특징 데이터 추출 방법을 제안한다. 정규화 방법은 심전도 신호의 연속성 특징을 고려하여 개인 심전도의 적응형 임계 값에 의해 이상적인 심전도 주기들로 정규화

한다. 이는 형태학적 특징들이 일그러진 동적 상태의 심전도 주기들은 제안한 방법을 이용하여 정적인 상태에서 취득된 심전도 신호의 형태학적 특징처럼 정규화된다. 다차원 특징 데이터 추출 방법은 심전도의 시간-주파수 분해능 조정으로 정규화된 2D 스펙트로그램 영상 데이터를 추출한다. 심전도 신호로부터 정규화된 다차원 특징 데이터를 이용하여 딥러닝의 낮은 층으로 구성된 단일 네트워크층에서 높은 성능으로 사용자가 인식된다.

본 논문의 구성은 다음과 같다. 1장의 서론에 이어 2장에서는 기존 심전도를 이용한 정규화 방법과 특징 추출 방법을 소개한다. 3장에서는 본 논문에서 제안하는 정규화 방법과 2D 스펙트로그램 특징 추출 방법에 대해 세부적으로 설명한다. 4장에서는 정규화 및 다차원 특징 추출을 이용한 사용자 인식 성능 결과를 분석하고 5장에서 본 논문의 결론과 향후 연구 방향을 제시한다.

제2장 심전도 신호를 이용한 사용자 인식

제1절 사용자 인식 시스템

사용자 인식 시스템은 등록과정과 인식 과정으로 구성된다. 인식 시스템에서 등록과 인식 과정은 심전도 신호 취득 과정, 신호처리 과정, 데이터 분석 과정 단계까지 같고 이후 등록 데이터는 머신러닝에 의해 학습되고 인식 데이터는 학습된 모델과 정합되어 최종 클래스로 그림 5처럼 분류된다.

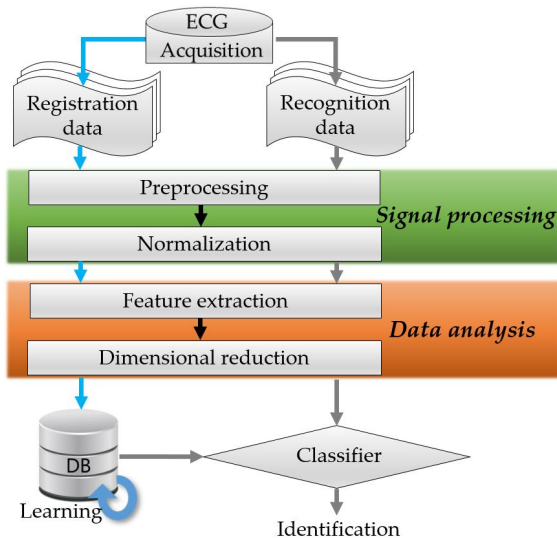


그림 5. 심전도를 이용한 사용자 인식 시스템 구조

심전도를 이용한 사용자 인식 시스템의 초기 연구는 공개 데이터베이스를 이용하여 인식 성능을 높이기 위해 진행되어왔다. 일반적으로 사용자 인식을 위해 사용되는 심전도 신호는 공개 데이터베이스인 Physionet에서 다양하게 분류된 심전도 데이터베이스이다. Physionet 데이터베이스는 1999년

NIH(National Institutes of Health, USA)의 후원으로 생리 및 임상 데이터를 공개함으로써 생물 의학 연구 및 교육 목적으로 구축되었다. 이후 심전도의 부정맥을 진단하기 위해 연구가 많이 수행되었고 2001년 바이오인식 분야에서 사용자 인식에 대해 가능성이 확인되어 많은 연구가 시작되었다. 사용자 인식을 위해 Physionet에서 주로 사용되는 데이터베이스는 표 1과 같다.

표 1. 정적 상태의 심전도 공개 데이터베이스

데이터베이스	피험자 수	설명
MIT-BIH NSR(Normal Sinus Rhythm)	18	<ul style="list-style-type: none"> - 미국 보스턴의 베스 이스라엘 병원의 부정맥 연구소에서 공개 - 20~50세의 18명(남성 5명, 여성 13명) 심전도 신호 Lead-I, II 데이터
QT	105	<ul style="list-style-type: none"> - 다양한 데이터베이스들을 혼합시켜서 구성(MIT-BIH DB 5개, 그 외 2개) - 15분 동안 심전도 신호 데이터의 특징 점들을 세부적으로 표시
European ST-T	79	<ul style="list-style-type: none"> - ST 및 T파 변화 분석 알고리즘 평가에 사용하기 위한 데이터 - 30~84세 사이의 남성 70명과 55~71세 사이의 8명 여성의 심전도 신호를 취득
Long Term ST	80	<ul style="list-style-type: none"> - 심근 허혈성 구별을 위한 ST세그먼트 변화에 따른 심전도 신호 데이터 - 21~24시간 동안의 심전도 신호 2~3개 리드

공개 데이터베이스의 심전도 데이터는 의료 장비로부터 심장질환의 신호뿐만 아니라 심장이 건강한 적은 수의 피험자들로부터 심전도 신호를 취득하고 구축되었다. 공개 데이터베이스의 심전도는 진단을 목적으로 임상을 위해 측정되어 실생활에 적용하기 위한 사용자 인식을 위해 재현성이 낮아 일상생활을

고려한 환경에서 심전도를 취득해야 한다. 일상생활을 고려한 동적 상태의 공개 데이터베이스는 표 2처럼 취득한 피험자 수가 낮고 같은 상태에서 심전도 신호를 취득하지 않았다. 동적 상태의 심전도를 연구하는 기관에서 자체 취득했으나 비공개로 되어있다.

표 2. 동적 상태의 심전도 공개 데이터베이스

데이터베이스	피험자 수	설명
Wrist PPG During Exercise	8	- 피험자마다 동일하지 않는 상태에서 PPG, 흉부 ECG 취득 - ex) 1번 피험자: 걷기, 2번 피험자 달리기, 3번 피험자 자전거 타기
Motion Artifact Contaminated ECG	1	- 25세 한 명의 남성으로부터 1회 8초씩 취득(흉부유도 V1~4) - 전극 각도: 0도(3회), 45도(3회), 90도(3회) - 상태 변화: 일어서기, 걷기, 점프

최근 사용자 인식 연구가 실생활에서 적용되기 위해 휴대용이 쉬운(Portable) 측정 장비와 사용자의 다양한 상태에서 심전도를 측정할 수 있는 환경이 그림 6처럼 정의되고 있다.




그림 6. 측정 상태 변화에 따른 심전도 측정

표 3. 측정 상태에 따른 심전도 신호처리

저자	측정 상태	신호처리	인식 성능
Zhao et al. [31]	정적인 상태	<ul style="list-style-type: none"> • High pass filter • Wavelet • Resample 	95.56%
Shen et al. [32]	정적인 상태	<ul style="list-style-type: none"> • Band pass filter 	95.3%
Choi et al. [29]	정적인 상태	<ul style="list-style-type: none"> • High pass filter • Low pass filter 	98%
Belgacem et al. [33]	정적인 상태	<ul style="list-style-type: none"> • Wavelet 	100%
Chun et al. [34]	정적인 상태	<ul style="list-style-type: none"> • Band pass filter 	97%
Komeili et al. [35]	운동 전과 후	<ul style="list-style-type: none"> • Band pass filter 	88%
Sung et al. [30]	운동 전과 후	<ul style="list-style-type: none"> • Band pass filter 	87.16%
Nobunaga et al. [36]	운동 전과 후	<ul style="list-style-type: none"> • Optimised band pass filter 	100%
Lin et al. [37]	운동 중	<ul style="list-style-type: none"> • - 	81.73%
Kang et al. [27]	천천히 걸기	<ul style="list-style-type: none"> • Band pass filter • Wavelet • Cross correlation 	96%

캐나다의 토론토대학교는 Vernier 社の 측정 센서를 이용하여 1,012명의 정적인 상태에서 심전도를 측정했으며 그중 71명은 앉기, 서기, 눕기, 구부리기, 운동 후 등의 상태를 변경하며 추가로 측정하고 데이터베이스로 구축했다 [24]. 캐나다의 오타와대학교는 AliveCore 社の 모바일 센서를 이용하여 73명의 정적인 상태에서 심전도를 측정하고 데이터베이스로 구축했다[25]. 일본의 도요타는 BioPac 社の 측정 센서를 이용하여 10명에 대해 운동 전과 후 상태에서 심전도를 측정했으며, 중국의 텐진대학교는 개발한 측정 센서를 이

용하여 13명에 대해 상태 변화에 따라 심전도를 측정했다[26]. LG전자는 ARM Cortex-M 기반으로 시계 타입의 측정 센서를 개발하고 28명이 차분한 상태에서 앉아 있거나 천천히 걸을 때 심전도를 측정했다[27]. 울산과학기술원은 Nymi 社의 시계 타입 측정 센서를 이용하여 15명의 정적인 상태에서 심전도를 측정했다[28]. 서울대학교는 NeuroSky 社의 모바일 센서를 이용하여 175명이 정적인 상태에서 심전도를 측정하고, BioPac 社의 측정 센서를 이용하여 55명이 운동 전과 후 상태에서 심전도를 측정했다[29][30]. 이처럼 심전도 신호는 전기적 신호로 행동적 특징에 의해 발생하기 때문에 실생활에서 사용자 인식 시스템에 적용되기 위해 다양한 상태를 고려하여 측정해야 한다.

다양한 상태에서 측정한 심전도 신호는 외부 환경에 민감하여 측정자 움직임에 의해 아티팩트가 심하게 발생하기 때문에 외부 환경에 대응하는 적응형 신호처리 기술이 필요하다. 현재까지 심전도 신호처리 기술들은 정적인 상태에서 측정된 심전도를 주로 고려하여 표 3처럼 연구되었다. 정적인 상태에서 적용된 전처리 기술들은 동적인 상태의 심전도 신호를 고려하지 않고 적용하여 연구되었다. 정적인 상태의 일반적인 인식 성능은 95~100%로 분석되며, 동적인 상태의 인식 성능은 정적인 상태보다 낮은 81~88%로 분석되었다. 동적인 상태에서 측정한 심전도의 사용자 인식 성능은 정적인 상태의 인식 성능보다 대체로 10% 이상 낮게 분석된다. 이와 반면에, 운동 상태에서 정규화 기술이 적용된 인식 성능은 정적인 상태의 인식 성능과 일정하게 유사했다. 이는 인식 성능을 비교 분석하면, 심전도의 측정 상태를 고려하여 맞춤형 전처리 기술이 필요함을 확인할 수 있다. 동적인 상태에서 인식 성능을 향상하기 위해 심전도 신호에 포함된 아티팩트를 제거할 수 있는 정규화 중심의 신호처리 연구가 필요하다.

제2절 기존 심전도 정규화 방법

본 절에서는 각 측정 상태에 따라 심전도 신호에 적용되는 정규화 방법들을 소개하고 차원 영역에 따른 정규화 방법을 설명한다. 정규화는 심전도의 형태학적 특징들을 더욱 일치시키고 인식 성능을 향상하기 때문에 동적인 상태뿐만 아니라 정적인 상태의 심전도에도 적용되어 연구되는 중이다. 심전도의 형태학적 특징들은 측정 상태에 따라 왜곡되는 정도가 달라지기 때문에 적용되는 정규화 방법들이 다양하게 연구되고 있다. 정적인 상태의 심전도는 형태학적 특징들이 뚜렷하고 반주기 신호로 발생하기 때문에 시간 영역을 고려한 정규화 방법들이 연구되고 있다. 동적인 상태의 심전도는 형태학적 특징들이 왜곡되고 일정하게 분포되지 않기 때문에 시간 영역뿐만 아니라 주파수 영역, 위상영역을 고려한 정규화 방법들이 연구되고 있다[27][36][37].

이처럼 정규화가 적용되는 각 차원 영역들은 시간 영역, 주파수 영역, 위상영역 등으로 나눌 수 있다. 시간 영역에서 적용되는 정규화는 심전도의 형태학적 특징들을 이용하여 기준점 기반 영역 분할 방법, 한 주기의 데이터를 리샘플링 방법, 유사도 비율에 따라 일치되는 특징 데이터 필터 방법으로 진행된다. 주파수 영역에서 적용되는 정규화는 최적화된 주파수 대역을 찾고 상태에 따라 같은 주파수 대역으로 일치시켜주는 방법으로 진행된다. 위상영역에서 적용되는 정규화는 위상 차원으로 변환하고 지연되는 파라미터로 조정하여 일치시켜주는 방법으로 진행된다. 본 논문에서는 각 상태에서 적용되는 기존 정규화 방법을 설명한다.

1. 정적인 상태에서 심전도를 이용한 정규화

정적인 상태의 심전도 신호는 형태학적 특징들이 일정하게 분포되어 측정되지만, 피험자 수 증가에 따라 형태학적 특징들이 겹치게 되어 인식 성능이 저하되는 문제점이 있다. 이를 해결하기 위해 형태학적 특징들을 더욱 일치시키고 정규화하는 방법들이 연구되고 있다. 심전도의 한 주기 신호를 시간 영역에서 기준점 기반 분할 방법, 리샘플링 방법, 유사도에 따른 필터 방법으로 구분된다.




그림 7. 기준점 분할 정규화 흐름도 예

그림 7은 심전도 신호의 한 주기를 일정한 영역으로 기준점 기반 분할한 흐름도이다. 기준점 분할 정규화는 심전도를 취득 후 잡음 제거된 신호에서 R파 정점 기준으로 좌측 영역의 P파 구간과 우측 영역의 T파 구간까지 일정하게 분할하여, 한 주기의 형태학적 특징들을 일정하게 일치시키는 일반적인 방법이다[29]. 정규화된 한 주기에서 형태학적 특징들이 추출되고 데이터 분석 단계로 진행된다. 기준점 분할 정규화는 R파 정점 중심으로 일정하게 분할하기 때문에 QRS Complexes 구간을 제외한 P, T파 구간들이 불일치하게

나타나는 문제점이 있다. 한 주기가 분할되고 P, T파 구간을 일치시키기 위한 정규화 방법이 필요하다. 이러한 문제를 해결하기 위해 리샘플링 정규화 방법이 그림 8처럼 제안되었다[30].

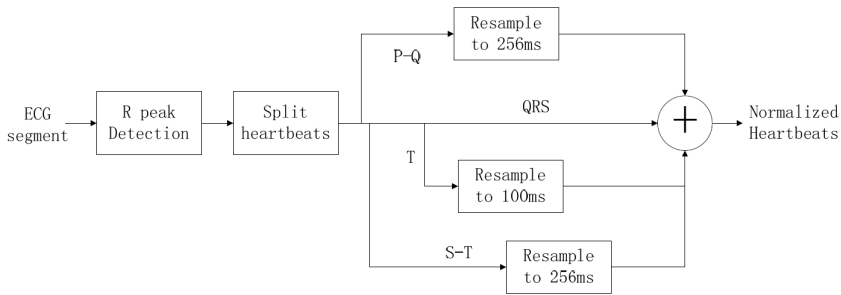


그림 8. 리샘플링 정규화 흐름도 예

분할된 한주기를 이용하여 R파 정점이 검출되고 한 주기에서 형태학적 특징 구간들이 영역마다 분해된다. 분해된 각 영역은 PQ segment, QRS Complexes, ST segment, T파로 식(1), (2), (3), (4)에 의해 결정된다.

$$PQ(i) = S[p(i) - 2.24 \times fs + dt : p(i) - 0.06 \times fs] \quad (1)$$

$$QRS(i) = S[p(i) - 0.06 \times fs : p(i) + 0.1 \times fs] \quad (2)$$

$$ST(i) = S[s(i) : s(i) + 0.08 \times RR] \quad (3)$$

$$T(i) = S[s(i) + 0.08 \times RR : s(i) + 0.4 \times RR] \quad (4)$$

i 는 데이터 수, $p(i)$ 는 R파 정점 위치, fs 는 샘플링 레이트, dt 는 시간의 변화

량, RR 은 R파 정점 사이의 시차이다. dt 는 심박수 HR (Heart Rate)이 bpm(beat per minute) 범위에 따라 식 (5)에 의해 결정된다.

$$dt = \begin{cases} -10 \text{ ms} & HR < 65 \text{ bpm} \\ +0 \text{ ms} & 65 \text{ bpm} < HR < 80 \text{ bpm} \\ +10 \text{ ms} & 80 \text{ bpm} < HR < 95 \text{ bpm} \\ +20 \text{ ms} & HR > 95 \text{ bpm} \end{cases} \quad (5)$$

QRS Complexes 구간은 개인 고유한 특징들로 구성되기 때문에 QRS Complexes 구간을 제외한 나머지 구간들은 정규화된 샘플 데이터로 리샘플링된다. 리샘플링된 각 구간과 QRS Complexes 구간은 결합으로 정규화된다. 리샘플링 정규화 방법은 분할 정규화 방법보다 형태학적 특징들이 일정하게 일치되는 장점이 있지만, bpm을 고려하기 때문에 1분 이상의 심전도 신호가 분석되는 단점이 있다. 이는 정규화를 위해 일상생활에서 최소 1분 이상의 심전도 신호 데이터가 요구되기 때문에 실시간으로 심전도 신호가 정규화되는 연구가 필요하다.

실시간으로 심전도 신호가 정규화되기 위해 유사도에 따른 필터 방법이 그림 9처럼 제안되었다[25]. 정규화를 위해 심전도의 한 주기가 R파 정점을 통해 분할되면 R파 정점과 P파의 골(Valley)에 의해 교정된다. 교정된 심전도의 한 주기에서 각 형태학적 특징들이 유사도를 위해 분해된다. 분해된 형태학적 특징들은 RLP(R peak to Left P wave), RP(R peak to P peak), RQ(R peak to Q peak), RS(R peak to S peak), RT(R peak to T peak), RSA(R peak to S peak Amplitude), RQA(R peak to Q peak Amplitude)들로 구성된다. RLP 특징부터 순서대로 RQA 특징까지 등록 데이터와 인식 데이터가 정합되고 유사도에 의해 일치되면 카운트되어 인식되며 유사하지 않으면 인식되지 않는다. 카운트된 특징들은 등록 데이터와 일치되기 때문에 정합될 경

우, 인식 성능이 높게 분석되는 장점이 있지만, 카운트될 때까지 경우의 수가 많아서 정합이 되기 전에 제외되는 심전도 주기들이 증가하는 단점이 있다.

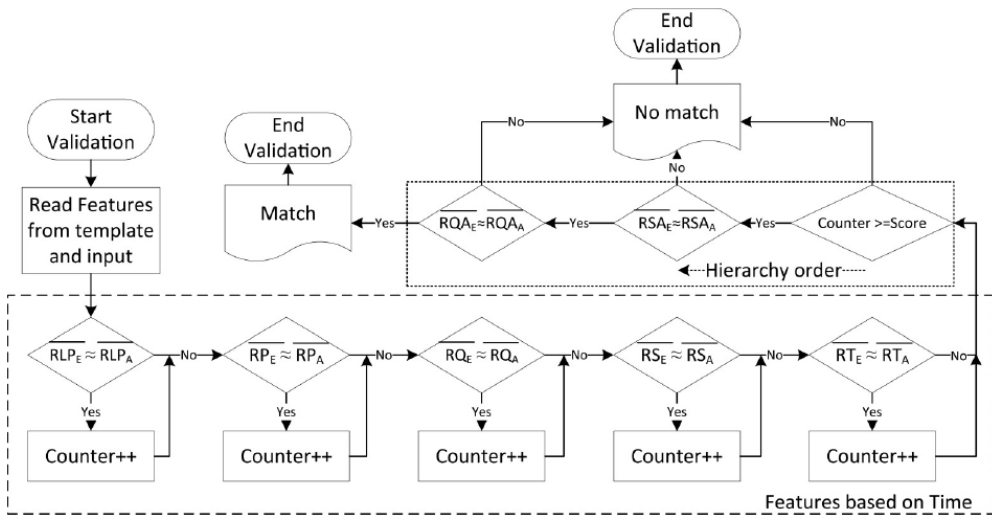


그림 9. 유사도에 따른 필터 정규화 흐름도 예

또한, 필터 정규화 방법은 인식 데이터에만 고려되었으며 등록 데이터에 대한 기준이 없다. 만약에 등록 데이터가 형태학적 특징이 뚜렷하지 않고 잡음이 많이 포함된 심전도 주기들로 구성되어 있다면 인식 데이터는 등록 데이터와 같은 잡음이 포함된 심전도 주기들로 필터 된다. 즉, 등록 데이터가 형태학적 특징이 뚜렷하지 않으면 인식할 수 없다. 이처럼 필터 정규화 방법은 등록 데이터의 특징과 같은 인식 데이터로 필터할 수 있는 장점이기 때문에 등록 데이터에 대한 기준과 적은 경우의 수로 정규화되는 방법이 연구되면 보완할 수 있다.

2. 동적인 상태에서 심전도를 이용한 정규화

동적인 상태의 심전도 신호는 피험자의 움직임으로 높은 아티팩트 발생 때문에 형태학적 특징들이 뚜렷하지 않거나 잡음이 심한 신호로 측정되어 인식 성능이 저하되는 문제점이 있다. 동적인 심전도 신호는 정적인 상태의 인식 성능보다 낮게 분석되기 때문에 동적인 상태를 정의하고 요구되는 정규화 기술이 적용된다. 일상생활에서 동적인 상태를 고려하기 위해 정의되고 있는 상태는 천천히 걷기, 운동 중, 운동 후 상태이다. 이러한 상태에서 측정된 신호를 정규화하기 위해 적용되는 방법들은 시간 영역, 주파수 영역, 위상영역에서 각각 연구되는 중이다. 시간 영역의 정규화 방법은 심전도 신호가 연속적으로 측정될 수 있는 특징을 반영하여 등록된 신호와 유사하지 않으면 필터 하는 CC(Cross Correlation) 알고리즘이다[27]. CC 기반 정규화 방법은 등록된 심전도 신호의 $x(t)$ 와 인식을 위한 심전도 신호 $y(t)$ 와의 유사성을 연산하고 최댓값 1과 근사하면 $y(t)$ 데이터를 인식 데이터로 사용한다. $x(t)$ 로부터 $y(t)$ 의 CC 유사도 측정은 식(6)으로 결정된다.

$$R_{xy}(\tau) = \int_{-\infty}^{\infty} x(t)y(t+\tau)dt \quad (6)$$

$y(t)$ 가 일정한 시간 t 로부터 τ 만큼 이동됨에 따라 $x(t)$ 와 연산한 값들의 총합으로 유사도 R이 산출된다. R 값이 최대 1부터 최소 -1까지 산출되어 그림 9에서 $x(t)$, $y(t)$ 신호가 유사성이 높은 순서대로 (a)부터 (d)까지 확인할 수 있다. 그림 10에서 파란 신호는 등록된 심전도 신호이며 빨간 그래프는 CC 연산을 위한 $y(t)$ 신호이다. 등록된 심전도 신호로부터 정규화된 인식 데이터는 그림 10의 (a)처럼 $x(t)$ 와 유사한 $y(t)$ 심전도 신호이고, 인식을 위해 데

이터로 사용된다. 그림 10의 (a)와 같은 인식 데이터로 정규화된 심전도는 그림 11의 (a)에서 (b)로 변환되어 형태학적 특징들이 일정하게 일치된다.





그림 10. 높은 유사도부터 낮은 유사도의 심전도 신호 예



(a) 정규화 전

(b) 정규화 후

그림 11. 심전도 신호의 CC 정규화 전과 후

CC 기반 정규화 방법은 등록된 심전도 신호와 같은 형태학적 특징으로 인식 데이터를 구성할 수 있는 장점이 있지만, 등록을 위한 심전도 신호의 기준이 없어 연속적으로 등록 데이터를 선정하고 인식 데이터를 정규화하는 반복연산이 진행된다. 이는 등록 데이터를 위한 심전도 신호에 대해 기준을 설정하고 인식 데이터가 정규화되는 연구가 필요하다. 또한, 형태학적 특징들이 뚜렷하지 않은 심전도 신호로 등록될 경우 인식 데이터가 잡음이 포함된 심전도 신호로 정규화될 수 있는 단점이 있다. 이러한 문제를 해결하기 위해 등록 데이터 기준 없이 정규화되는 방법으로 주파수 영역에서 OBPF(Optimized Band Pass Filter) 기술이 제안되었다[36]. 제안된 방법은 운동 후 상태의 심전도를 운동 전 형태학적 특징과 일치시켜 정규화하는 기술이다.

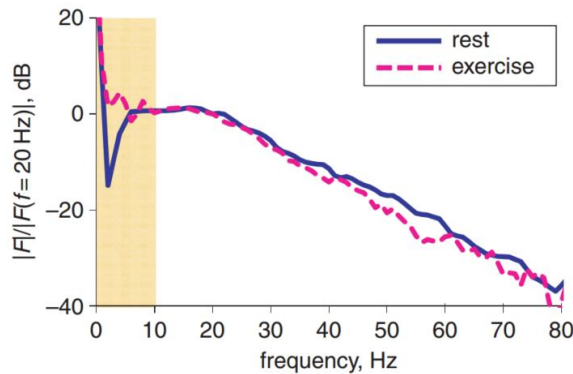


그림 12. 운동 전과 후 심전도 신호의 주파수 대역

OBPF 정규화 기술로 운동 전과 후 심전도 신호는 FFT(Fast Fourier Transform)에 의해 주파수로 변환되고 주파수 대역을 분석하여 일정하게 분포되어 최적화된 같은 대역으로 필터 된다. 운동 전과 후 상태에서 심전도 신호의 최적화된 대역은 그림 12과 같이 10Hz 이후부터 80Hz까지이고, 이외

의 주파수 대역은 차단된다. 10Hz 이하 주파수 대역에 분포하는 심전도 신호는 운동 상태에 의해 아티팩트 영향을 받는 구간으로 분석할 수 있다. 따라서 최적화된 주파수 대역으로 필터된 심전도는 그림 13(a)에서 (b)처럼 정규화된다. OBPF 정규화 방법은 등록된 심전도 신호와 상관관계로 분석하는 단계 없이 정규화할 수 있는 장점이 있지만, 심전도 신호의 형태학적 특징들이 뚜렷한 파형 여부가 확인될 수 없는 단점이 있다.

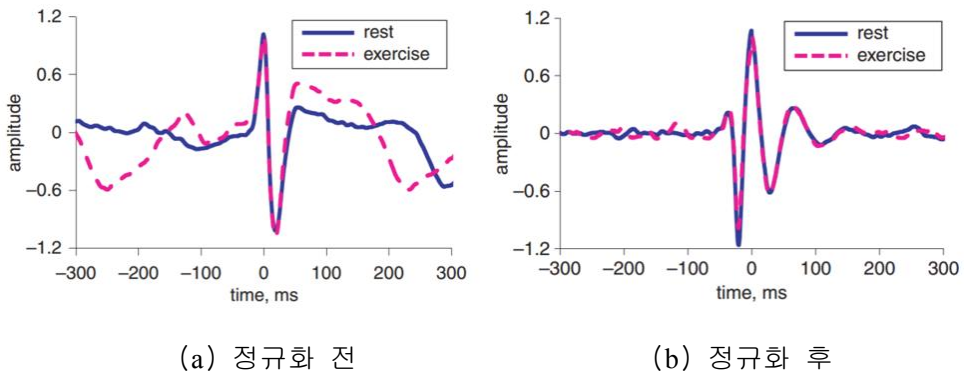


그림 13. 심전도 신호의 OBPF 정규화 전과 후

이는 OBPF에 의해 정규화가 되어도 잡음이 심한 심전도 신호일 경우, 인식을 위해 추출된 특징들이 등록된 특징 데이터와 일치되지 않고 인식 성능을 감소시키는 문제가 발생한다. 정규화되기 전 심전도 신호의 형태학적 특징들을 분석하는 단계가 추가되면 OBPF 정규화 방법이 보완될 수 있다. OBPF 정규화 방법은 개인 고유의 형태학적 특징을 고려하지 않고 주파수 대역만 고려하여 진행하기 때문에 형태학적 특징들이 일치되지 않을 수 있다. OBPF 정규화 전 개인 고유의 형태학적 특징을 기준으로 취득된 심전도 신호와 유사도 분석을 통해 일치되는 신호들을 이용하여 정규화가 진행된다면 인식 성능의 저하 문제를 해결할 수 있다.

위상영역의 정규화는 운동 중일 때 측정된 심전도를 이용하여 위상 궤적으로 변환하는 방법으로 제안되었다[37]. 위상 궤적 정규화 방법은 심전도 신호의 주기성 특징으로 카오스 이론에 적용될 수 있는 동역학적 시스템이기 때문에 위상 궤적에서 수렴되고, 심전도 신호의 형태학적 특징들이 위상영역에서 일정하게 일치된다. 위상 궤적으로 변환된 심전도 신호는 그림 14(a)에서 (b)처럼 정규화된다. 위상영역으로 변환되기 위해 심전도 신호는 $x(t)$ 와 τ 만큼 지연되는 $x(t+\tau)$ 신호를 이용하여 위상 궤적으로 변환된다. 위상 궤적 정규화 방법은 심전도의 형태학적 특징들이 일정하게 일치되는 장점이 있지만, 인식을 위해 분류할 경우 다른 클래스와 데이터 중첩되는 문제로 인식 성능이 낮게 분석되는 단점이 있다.

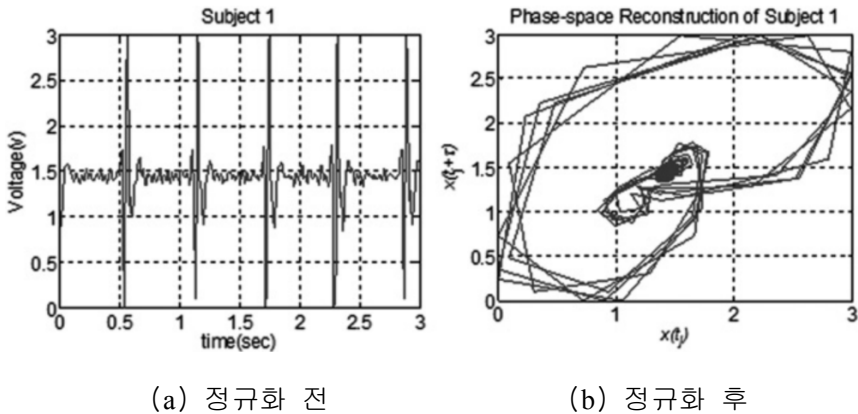


그림 14. 심전도 신호의 위상 궤적 정규화 전과 후

위상영역에서 고유한 특징들이 외적 클래스의 데이터와 차별될 수 있는 위상 궤적 정규화 방법의 추가 연구가 필요하다.

현재까지 정적, 동적인 상태에서 측정된 심전도 신호를 정규화하기 위해 각각 진행되었지만, 개인 고유의 형태학적 특징을 고려하지 않고 아티팩트

잡음을 제거하기 위해 보완하는 전처리 연구가 필요하다. 또한, 일상생활 환경을 고려하여 다양한 상태에서 측정될 수 있는 상태가 정의되고 취득한 심전도 신호의 정규화를 위해 새로운 방법이 요구된다. 그러므로 본 논문에서는 기존 정규화 기술의 문제점을 보완하고 실제 환경에서 정의될 수 있는 복합적 상태에서 취득한 심전도 신호에 적용 가능한 정규화 방법을 제안한다.

제3절 기존 특징 추출 방법

심전도를 이용한 사용자 인식에 사용되는 특징 데이터 추출 방법들은 인식 성능에 영향을 주는 요인이며, 성능 향상을 위해 연구되었다[38][39][40]. 심전도의 한 주기의 형태학적 특징들을 이용한 단 차원으로 추출하는 방법, 차원 변환에 의한 다차원으로 추출하는 방법, 딥러닝에 의한 방법으로 각각 연구되는 중이다. 단 차원에서 특징 추출하는 방법은 주로 심전도의 한 주기에서 진행된다. Choi et al. [29]는 심전도의 한 주기의 정점들 사이에서 PQ, QS, ST 구간들과 P, Q, R, S, T 진폭들을 특징으로 추출했다. 추출된 특징들을 이용하여 175명에 대한 인식 성능이 SVM(Support Vector Machine)에 의해 95.9%로 분석되었다. Shen et al. [32]는 심전도의 한 주기에서 RQ, RS, RS2, PQ, QS, RP, RT, TS 정점들의 진폭, QS, QT의 지속구간, QRS Complexes 넓이, RS, ST의 기울기와 Q, R, S의 y축과의 각도들을 특징으로 추출했다. 추출된 특징들을 이용하여 49명에 대한 인식 성능이 유클리디언 거리에 의해 98%로 분석되었다. Nobunaga et al. [36]은 심전도의 한 주기에서 정점들의 P, Q, S, T파의 진폭, 시간과 한 주기의 파형이 영점과 교차하는 구간의 시간을 특징들로 추출했다. 추출한 특징들을 이용하여 10명에 대한 인식 성능이 KNN(k-Nearest Neighbors)에 의해 100%로 분석되었다. 단 차원의 특징 추출 방법은 낮은 피험자 수에서 높은 인식 성능으로 분석되지만, 피험자 수가 증가할수록 낮은 인식 성능으로 분석되는 단점이 있다. 이러한 문제를 해결하기 위해 $M \times N$ 행렬로 추출하고 단 차원보다 많은 특징 데이터로 높은 인식 성능으로 분석할 수 있는 다차원 특징 추출 기술들이 제안되었다.

Zhao et al. [31]은 주파수 대역마다 심전도 신호를 변환하고 특징 추출할 수 있는 EEMD(Ensemble Empirical Mode Decomposition) 방법을 제안했다.

EEMD는 심전도 신호에 인위적인 잡음을 추가하고, 앙상블 평균을 통해 마지막에 인위적인 잡음을 제거하는 방법이다. 정규분포를 따르는 백색 잡음 $w(t)$ 를 분석하기 위해 심전도의 신호 $r(t)$ 에 더하여 $x(t)$ 가 식(7)에 의해 결정된다.

$$x(t) = r(t) + w(t) \quad (7)$$

백색 잡음이 포함된 심전도 신호에서 국소 최대 및 최소값을 찾고, 3차 스플라인 보간법을 이용하여 상위 및 하위 막을 생성한다. 생성한 상위 막과 하위 막의 평균 $m(t)$ 를 산출하여 $x(t)$ 와 함께 의해 고유 방식 함수 IMF(Intrinsic Mode Function) $h(t)$ 가 식(8)처럼 결정된다.

$$h(t) = x(t) + m(t) \quad (8)$$

산출된 $h(t)$ 에서 상위 막과 하위 막의 평균 0에 가까워질 때까지 반복 수행하여 $c(t)$ 를 산출하고, 백색 잡음이 합산된 심전도 신호 $x(t)$ 와 $c(t)$ 의 차이를 산출하여 $r_1(t)$ 를 얻을 수 있다. 이러한 과정을 n 번 반복하여 n 개의 IMF 신호를 생성할 수 있다. 4개의 IMF와 파워 스펙트럼 변환으로 8개의 신호에서 각각 그림 15처럼 특징들이 추출되었다. 추출한 특징들을 이용하여 10명에 대한 인식 성능이 KNN에 의해 PTB 데이터베이스에서 96%, Long-Term ST 데이터베이스에서 95.75%로 분석되었고, 데이터베이스를 모두 사용할 경우 95.56%로 단일 데이터베이스의 성능과 유사하게 분석되었다. 이는 피험자 수가 증가하여도 다차원 특징 추출을 이용하여 인식 성능이 유지 되었다.

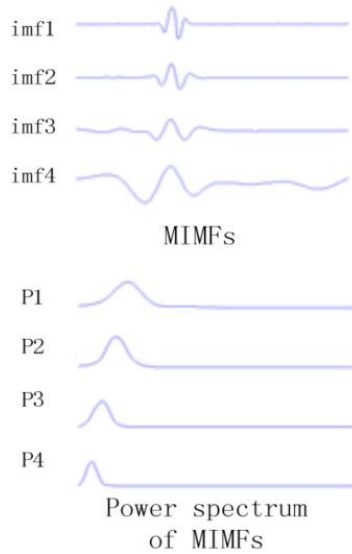


그림 15. 심전도 신호의 IMF와 파워 스펙트럼

Chen et al. [41]은 Mel 주파수 대역마다 존재하는 신호들을 DCT에 의해 다차원 특징 추출할 수 있는 MFCCs(Mel Frequency Cepstrum Coefficients) 방법이 적용되었다. MFCCs는 심전도 신호를 단 구간 신호로 분할하고 파워 스펙트럼으로 변환하여 비선형적인 멜 스케일의 주파수 영역에서 로그 파워 스펙트럼에 코사인변환을 통해 각 멜 필터 대역마다 그림 16처럼 특징 추출하는 방법이다.

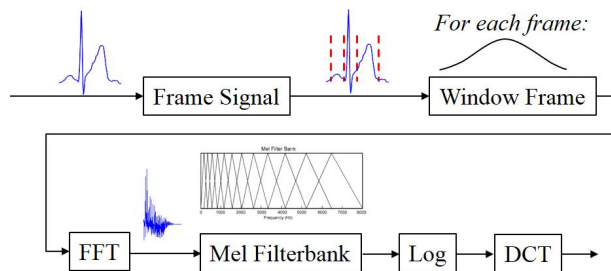


그림 16. 심전도의 MFCC 변환 흐름도

심전도 신호의 한 주기는 HW(Hamming Window) 함수를 합성하여 프레임 단위로 나눈 후에 FFT를 이용하여 주파수 영역으로 변환된다. 변환된 신호는 멜 필터 대역에 따라 1,000Hz 이하에서 중심 주파수와 대역폭이 선형적이고, 1,000Hz 이상에서는 로그 스케일로 증가하며 변환된다. 이때 멜 필터 대역에 따른 멜 값은 식(9)에 의해 결정된다.

$$M(f) = 1125 \ln \left(1 + \frac{f}{700} \right) \quad (9)$$

DCT 과정으로 2차 주파수 영역에 있는 캡스트럼으로 변환되며, 각 필터 대역폭에 따라 MFC의 계수들로 특징들이 추출된다. 추출한 특징들을 이용하여 PTB 데이터베이스에 대한 인식 성능이 KNN에 의해 80%로 분석되었고 피험자 수를 추가로 증가하여 데이터베이스 2, 3에 대한 인식 성능은 80%로 일정하게 유지되었다.

다차원 특징 추출 방법을 이용한 인식 성능은 피험자 수가 증가하여도 단차원 특징을 이용한 인식 성능보다 유지되는 장점이 있지만, 인식 성능이 높게 분석되지 않는 단점이 있다. 낮은 인식 성능으로 분석되는 단점을 보완하기 위해 딥러닝 기반 인식 시스템이 연구되고 있다. 딥러닝을 이용한 인식 시스템은 특징 추출 단계와 분류 단계가 네트워크층으로 연결되어 진행되는 특징이 있다. 딥러닝의 구조는 단일 네트워크, 다중 네트워크로 설계할 수 있으며, 각 네트워크는 일반적으로 합성곱 신경망(Convolutional Neural Network), 순환 신경망(Recurrent Neural Network), 심층 신뢰 신경망(Deep Brief Network)을 이용하여 구성된다.

Giannakakis et al. [42]는 합성곱 신경망을 이용하여 단일 네트워크로 그림 17처럼 구성했다. 합성곱 신경망은 1차원인 심전도 신호를 고려하여 1차원

합성곱 신경망으로 설계했다. 합성곱 계층에서 입력 데이터는 필터 또는 커널에 의해 데이터가 압축되고 차원이 축소된다. 합성곱 계층을 통해 출력된 데이터는 입력 데이터와 유사한 값을 강조하는 특징 맵으로 추출되고, 추출된 특징들을 이용하여 클래스가 분류되는 소프트 맥스 층에서 인식 성능이 결정된다. 인식 성능을 높이기 위해 합성곱 신경망은 특징 맵으로 필터하는 커널을 50으로 조정하고 합성곱 계층을 다중으로 설계했다. 자체 취득 24명 에 대한 인식 성능은 99.4%로 분석되었다.

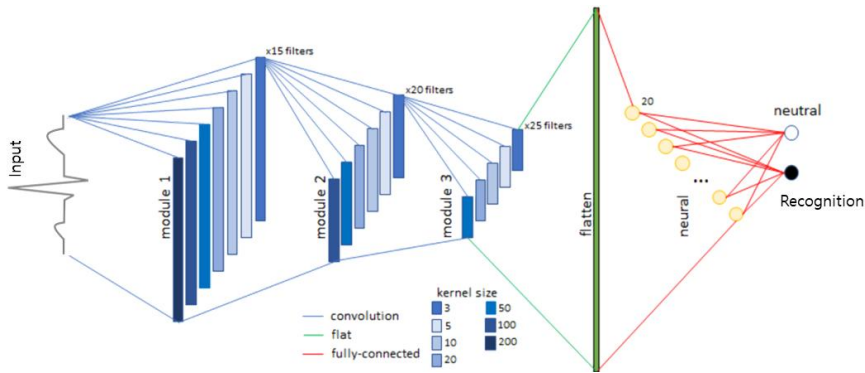


그림 17. 단일 네트워크 구조 예

Jeong et al. [43]은 1차원 합성곱 신경망, Bi-LSTM(Bidirectional Long Short Term Memory) 신경망과 심층 신뢰 신경망을 이용하여 단일 네트워크로 그림 18처럼 구성하였다. LSTM 신경망은 순환 신경망에서 히든 상태에 구조적 상태를 추가한 구조로써 시계열 데이터의 정보를 순차적으로 기억하고 학습할 수 있는 구조이고, 심층 신뢰 신경망은 경사감소 소멸 문제를 해결하기 위해 최종 가중치를 정의해주는 구조이다. LSTM 신경망을 양방향으로 기억하고 학습할 수 있는 Bi-LSTM으로 설계하여 마지막으로 특징 추출되며, 추출된 특징들을 이용하여 소프트 맥스 층에서 MIT-BIH 데이터베이스에 대한 인식




그림 18. 다중 네트워크 구조 예

성능이 96%로 분석되었다. 딥러닝 기반 인식 성능은 다차원 특징을 이용한 인식 성능보다 높게 분석되지만, 정적인 상태에서 측정된 심전도에 맞춰져 있는 파라미터와 복잡한 층 구조로 학습을 위해 HTC(High Time Complexity)가 발생하는 문제점이 있다. 딥러닝에서 문제가 발생하는 영역들이 보완되기 위해 네트워크 은닉층에서 연구되고 있지만, 본 논문에서는 제안한 전처리 단계인 심전도 정규화와 정규화된 심전도의 분해능이 최적화로 조정된 스펙트로그램 특징들을 리사이즈로 이용하여 시간의 복잡도가 발생하지 않는 단일 네트워크로 구성된 시스템에서 높은 성능으로 사용자를 인식한다.

제3장 제안한 방법을 이용한 사용자 인식

본 장에서는 복합적 상태의 심전도 신호를 이용하여 사용자 인식을 위해 제안하는 이상적인 심전도 정규화 방법과 시간-주파수 분해능 조정된 2D 스펙트로그램 방법을 설명하고 제안한 방법이 적용된 사용자 인식 시스템에 관해 설명한다. 사용자 인식에 사용되는 심전도 신호의 정규화 과정은 형태학적 특징이 일정하게 일치되는 여부와 피험자 수 증가에 따라 안정적인 성능으로 분석되는 다차원 특징 추출 기술은 인식률과 직접 연관되기 때문에 중요한 과정이다. 복합적 상태의 심전도는 피험자의 움직임에 의한 아티팩트가 포함되어 잡음이 심한 신호로 나타난다. 본 논문에서는 일상생활에서 측정될 수 있는 복합적 상태의 심전도 신호에서 발생하는 잡음과 딥러닝의 높은 시간 복잡도를 해결하며 인식 성능 향상을 위한 다차원 특징 추출 방법을 제안한다.

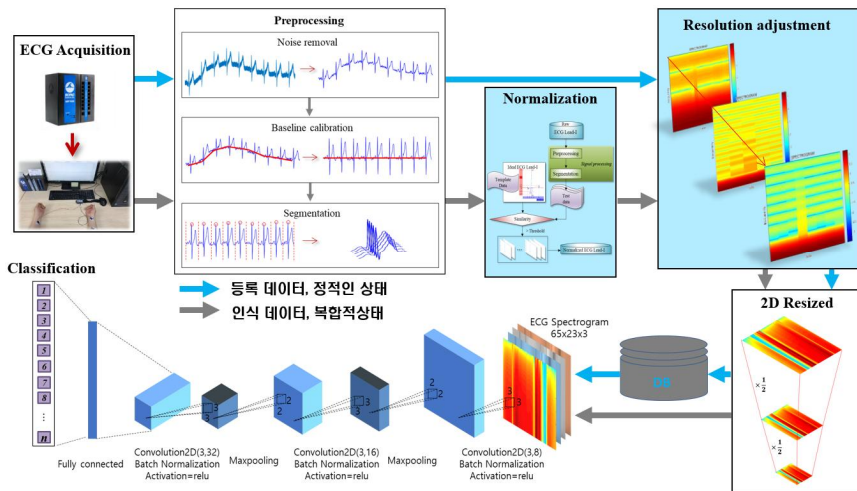


그림 19. 제안하는 정규화된 심전도를 이용한 사용자 인식 시스템

기존 정규화 방법은 등록 데이터에 대한 형태학적 특징 기준이 없으며 인식 데이터에 대한 많은 조건으로 한 주기가 생성되기 어렵지만, 제안한 방법은 이상적인 심전도 주기에 의해 개인의 대표 심전도 한 주기가 선정되고 유사한 심전도들로 필터 되어 정규화되는 기술이 제공된다. 또한, 정규화된 심전도를 다차원 영역에서 특징 추출하기 위해 시간-주파수 분해능이 최적화로 조정된 2D 스펙트로그램으로 변환하고, 단일 합성곱 신경망에 입력되어 우수한 인식 성능으로 분석되는 시스템을 제공한다.

그림 19는 제안하는 정규화 단계와 다차원 특징 추출 단계가 적용된 사용자 인식 시스템의 순서도이다. 등록될 때 정적인 상태에서 측정된 심전도 신호와 인식될 때 복합적인 상태에서 측정된 심전도 신호를 이용하여 신호처리가 진행된다. 신호처리는 대표적인 잡음들을 제거하고 심전도의 형태학적 특징이 존재한 한 주기로 기준점 분할되면 정규화가 진행된다. 특징 추출은 정규화된 등록 데이터와 한 주기로 분할된 인식 데이터가 시간-주파수 분해능 조정으로 각각 진행된다. 특징 추출된 스펙트로그램은 2D로 리사이즈되며 합성곱 신경망의 입력 데이터로 사용된다. 최종적으로 학습된 등록 데이터로부터 인식 데이터가 소프트 맥스 층에서 분류된다.

제1절 심전도 신호처리

심전도 신호 신호처리는 잡음 제거 단계와 한 주기 분할 단계로 진행된다. 잡음 제거 단계는 심전도 신호에 존재하는 대표적인 60Hz 전력선 잡음, 피형자 호흡에 의한 기저선 변동 잡음, 미세한 아티팩트 잡음들을 제거하는 과정이다.

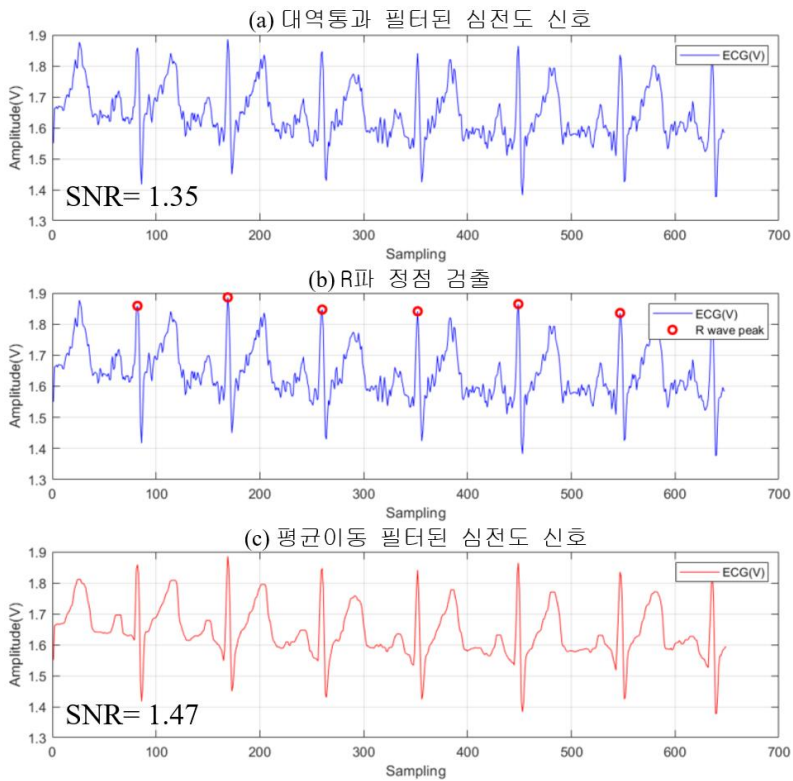


그림 20. 잡음이 제거된 심전도 신호

0Hz 이상 주파수 대역에 존재하는 전력선 잡음과 미세하게 움직임으로 발생하는 잡음, 0.5Hz 이하 주파수 대역에 존재하는 전극의 접촉 잡음들은 대

역 통과 필터에 의해 그림 20(a)처럼 제거된다. 주파수 필터에서 출력된 신호에도 미세한 잡음들이 존재하기 때문에 개인 고유한 생체정보가 포함되는 QRS Complexes 구간을 제외한 구간에서 제거해야 한다. QRS Complexes 구간을 설정하기 위해 R파 정점을 검출해야 한다. R파 정점은 Pan&Tomkins 알고리즘에 의해 그림 20(b)처럼 검출된다[44]. QRS Complexes 구간을 제외한 신호들은 평균 이동 필터에 의해 미세한 잡음들을 그림 20(c)처럼 제거된다. 잡음 제거의 정도를 SNR(Signal to Noise Ratio)로 분석하였으며 평균 이동 필터에 의해 출력된 신호가 주파수 필터보다 높게 분석되었다. 대역 통과 필터 및 평균 이동 필터를 이용하여도 피험자 호흡에 의한 기저선 변동 잡음은 제거되지 않는다.

기저선 변동은 기저선 추정 과정, 투영 과정, 0점 조정 과정으로 교정될 수 있다. 기저선 추정은 1차 회귀 분석으로 부분적 기저선을 정의하고 연속적 기저선으로 생성된다[45]. 부분적 기저선은 심전도의 T파와 P파 중간값, P파와 Q파 중간값을 이용하여 1차 회귀 분석이 수식 (10), (11), (12)에 의해 결정되며, 그림 21(a)과 같다. 부분적 기저선들이 연속적으로 추정되면 그림 21(b)과 같이 기저선 변동이 추정된다.

$$Partial\ baseline = w \cdot x + \beta \quad (10)$$

$$w = \frac{y_2 - y_1}{x_2 - x_1} \quad (11)$$

$$\beta = y_1 - \frac{y_2 - y_1}{x_2 - x_1} \cdot x_1 \quad (12)$$

추정된 기저선들은 평균 수평선을 생성하고, 수평선에 그림 21(c)처럼 투영된 후 0점으로 조정된다. 영점으로 조정된 심전도 신호는 형태학적 특징이 유지되면서 개인 고유의 정보인 QRS Complexes 값들에 영향을 주지 않으며 그림 22(a)의 기저선 변동 잡음이 (b)에서 추정되고 (c)처럼 0점 조정되었다.

잡음이 제거된 심전도 신호는 특징들이 추출되기 위해 분할과정이 진행된다. 심전도 분할은 기준점 분할과 비기준점 분할 과정으로 진행될 수 있으며, 형태학적 특징들이 일정하게 분석될 수 있는 기준점 기반 분할 방법으로 심전도의 한 주기로 구성된 P, QRS Complexes, T파로 분할된다. 분할된 심전

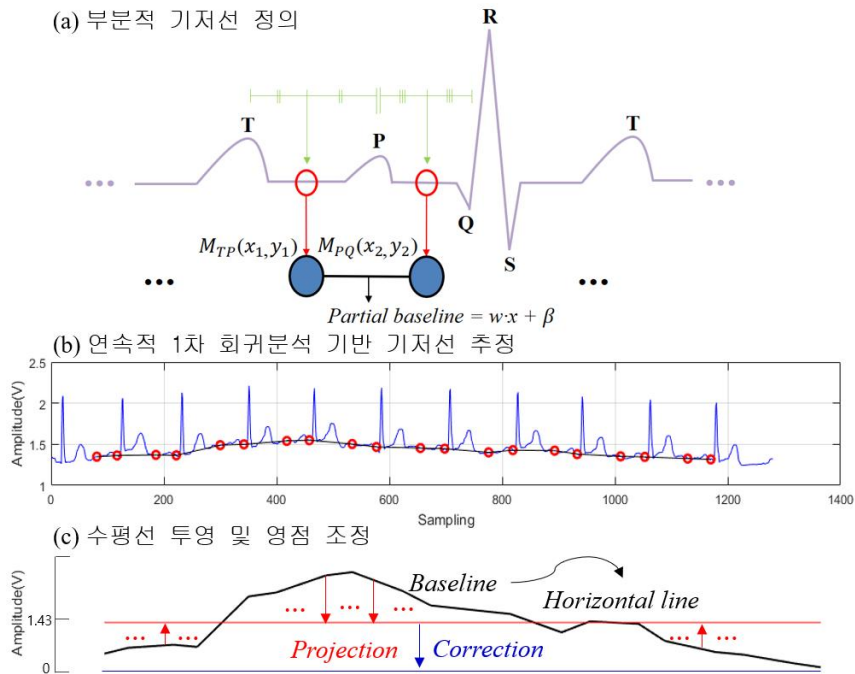


그림 21. 심전도 신호의 기저선 추정 과정




그림 22. 0점으로 조정된 심전도

도 주기는 등록 데이터를 위해 특징 추출 단계로 진행되고, 인식 데이터는 제안한 정규화 단계로 각각 진행된다.

제2절 이상적인 심전도 정규화

복합적인 상태에서 측정된 심전도 신호는 움직임에 의해 아티팩트가 높게 포함되어 잡음과 같은 신호로 나타날 수 있다. 잡음을 제거하고 심전도 신호의 형태학적 특징들을 일치시키기 위해 기존 정규화 방법은 정적인 상태에서 측정된 심전도를 위한 적응형 정규화 방법이며, 인식 데이터가 정규화되어 생성되기까지 경우의 수가 많거나 등록 데이터가 정의되어 있지 않기 때문에 잡음이 포함된 심전도 신호로 정규화될 수 있는 문제점이 있다. 본 논문에서는 복합적 상태에서 측정된 심전도 신호의 형태학적 특징들이 뚜렷한 심전도 주기들로 정규화하기 위해 각 피험자의 이상적인 심전도 주기가 선정되어 인식 데이터가 이상적인 심전도로 필터 되어 정규화되는 방법을 제안한다. 제안한 정규화 방법은 이상적인 심전도 한 주기를 생성하는 과정, 각 피험자의 적응형 표본 심전도 주기를 선정하는 과정, 표본 심전도 주기에 의해 인식 데이터가 필터 되는 과정으로 그림 23처럼 구성된다.

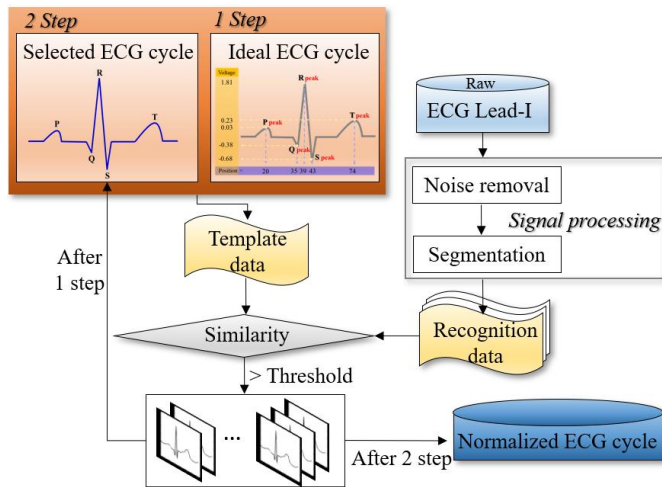


그림 23. 심전도 정규화 흐름도

이상적인 심전도 한 주기는 심전도의 P, QRS Complexes, T파가 뚜렷하게 구성되어 있으며 잡음에 의해 신호가 일그러지거나 왜곡되지 않는 신호이다. 이상적인 심전도 한 주기는 공용 DB인 MIT-BIH NSR, QT, European의 심전도 주기에서 P, Q, R, S, T파 정점들의 전압과 위치 정보를 표4의 수식들을 이용하여 산출하고, 정점들의 연결은 1, 2차 수식으로 데이터가 보강되어 생성된다. MIT-BIH NSR DB에서 1,800개(피험자 18명 × 100주기), QT DB에서 10,500개(피험자 105명 × 100주기)와 European DB에서 7,900개(피험자 79명 × 100주기)의 심전도 주기를 이용했다.

표 4. 이상적인 심전도의 P, Q, R, S, T파 정점 수식

	Voltage	Location
P peak	$\frac{\sum_{i=1}^n PV_i}{n}$	$\frac{\sum_{i=1}^n PL_i}{n}$
Q peak	$\frac{\sum_{i=1}^n QV_i}{n}$	$\frac{\sum_{i=1}^n QL_i}{n}$
R peak	$\frac{\sum_{i=1}^n RV_i}{n}$	$\frac{\sum_{i=1}^n RL_i}{n}$
S peak	$\frac{\sum_{i=1}^n SV_i}{n}$	$\frac{\sum_{i=1}^n SL_i}{n}$
T peak	$\frac{\sum_{i=1}^n TV_i}{n}$	$\frac{\sum_{i=1}^n TL_i}{n}$

P, Q, R, S, T파 정점의 데이터 정보를 이용하여 이상적인 심전도 주기를 생성한다. 각 정점을 제외한 QRS Complexes 구간은 1차 방정식, P파와 T파 구간은 2차 방정식으로 데이터를 생성하고 보강한다. 1, 2차 방정식의 가중

치 ω 와 바이어스 β_1, β_2 는 수식 (13)으로 결정된다. 각 정점과 형태학적 특징 이외의 구간은 0점 조정된 심전도 주기로 생성하기 위해 0V로 설정되고 그림 24처럼 이상적인 주기가 생성된다. 개인의 표본 심전도를 선정하기 위해 심전도 신호의 형태학적 특징들이 뚜렷하게 나타날 수 있는 정적인 상태에서 심전도가 측정되어야 한다. 유사도가 분석되기 위해 측정된 신호들은 기준점 기반 주기가 분할되어 이상적인 심전도와 일정한 데이터 크기로 정합된다. 그림 25는 이상적인 심전도 주기를 이용하여 개인의 표본 심전도 주기를 선정하고, 개인의 임계 값에 의해 표본 심전도 주기와 유사한 심전도 주기로 정규화하는 과정을 보여준다.

$$\omega = \frac{y_2 - y_1}{x_2 - x_1}$$

$$\beta_1 = y_1 - \frac{y_2 - y_1}{x_2 - x_1} \times (x_1 - m) \quad (13)$$

$$\beta_2 = y_1 - \frac{y_2 - y_1}{x_2 - x_1} \times (x_1 - m)^2$$

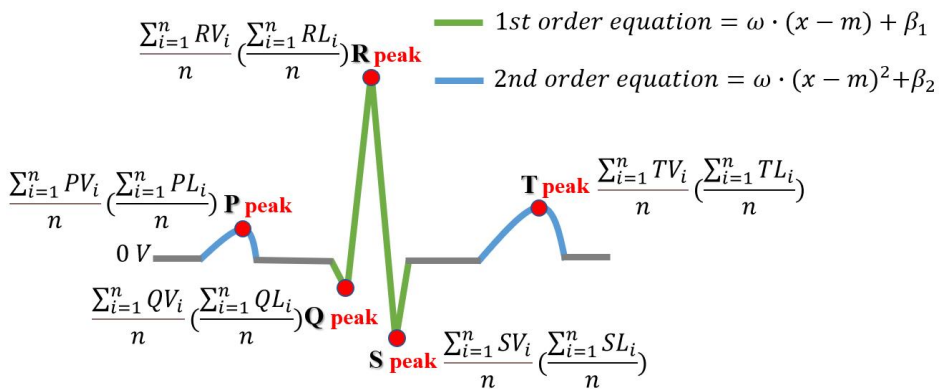


그림 24. 이상적인 심전도의 주기 생성

개인의 표본 심전도 주기의 선정은 인식 데이터 X 가 이상적인 심전도 Y 와 최대 유사도 비율에 해당하는 심전도 주기 Z 가 개인 표본 심전도로 선정된다. X 와 Z 의 유사도에 의해 최솟값 k , 최댓값 l 을 이용하여 임계 값 Th 가 결정된다. $k+Th$ 에 의해 표본 심전도 주기로부터 정규화된 N 이 집합된다. 개인의 표본 심전도와 취득된 심전도를 이용하여 연산한 $k+Th$ 에 의해 MSR(Maximum Similarity Rate)의 값으로 필터 되는 허용 유사도 비율 PSR(Permit Similarity Rate)이 Th 설정되는 범위에 따라 정해진다. 그림 26은 Th 에 따라 MSR과 PSR 관계를 보여준다. 심전도의 원신호인 그림 26(a)에서 MSR이 높으면 PSR이 높아져 필터 되는 심전도 주기들이 그림 26(b)처럼 많아지고, 제외되는 심전도 주기들은 적어진다. 반대로 MSR이 낮으면 PSR이 낮아져 필터 되는 심전도 주기들이 그림 26(c)처럼 적어지고, 제외되는 심전도 주기들이 많아진다.

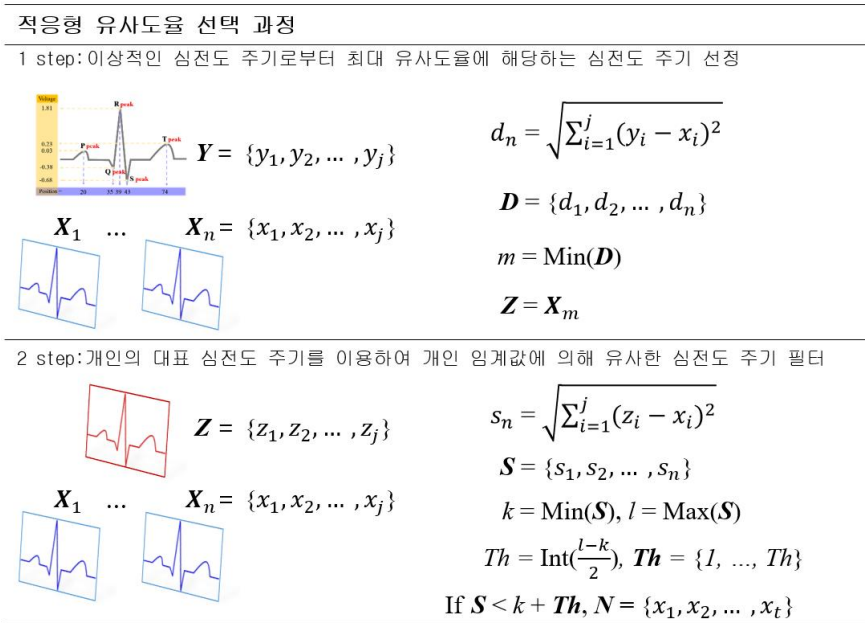


그림 25. 적응형 유사도 필터 과정





그림 26. Th 에 따라 필터 되는 심전도


PSR이 낮을수록 개인의 표본 심전도의 형태학적 특징들과 유사한 심전도 주기들로 구성된다. 그림 27은 각 피험자 (a)와 (b)의 PSR 값에 따라 정규화된 심전도 신호이다. 이상적인 심전도로부터 개인의 표본 심전도의 PSR에 따라 설정되어 일정하지 않은 형태학적 특징들이 나타날 경우, 필터 되어 전체 신호에서 제외된다. 따라서 제안된 정규화 알고리즘에 의해 개인의 형태학적 특징들이 유사한 심전도 주기들로 정규화되고, 개인 맞춤형 심전도로 필터 되는 주기들로 구성된다.

표 5는 적응형 유사도 필터 기반 정규화에 의해 각 취득 상태마다 필터 및 제외되는 심전도 주기 수이다. 정규화 결과, 동적 상태의 심전도에서 제외되는 주기 수가 증가하여 정적 상태의 심전도 주기보다 아티팩트가 높게 포함됨을 확인했다. 또한, 심전도 취득할 때 취득 부위에서 움직임이 많을수록

정규화에 의해 제외되는 심전도 주기 수가 높은 동작은 문 여닫기 동작을 통해 확인했다.



(a) 43번 피험자의 정규화



(b) 65번 피험자의 정규화

그림 27. 피험자에 따라 정규화된 심전도

적응형 유사도 필터 기반 정규화로 형태학적 특징과 유사하지 못한 심전도 주기들이 제외되면 전체 심전도 주기 수와 일치되지 않는 데이터 불균형 문제가 발생한다. 데이터 불균형 문제를 해결하기 위해 비지도 학습 기반 생성

모델인 VAE(Variational Auto-encoder)를 이용하여 심전도 주기들의 데이터를 생성한다.


표 5. 취득 상태에 따른 정규화 후 심전도 주기 수 분석

동작	심전도 주기 수		
	필터	제외	
정적	앉기	9,897	103
	서기	9,527	473
	운동 후 앉기	9,345	655
동적	폰 터치	8,943	1,057
	문 여닫기	7,240	2,760
	운동 중	8,348	1,652

VAE는 식 (14)에 의해 입력 데이터 x 로부터 모델 파라미터에 의한 샘플 데이터 z 확률인 $p_{\theta}(z)$ 와 z 에 대한 조건확률인 $p_{\theta}(x|z)$ 을 이용하여 데이터를 생성한다. 입력 심전도 주기를 이용하여 학습 반복 횟수에 따라 생성한 심전도 주기는 표 6과 같다. 입력 심전도 주기와 일치되는 반복 횟수 4에서 생성되는 심전도 주기들을 이용하여 데이터 불균형 문제를 해결한다.

$$p_{\theta}(x) = \int p_{\theta}(z)p_{\theta}(x|z)dz \quad (14)$$

표 6. 학습 반복 횟수에 따라 생성한 심전도 주기



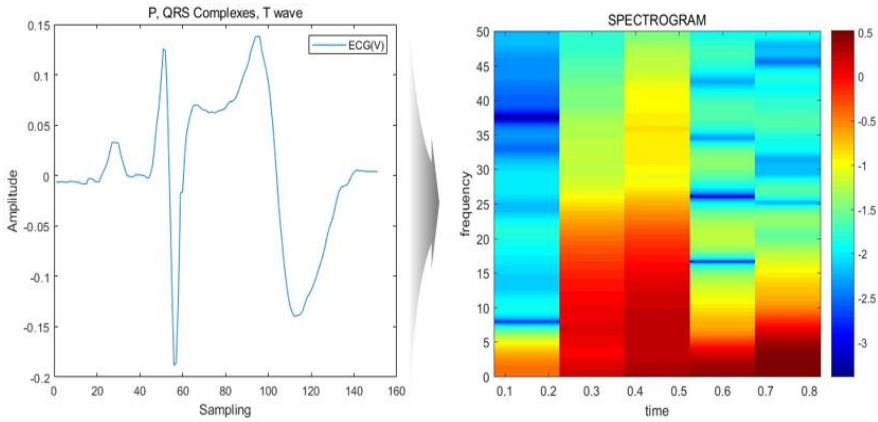
제3절 분해능 조정된 2D 스펙트로그램 특징 추출을 이용한 사용자 인식 시스템

특징 추출 단계는 인식 성능에 직접적인 영향을 주는 과정이다. 기존 특징 추출 기술들은 인식 성능을 높이기 위해 단 차원, 다차원과 딥러닝으로 연구되어왔고, 피험자 수 증가에 따른 인식 성능에 영향을 받지 않으며 인식 성능을 높이고 있다. 단 차원에서 추출된 특징들은 높은 인식 성능으로 분석되지만, 피험자 수가 증가할수록 낮아지는 단점과 다차원에서 추출된 특징들은 피험자 수가 증가하여도 인식 성능이 유지되지만 낮은 인식 성능으로 분석되는 단점이 있다. 딥러닝에 의해 특징 추출과 인식 분류에 대한 성능은 기존 다차원 특징 추출 방법의 단점을 보완하여 높은 성능으로 분석되지만, 단일 네트워크 및 다중 네트워크의 복잡한 구조에 의해 학습 과정이 높은 시간 복잡성으로 HTC 문제가 발생하는 단점이 있다. 본 논문에서는 높은 시간 복잡성 문제를 해결하고 피험자 수가 증가하여도 기존 다차원 특징 추출 기술보다 인식 성능이 높게 분석되는 방법을 제안한다. 제안한 방법은 심전도 한 주기의 시간-주파수 분해능을 최적화로 조정하여 스펙트로그램으로 변환하는 과정, 2D 영상을 리사이즈하는 과정과 합성곱 신경망으로 구성된 단일 네트워크의 낮은 은닉층에 의해 사용자가 인식되는 과정으로 구성된다.

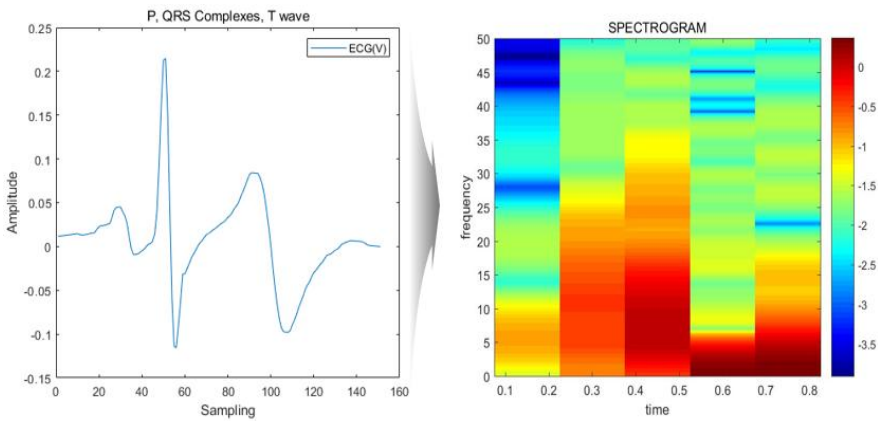
시간-주파수 분해능이 조정된 스펙트로그램은 심전도의 한주기를 스펙트로그램으로 변환하고 시간과 주파수 분해능을 조정하는 과정, 2D로 변환하는 과정으로 진행된다. 스펙트로그램으로 변환은 심전도 신호 $x(t)$ 를 이용하여 식(15)에 의해 결정된다. 변환된 스펙트로그램 X 는 실수와 허숫값 s 로 구성되며 원도 함수 $w(t)$ 가 이동되는 τ 에 따라 심전도 신호와 FFT 연산 되어 τ 와 각주파수 w 마다 s 값으로 산출된다.

$$X(\tau, \omega) = \int_{-\infty}^{\infty} x(t)w(t - \tau)e^{-i\omega t} dt = s \quad (15)$$

각 피험자의 심전도 한 주기를 이용하여 변환된 스펙트로그램은 그림 27과 같다.



(a) 피험자 35번의 심전도와 스펙트로그램



(b) 피험자 57번의 심전도와 스펙트로그램

그림 28. 피험자마다 심전도 한 주기를 이용한 스펙트로그램 변환

피험자마다 심전도 신호의 형태학적 특징들이 스펙트로그램으로 변환되어 시간에 따라 주파수의 대역에 분포되는 크기를 확인할 수 있다.

표 7. 원도 이동 변수 조정에 따른 스펙트로그램

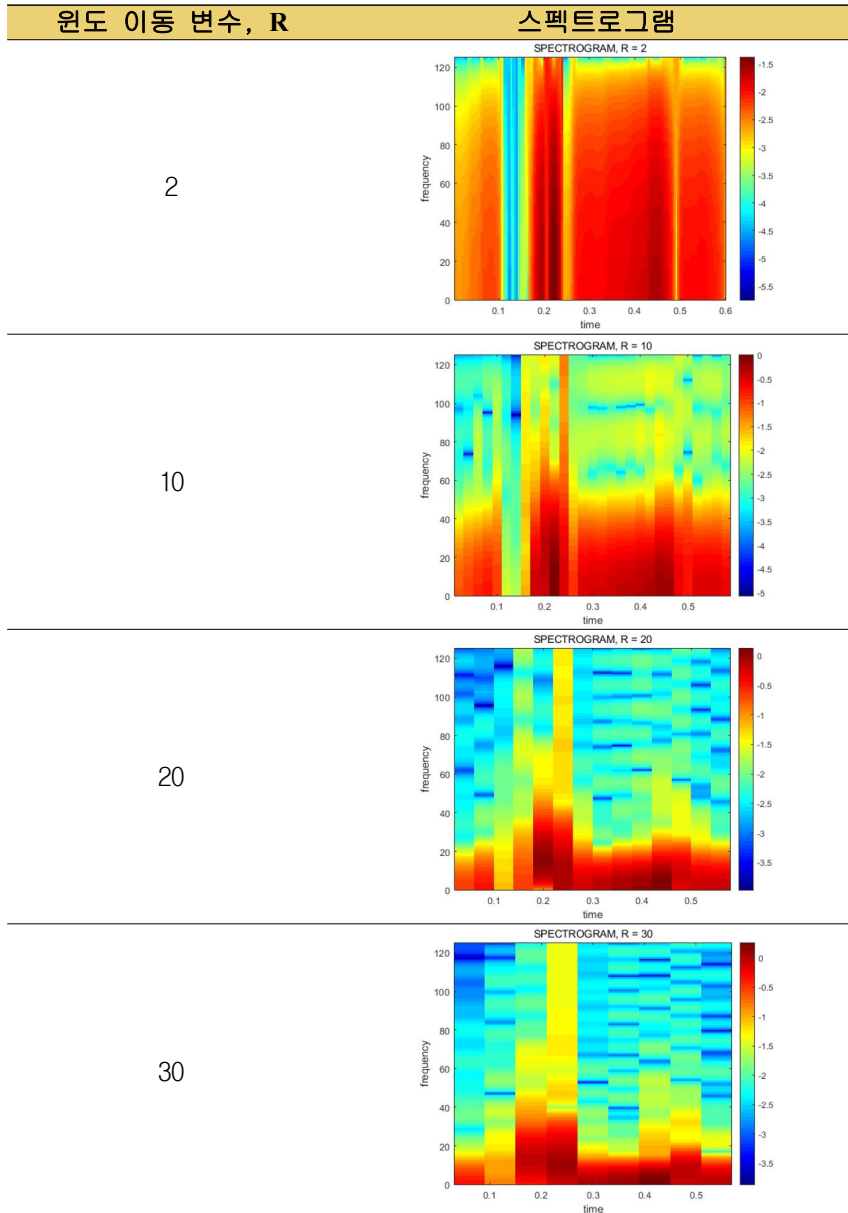


그림 28(a)의 스펙트로그램은 (b)보다 P파와 QRS Complexes 구간에서 비슷한 주파수 대역에서 높은 크기 값들로 구성되어 있다. 스펙트로그램의 주파수 영역에서 피험자마다 주파수 대역의 크기 값들이 고유한 특징들로 구성된다. 스펙트로그램은 윈도우 이동에 따라 시간과 주파수 분해능이 조정되어 출력될 수 있다. 윈도우가 이동될 때 겹치는 데이터 수인 윈도우 이동 변수에 의해 시간과 주파수 분해능이 조정된다. 윈도우 이동 변수는 FFT 길이와 겹치는 데이터 수의 차에 의해 조정되며, 윈도우 이동 변수가 높을수록 주파수 분해능은 높아지고 시간 분해능이 낮아지는 반비례 관계로 분석된다.




그림 29. 2D 리사이즈된 스펙트로그램

표 7처럼 윈도우 이동 변수 조정됨에 따라 시간과 주파수 분해능이 조정된 스펙트로그램을 확인할 수 있다. 이는 시간 분해능이 높아질수록 심전도 신호

호를 좁은 간격의 시간에 따른 주파수 크기 값들을 확인할 수 있고 낮아질수록 넓은 간격의 시간에 따라 주파수 크기 값들을 확인할 수 있다. 본 논문에서는 시간과 주파수 영역에서 동시에 분석할 수 있는 스펙트로그램으로 변환하고, 심전도 신호의 형태학적 특징들이 시간에 따라 분포됨을 고려하여 시간 분해능이 최대일 때 스펙트로그램을 다차원 특징들로 추출한다.

2D 영상 리사이즈 과정은 다차원 특징으로 추출한 스펙트로그램을 영상으로 변환하고 변환된 영상 크기의 차원을 축소하기 위해 리사이즈 과정으로 진행된다. 리사이즈 방법은 Bi-cubic 보간에 의해 데이터 손실이 없는 보간 방법으로 압축된다. 리사이즈된 2D 스펙트로그램은 시간에 대한 해상도를 유지하며 영상 크기가 그림 29처럼 축소된다[46]. Bi-cubic 보간은 cubic 보간으로 x축과 y축으로 각각 진행한 후 얻는다. 네 점 (0, 0), (0, 1), (1, 0), (1, 1)을 꼭짓점으로 하는 정사각형 내의 임의의 지점 (x, y) $0 \leq x \leq 1$, $0 \leq y \leq 1$ 에서의 픽셀값을 주변의 16개 지점 (i, j) $-1 \leq i \leq 2$, $-1 \leq j \leq 2$ 에서의 픽셀값을 이용하여 구한다. 픽셀값 f(x, y)는 x와 y의 3차 함수로 식(16)에 의해 결정된다. 이후 보간은 a의 16 계수를 결정하고 진행된다. f(x, y) 함숫값을 이용하여 네 개의 방정식을 식(17)처럼 얻을 수 있다.

$$f(x, y) = \sum_{i=0}^3 \sum_{j=0}^3 a_{ij} x^i y^j \quad (16)$$

$$\begin{aligned}
 f(0, 0) &= a_{00}, & f(1, 0) &= a_{00} + a_{10} + a_{20} + a_{30} \\
 f(0, 1) &= a_{00} + a_{01} + a_{02} + a_{03}
 \end{aligned} \quad (17)$$

$$f(1, 1) = \sum_{i=0}^3 \sum_{j=0}^3 a_{ij}$$

이후 x , y 방향으로 미분한 8개의 방정식과 xy 혼합 편 미분한 4개의 방정식에 의해 16개의 다항식의 계수 16차원 벡터를 이용하여 픽셀에서의 주변 정보를 연산하고 보강한다. Bi-cubic 보간에 의해 영상 크기가 1단계 축소로 257×94 에서 129×47 , 2단계 축소로 129×47 에서 65×23 으로 리사이즈된다.

사용자 인식을 위해 2D 리사이즈된 스펙트로그램 영상은 단일 네트워크인 합성곱 신경망으로 입력된다. 분해능 조정된 2D 스펙트로그램을 입력 영상으로 설계한 CNN은 2D 합성곱, 배치 정규화와 활성화 함수 ReLU는 3개의 층, 맥스 풀링은 2개의 층, 완전 연결과 소프트 맥스 층으로 표 8처럼 구성된다. 2D 합성곱은 6개의 층으로 증가하는 구조에서 검증률과 인식 성능이 향상된 후 수렴되는 3개의 합성곱 층으로 설계된다. 배치 정규화는 학습할 때 과적합(Overfitting)을 줄이고 학습률이 수렴되는 경과 시간을 단축하기 때문에 합성곱 특징 맵이 생성된 이후에 설계된다. 정규화된 특징 맵에서 0보다 큰 값들이 비선형 구조로 활성화되기 위해 ReLU 함수가 배치 정규화 이후에 설계된다.

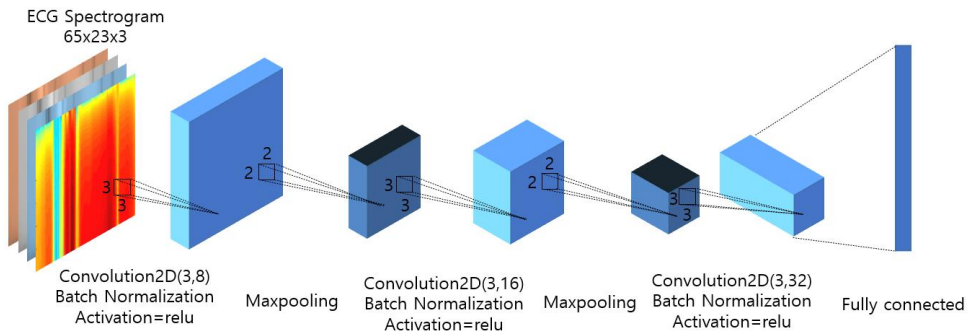


그림 30. 사용자 인식을 위한 합성곱 신경망

뚜렷한 특징 맵 생성과 특징 데이터 차원 축소 및 인식 성능을 향상하는

2×2 필터가 적용된 맥스 풀링 층이 설계된다. 최종 사용자를 인식하기 위해
 확률적으로 클래스를 분류하는 완전 연결과 소프트 맥스 층으로 설계된다.

표 8. CNN 네트워크 구조

	Layer	Describe
1	Input	65 × 23 × 3
2	2D convolution	8, 3 × 3 Conv., Stride[1 1]
3	Batch nor.	Output value nor.
4	ReLU	If $x > 0$ gradient 1, If $x < 0$ $f(x)=0$
5	Max-pooling	2 × 2 max value, Stride[2 2]
6	2D convolution	16, 3 × 3 Conv., Stride[1 1]
7	Batch nor.	Output value nor.
8	ReLU	If $x > 0$ gradient 1, If $x < 0$ $f(x)=0$
9	Max-pooling	2 × 2 max value, Stride[2 2]
10	2D convolution	32, 3 × 3 Conv., Stride[1 1]
11	Batch nor.	Output value nor.
12	ReLU	If $x > 0$ gradient 1, If $x < 0$ $f(x)=0$
13	Fully connected	100 fully connected layer
14	Softmax	Softmax

제4장 실험 조건별 성능 분석

본 장에서는 제안한 사용자 인식 시스템을 평가하기 위해 복합적 상태를 정의하고 취득하는 규정에 따라 자체적으로 심전도 신호를 취득하고 인식 성능을 분석한다. 인식 성능을 분석하기 위해 제안하는 정규화 방법과 다차원 특징 추출 방법 조건에 따라 변화하는 인식률을 분석한다.

제1절 실험 방법

본 논문에서 제안한 정규화 방법과 특징 추출 방법은 각각 유사도 비율과 인식률로 확인한다. 유사도 비율은 심전도 신호를 제안한 방법으로 정규화 전과 후에 의해 변화하는 성능을 기존 정규화 방법과 성능을 비교하여 확인한다. 또한, 사용자 인식률은 1:N 정합으로 식별되고 데이터베이스에 저장된 심전도 데이터 중 가장 유사한 인식 데이터가 해당 클래스로 분류되는 정도를 확인한다. 제안한 다차원 특징 추출 조건에 의한 인식률을 분석하고 최적의 인식 방법을 제안하며 기존 방법과 인식률을 비교하여 확인한다.

1. 심전도 DB

사용한 심전도 데이터베이스는 실생활에서 고려될 수 있는 복합적인 상태를 정의하여 피험자들로부터 심전도를 취득하고 CU-DB(Chosun University Database)로 구축했다. CU-DB는 피험자 200명의 정적인 상태에서 심전도 lead-I 신호를 3회 취득하고 DB로 구축했으며, 피험자 300명의 동적인 상태에서 심전도 lead-I 신호를 3회 취득하고 DB로 구축했다. 본 논문에서는 정

적인 DB와 동적인 DB를 연계하며 실험에 사용할 수 있는 피험자 100명의 심전도 신호를 선별하고 실험 데이터로 구성했다. 실험을 위해 학습 데이터와 인식 데이터의 구성 비율은 7:3이고, 학습 데이터는 정적인 상태에서 취득한 심전도의 주기를 총 12,600개(피험자 100명 × 정적인 상태 3 동작 × 42 주기), 인식 데이터는 복합적 상태에서 취득한 심전도의 주기를 총 5,400개(피험자 100명 × 복합적 상태 6 동작 × 9주기)로 구성된다.


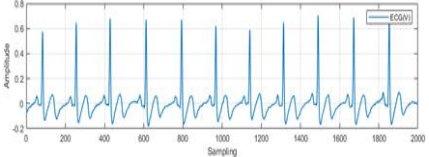

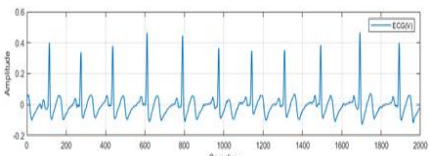

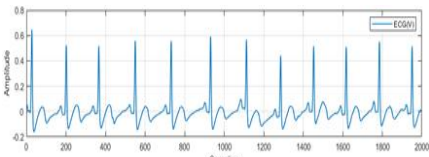

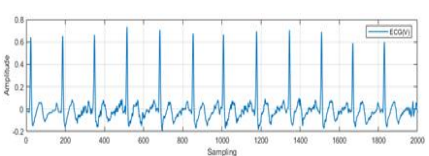

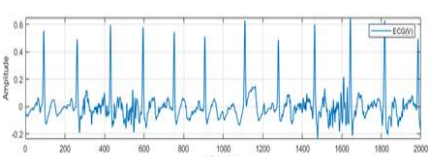

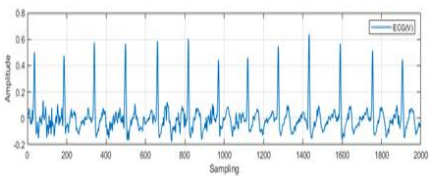
심전도 신호를 취득하기 위해 BioPac社の MP160 측정 장비를 이용했고, 심전도 lead-I 신호를 취득할 때 원 심전도에 포함된 잡음을 제거하기 위해 하드웨어에서 노치 필터, 소프트웨어에서 5Hz부터 30Hz까지 대역 통과 필터가 실시간으로 적용된 심전도 데이터로 구축했다. 취득할 때 개인 고유의 형태학적 특징 데이터들을 정밀하게 수집하기 위해 2,000Hz 샘플링 레이트에서 취득된 데이터를 구축하고 연산 속도향상을 위해 200Hz로 다운 샘플링했다.

표 9. 심전도 측정 규약

횟수	상태					
	정적			동적		
	앉기	서기	운동 후 앉기	폰 터치	문 여닫기	운동 중
1	60초	60초	180초	10회	10회	180초
2~3일 휴식						
2	60초	60초	180초	10회	10회	180초
2~3일 휴식						
3	60초	60초	180초	10회	10회	180초

공개 DB의 샘플링 레이트는 MIT-BIH NSR에서 128Hz, QT에서 250Hz,

표 10. 복합적 상태에서 취득된 심전도 신호

측정 상태	측정한 심전도
<p>앉기</p> 	
<p>서기</p> 	
<p>운동 후 앉기</p> 	
<p>폰 터치</p> 	
<p>문 여닫기</p> 	
<p>운동 중</p> 	

European에서 250Hz, Arrhythmia에서 360Hz로 각 DB의 심전도를 취득할 때 서로 다른 샘플링 레이트에서 심전도 신호가 데이터로 구축되었다. CU-DB와 동일한 샘플링 레이트로 조정하기 위해 4개 공개 DB의 샘플링 레이트를 200Hz로 리샘플링했다.

심전도 Lead-I 취득을 위해 측정 전용 전극인 Covidien 社의 Kendall 습식 전극을 피험자 양 손목에 부착했다. 심전도 신호 취득 규약은 표 9와 같으며, 실생활 재현성을 위해 2~3일 기간 간격으로 피험자마다 정적인 상태와 동적인 상태에서 심전도를 총 3회 취득했다. 정적인 상태는 앉기, 서기, 운동 후 앉기이며 동적인 상태는 핸드폰 터치, 문 여닫기, 운동 중으로 표 10 처럼 정의했다. 심전도를 취득하기 전과 후 피험자 상태를 고려하기 위해 설문지 작성을 시행했으며 취득하기 전 영향을 줄 수 있는 카페인, 음주 및 약물 복용 등을 확인하고 음주를 제외한 모든 상태에서 취득을 진행했다.

2. 정규화 및 사용자 인식 성능 평가 방법

심전도 신호를 정규화 전, 제안한 방법에 따라 정규화된 후 유사도와 다차원 특징 추출을 이용한 인식률을 확인하고 기존 방법들과 비교 분석한다. 유사도 평가는 유클리디언 거리, 마할라노비스 거리와 코사인 유사도를 이용하여 심전도 신호의 정규화 유무에 따라 측정하였다. 유클리디언 거리는 두 특징 벡터 간의 직선거리를 측정하여 데이터의 거리 공식에 따라 계산하는 방법이다[47]. 두 개의 심전도 주기 데이터 사이의 거리를 계산하여 0에 가까울수록 유사하다. 유클리디언 거리는 식 (18)에 의해 결정되고, p 와 q 는 유사도를 구하기 위한 심전도 특징 벡터이다.

$$d(p, q) = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (18)$$

마할라노비스 거리는 유클리디언 거리에서 특징 벡터 속성들의 공분산을 반영하여 유사도를 확률 분포상의 거리로 측정한다[48]. 유클리디언 거리와 동일하게 두 개의 심전도 주기 데이터와 공분산 행렬을 이용하여 0에 가까울수록 유사하다. 마할라노비스 거리는 식 (19)에 의해 결정된다.

$$d(p, q) = \sqrt{(p - q)C^{-1}(p - q)^T} \quad (19)$$

코사인 유사도는 유클리디언 거리와 달리 특징 벡터들의 방향에 따라 유사도를 판단하는 원리로 두 개의 심전도 주기 사이를 코사인 각도에 의해 측정된다[49]. 두 개의 심전도 주기의 코사인 유사도는 1에서 -1 사이의 값으로 측정되고 1에 근사할수록 유사하다. 코사인 유사도는 식 (20)에 의해 결정된다.

$$\cos(\theta) = \frac{p \cdot q}{\|p\| \|q\|} = \frac{\sum_{i=1}^n p_i \times q_i}{\sqrt{\sum_{i=1}^n p_i^2} \times \sqrt{\sum_{i=1}^n q_i^2}} \quad (20)$$

사용자 인식률은 인식 시스템 모델을 성능 평가하는 척도이며 등록 데이터 클래스에 대한 인식 데이터 클래스를 실제 정답과 분류 결과 값에 따라 혼동 행렬에 의해 산출된다. 혼동 행렬에서 결과 수치들은 TP(True Positive), FP(False Positive), FN(False Negative), TN(True Negative)이고, 수치들을 이

용하여 식 (21)부터 (25)까지 인식률인 정확도(Accuracy), 민감도(Sensitivity), 특이도(Specificity), 정밀도(Precision), F1-score가 측정된다.

- TP: 실제 True 인 정답을 True 로 식별
- FP: 실제 False 인 정답을 True 로 식별
- FN: 실제 True 인 정답을 False 로 식별
- TN: 실제 False 인 정답을 False 로 식별

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (21)$$

$$Sensitivity = \frac{TP}{TP + FN} \quad (22)$$

$$Specificity = \frac{TN}{TN + FP} \quad (23)$$

$$Precision = \frac{TP}{TP + FP} \quad (24)$$

$$F1 - score = 2 \times \frac{Precision \times Sensitivity}{Precision + Sensitivity} \quad (25)$$

제2절 정규화된 심전도 유사도 결과 및 분석

본 절에서는 복합적인 상태에서 측정된 CU-DB를 이용하여 제안하는 유사도 필터 기반 심전도 정규화 방법과 기존 정규화 방법의 유사도 성능을 각 유사도 측정 방법에 따라 비교 분석한다. 제안한 유사도 필터 기반 정규화 방법으로 형태학적 특징과 유사하지 않으면 제외하더라도 심전도 신호의 연속성 특징에 의해 일정한 테스트 데이터 수로 구성하고 유사도를 평가했다. 유사하지 않은 심전도 주기를 제외하기 전은 ‘정규화 전’ 이고, 제외한 후는 ‘정규화 후’ 로 진행된다. 기존 방법은 시간, 주파수, 위상영역에서 정규화했던 기술들이고, 유사도 성능은 각 상태의 유사도를 평균으로 산출한다. 각 정규화 방법에 따른 평균 유사도 성능을 비교하여 제안한 방법의 우수성을 증명한다.




그림 31. 정규화 전 각 상태의 유클리디언 거리 유사도

유사도 검증을 위해 각 피험자당 측정 상태마다 사용한 심전도 주기는 1부

터 100까지 이용하여 정규화 전일 때 유클리디언 거리에 의해 유사도 값인 0
 부터 1까지의 수를 역으로 환산하고 백분율로 측정했다. 그림 31은 정규화
 전 유클리디언 거리에 의해 심전도 주기 수가 증가함에 따라 정적 상태의 심
 전도 주기의 유사도는 일정하게 분석되는 반면, 동적 상태의 심전도 주기의
 유사도는 45주기 이상부터 감소하며 분석되었다.




그림 32. 각 정규화 방법에 따른 유클리디언 거리 유사도

피험자의 문 여닫기, 운동 중 상태에서 불규칙한 움직임 동작에 따라 모션
 아티팩트 영향으로 심전도 45주기 이상부터 평균 유사도가 저하되는 구간으
 로 분석된다. 모든 상태의 심전도 100주기 평균 유사도가 유클리디언 거리에
 의해 92.28%로 분석되었다. 기존 시간, 위상 정규화 방법은 유사도가 45주기
 이상부터 저하되는 반면, 제안한 정규화 방법은 안정적으로 유지되며 그림
 32처럼 분석되었다. 기존 주파수 정규화 방법은 제안한 방법과 일정하게 안
 정적으로 유지되지만, 제안한 방법보다 100주기에서 평균 유사도 비율이
 1.366% 낮게 분석되었다.

표 11. 유클리디언 거리에 의한 평균 유사도 비율 비교 분석

심전도 주기 수	정규화 전 평균 유사도 비율(%)	정규화 후 평균 유사도 비율(%)			
		시간, CC[27]	주파수, OBPF[36]	위상[37]	적응형 유사도 필터
1	93.774	94.300	95.630	91.7000	96.268
15	93.824	94.330	95.421	91.760	96.326
30	93.836	94.350	95.554	91.790	96.322
45	93.684	93.800	95.211	91.170	96.140
60	93.298	93.140	94.820	90.620	95.956
75	92.850	92.107	94.533	89.840	95.782
90	92.400	91.470	94.274	88.920	95.586
100	92.280	91.400	94.222	88.770	95.588

표 11은 정규화 전과 각 정규화 방법을 이용하여 유클리디언 거리에 의해 심전도 주기 수 증가에 따라 평균 유사도 비율을 비교 분석했다. 제안한 적응형




그림 33. 정규화 전 각 상태의 마할라노비스 거리 유사도

유사도 필터 방법을 이용할 경우, 기존 정규화 방법보다 유클리디언 거리에 의해 평균 유사도 비율이 높게 분석되었고 심전도의 형태학적 특징이 더욱 일치되었다.

그림 33은 정규화 전 마할라노비스 거리에 의해 심전도 주기 수가 증가함에 따라 정적 상태의 심전도 주기의 유사도는 상승하며 분석되는 반면, 동적 상태의 심전도 주기의 유사도는 45주기 이상부터 저하되며 분석되었다. 유클리디언 거리에 따른 유사도 분석과 일정하게 모션 아티팩트 영향으로 심전도 45주기 이상부터 평균 유사도가 저하되는 구간으로 분석된다. 모든 상태의 심전도 100주기 평균 유사도가 마할라노비스 거리에 의해 95.82%로 분석되었다. 기존 시간, 위상 정규화 방법은 유사도가 60주기 이상부터 저하되는 반면, 제안한 정규화 방법은 점차 상승하며 정규화 전 정적인 상태와 일정하게 그림 34처럼 분석되었다.




그림 34. 각 정규화 방법에 따른 마할라노비스 거리 유사도

기존 주파수 정규화 방법은 안정적으로 유지되지만, 제안한 방법보다 100

주기에서 평균 유사도 비율이 0.965% 낮게 분석되었다. 시간과 위상영역 정규화 방법들은 주파수 정규화 방법보다 더 낮게 분석되었다. 표 12는 정규화 전과 각 정규화 방법을 이용하여 마할라노비스 거리에 의해 심전도 주기 수 증가에 따라 평균 유사도 비율을 비교 분석했다.

표 12. 마할라노비스 거리에 의한 평균 유사도 비율 비교 분석

심 전 도 주 기 수	정규화 전 평균 유사도 비율(%)	정규화 후 평균 유사도 비율(%)			
		시간, CC[27]	주파수, OBPF[36]	위상[37]	적응형 유사도 필터
1	96.314	96.300	97.300	93.720	97.778
15	96.448	96.330	97.420	93.765	97.874
30	96.568	96.350	97.450	93.792	97.984
45	96.568	96.430	97.520	93.613	97.988
60	96.458	96.500	97.510	93.510	98.114
75	96.248	96.170	97.510	93.230	98.214
90	95.960	95.830	97.412	92.810	98.274
100	95.820	95.510	97.411	92.500	98.376

제안한 적응형 유사도 필터 방법을 이용할 경우, 기존 정규화 방법보다 마할라노비스 거리에 의해 평균 유사도 비율이 높게 분석되었고 심전도의 형태학적 특징이 더욱 일치되었다.

코사인 유사도에 의한 성능은 유사도 값 1부터 -1까지의 수를 백분율로 측정했다. 그림 35는 정규화 전 코사인 유사도에 의해 심전도 주기 수가 증가함에 따라 정적 상태의 심전도 주기의 유사도와 동적 상태의 심전도 주기의 유사도는 45주기 이상부터 저하되며 분석되었다.

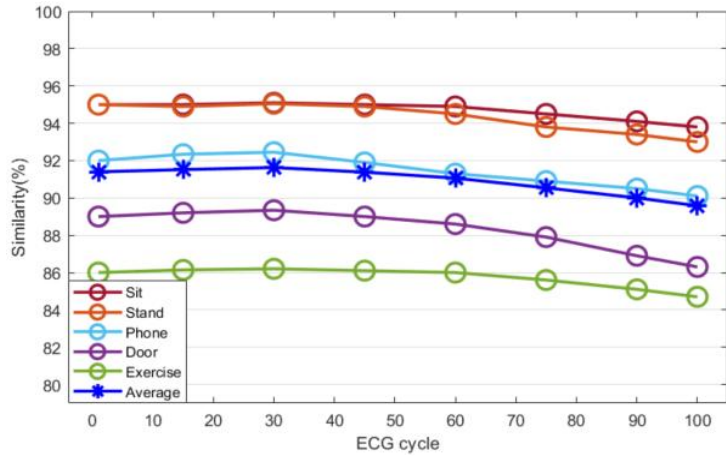


그림 35. 정규화 전 각 상태의 코사인 유사도

유클리디언 거리와 마할라노비스 거리에 따른 유사도 분석과 일정하게 모션 아티팩트 영향으로 심전도 45주기 이상부터 평균 유사도가 저하되는 구간으로 분석된다. 모든 상태의 심전도 100주기 평균 유사도가 코사인 유사도에 의해 89.58%로 분석되었다.




그림 36. 각 정규화 방법에 따른 코사인 유사도

그림 36은 기존 시간, 위상 정규화 방법은 유사도와 일정하게 제안한 정규화 방법도 60주기 이상부터 저하되며 분석되었다. 기존 주파수 정규화 방법은 시간, 위상 정규화 방법보다 높은 유사도로 분석되지만, 제안한 방법보다 100주기에서 평균 유사도 비율이 1.585% 낮게 분석되었다. 표 13은 정규화 전과 각 정규화 방법을 이용하여 코사인 유사도에 의해 심전도 주기 수 증가에 따라 평균 유사도 비율을 비교 분석했다. 제안한 적응형 유사도 필터 방법을 이용할 경우, 기존 정규화 방법보다 코사인 유사도에 의해 평균 유사도 비율이 높게 분석되었고 심전도의 형태학적 특징이 더욱 일치되었다.

표 13. 코사인 유사도에 의한 평균 유사도 비율 비교 분석

심전도 주기 수	정규화 전 평균 유사도 비율(%)	정규화 후 평균 유사도 비율(%)			
		시간, CC[27]	주파수, OBPF[36]	위상[37]	적응형 유사도 필터
1	91.400	91.300	93.208	90.041	94.200
15	91.516	91.515	93.420	90.155	94.308
30	91.628	91.831	93.717	90.273	94.488
45	91.380	91.712	93.828	90.371	94.612
60	91.060	91.405	93.633	89.930	94.590
75	90.540	91.073	93.218	89.428	94.448
90	90.000	90.401	92.734	88.533	94.096
100	89.580	89.724	92.221	87.811	93.806

유사도를 측정하는 각 종류에 따라 기존 방법과 제안한 방법을 통해 정규화된 심전도 주기들의 형태학적 특징이 일치되는 정도를 유사도 비율로 확인했

다. 확인 결과, 각 유사도 방법에서 정규화 전보다 제안한 방법으로 정규화
 때 유사도 성능은 평균 2% 향상되었다. 최대 유사도 성능으로 기존 정규화
 방법보다 제안한 정규화 방법이 유클리디언 거리에서 1.36%, 마할라노비스
 거리에서 0.97%, 코사인 유사도에서 1.6% 높게 분석되었다. 각 유사도 평가
 방법에 따라 동적 상태의 심전도 유사도가 45주기 이상부터 저하되며 분석되
 었다. 이는 모션 아티팩트 영향으로 심전도 45주기 이상부터 평균 유사도가
 저하되는 구간으로 분석된다.

유사도 측정 방법 중에서 유사도 성능 기준으로 마할라노비스 거리가 다른
 유사도 측정 방법보다 정규화 전과 후 모두 높은 유사도 성능으로 분석되며
 정규화 후 심전도 주기가 증가함에 따라 유사도 성능은 향상되었다. 이는 심
 전도의 형태학적 특징들이 직선거리와 각도보다 확률적 거리가 가깝게 분포
 되어 있다. 본 실험을 통해서 복합적 상태의 심전도 신호를 이용하여 제안한
 정규화 방법이 기존 정규화 방법보다 우수한 유사도 성능으로 분석되었다.

제3절 분해능 조정된 2D 스펙트로그램을 이용한 사용자 인식

본 절에서는 스펙트로그램 분해능 조정에 따른 인식 성능 분석, 기존 특징 추출 방법과 인식 성능 비교 분석, 기존 인식 시스템과 성능을 비교 분석하여 제안하는 사용자 인식 시스템의 우수성을 증명한다. 스펙트로그램을 이용한 인식 성능은 시간과 주파수 분해능을 조정하여 2D 스펙트로그램의 인식 성능을 각기 다른 DB에서 분석한다. 시간 분해능을 조정하는 TO(Time Overlap)와 주파수 성분 수 변화에 따라 인식 성능을 분석하기 위해 자체 취득한 CU-DB와 공개 DB인 MIT-BIH NSR, QT, European을 이용하여 7:3으로 학습 데이터와 인식 데이터로 구성했다. CU-DB의 학습 데이터는 12,600개(피험자 100명×정적인 상태 3 동작×42주기), 인식 데이터는 5,400개(피험자 100명×복합적 상태 6 동작×9주기)로 구성된다. MIT-BIH NSR DB의 학습 데이터는 2,520개(피험자 18명×140주기), 인식 데이터는 1,080개(피험자 18명×60주기)로 구성된다. QT DB의 학습 데이터는 14,700개(피험자 105명×140주기), 인식 데이터는 6,300개(피험자 105명×60주기)로 구성된다. European DB의 학습 데이터는 11,060개(피험자 79명×140주기), 인식 데이터는 4,740개(피험자 79명×60주기)로 구성된다. 스펙트로그램에서 시간의 분해능은 주파수 분해능과 상반되어 조정되기 때문에 시간 분해능을 증가하며 인식 성능을 분석한다. 시간 분해능은 주파수 성분 수와 원도 함수가 이동할 때 TO에 따라 결정되기 때문에 주파수 성분 수가 높을수록 TO가 낮을수록 시간 분해능이 높아진다.

Chun et al. [28]은 스펙트로그램 분해능을 조정하지 않고 고정된 0.02초 TO에 따라 변환했다. 샘플링 레이트는 200Hz이며 0.02초의 TO는 $200\text{Hz} \times 0.02\text{초}$ 에 의해 4로 설정된다. Abdeldayem et al. [50]은 스펙트로그램 분해능

을 조정하지 않고 고정된 0.015초의 TO에 따라 변환했다. 심전도의 샘플링 레이트는 200Hz이며 0.015초의 TO는 $200\text{Hz} \times 0.015\text{초}$ 에 의해 3으로 설정된다. 표 14는 고정된 각 TO로 분해능 조정되지 않는 2D 스펙트로그램과 시간 분해능이 최적화로 조정된 2D 스펙트로그램을 이용하여 심전도 주기 수 증가에 따라 인식 성능을 비교 분석했다. 제안한 분해능 조정된 2D 스펙트로그램 영상을 이용한 사용자 인식 성능은 기존 조정되지 않은 TO의 분해능 방법보다 모든 심전도 주기 수에서 높은 인식 성능으로 분석되었다.

표 14. 분해능 조정 전과 후의 인식 성능 비교

ECG cycle	2D Spectrogram		
	Non Resolution adjustment		Resolution adjustment
	TO= 4[28]	TO= 3[50]	
1	93.2%	94.9%	97.1%
2	93.1%	94.9%	97.2%
3	93.0%	95.0%	97.1%
4	92.8%	94.8%	97.0%
5	92.7%	94.6%	96.4%
6	92.4%	94.5%	96.3%
7	92.2%	93.2%	96.0%

분해능에 따라 인식 성능을 분석하기 위해 4개의 DB 모두 일정하게 TO와 주파수 성분 수를 조정했다. 스펙트로그램 변환 식(26)에서 샘플링 레이트로

주파수 성분 수를 결정하는 파라미터 N 과 심전도 주기 신호의 샘플 이동 파라미터 δ 에 따른 TO로 시간 분해능이 조정된다.

$$X[\delta T_s, \omega N] = \sum_{t=0}^{L-1} w[t]x[\delta + t]e^{-j\omega t} \quad (26)$$

그림 37은 TO가 낮아짐에 따라 각 DB의 인식 성능을 분석한 그래프이다. TO의 값을 일정하게 조정하고 최솟값 2일 때 인식 성능이 4개의 DB 모두 가장 높게 분석되고, 시간 분해능이 높고 주파수 분해능이 낮을 때 인식 성능이 향상되어 분석되었다.




그림 37. TO 변화에 따른 인식 성능

각 DB의 인식 성능은 CU-DB에서 97.1%, MIT-BIH NSR DB에서 100%, QT DB에서 98.1%, European DB에서 98.7%로 분석된다. 시간 분해능에 영향을 주는 주파수 성분 수를 증가시키며 각 DB의 인식 성능을 그림 38처럼 분석했다. 주파수 성분 수 N 이 4일 때 인식 성능이 4개의 DB 모두 향상되고 5부




그림 38. 주파수 성분 수 변화에 따른 인식 성능

더 일정하게 분석되었다. 특히, 주파수 성분 수가 증가할 때 인식 성능이 향상되며 일정한 주파수 성분 이상에서 인식 성능은 수렴되어 분석된다. 분해능 조정된 스펙트로그램을 이용하여 2D 영상 크기 변화에 따라 인식 성능과 학습 경과 시간을 그림 39처럼 동시에 분석했다.




그림 39. 영상 크기 조정에 따른 인식 성능 및 학습 경과 시간

영상의 크기는 8배, 4배, 2배, 원 영상, 1/2, 1/4, 1/8 일정한 비율로 조정된다. CNN에 의해 맥스 풀링으로 분해능 조정된 2D 스펙트로그램 원 영상을 이용하여 97.1% 인식 성능과 29초의 학습 경과 시간으로 분석되었다. 2D 스펙트로그램 영상 크기 조정으로 8배부터 1/4 영상 크기까지의 사용자 인식 성능은 2D 스펙트로그램의 합성곱 특징과 맥스 풀링에 의해 데이터 손실 없이 일정하게 유지되고, 학습 경과 시간은 6초 단축되었다. 1/4 영상의 크기 이후 2D 스펙트로그램 영상의 1/8 크기부터 학습 경과 시간을 2초 단축했지만, 인식 성능이 저하된다. 본 논문은 인식 성능이 유지되며 학습 경과 시간을 단축하는 1/4 영상 크기의 2D 스펙트로그램을 이용한다. 2D 스펙트로그램 영상이 맥스 풀링 층에서 데이터 손실 영향을 받는 정도를 확인하기 위해 필터를 조정했다. 조정한 맥스 풀링의 필터는 사용하지 않거나, $[1 \times 1]$, $[2 \times 2]$, $[3 \times 3]$, $[4 \times 4]$ 이고, 동시에 영상의 크기가 1/2, 1/4, 1/8로 축소될 때 인식 정확도로 데이터 손실되는 정도를 분석했다.

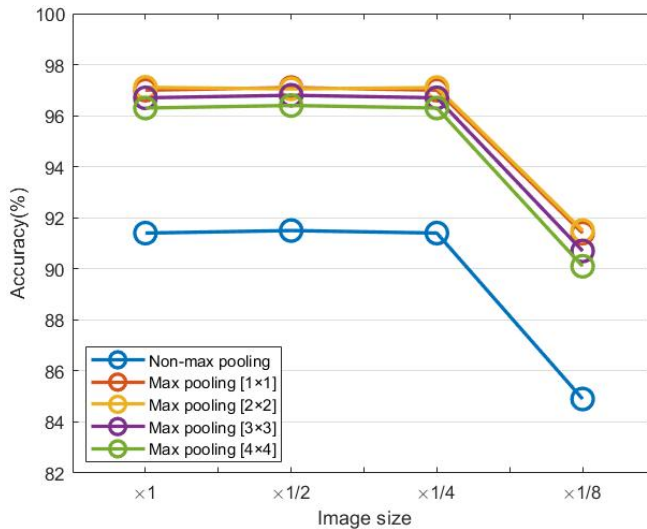


그림 40. 맥스 풀링 필터 조정에 따른 인식 정확도

그림 40은 영상 크기의 전 구간에서 맥스 풀링 필터가 $[2 \times 2]$ 까지 정확도가 일정하고 $[4 \times 4]$ 까지 저하되거나 맥스 풀링 층이 없을 때 더 낮게 분석되었다. 1/8 영상의 낮은 정확도는 맥스 풀링 층의 영향보다 영상의 크기가 축소됨에 따라 클래스를 분류하기 위한 특징들이 부족하여 인식 정확도가 낮게 분석되는 것으로 확인되었다.




그림 41. 정규화 전 기존, 제안한 특징을 이용한 인식 성능 비교

제안한 분해능 조정된 2D 스펙트로그램을 이용한 특징 추출 방법은 기존 다차원 특징 추출 방법을 이용하여 인식 성능을 비교 분석한다. 기존 다차원 특징 추출 방법은 EEMD와 MFCCs에서 진행되고 인식 성능을 검증하기 위해 CU-DB를 이용하여 심전도 주기 수 증가에 따라 평균 인식 성능으로 분석하였다[31][41]. 그림 41은 기존 다차원 특징 추출과 제안한 다차원 특징 추출 방법을 정규화 전 인식 성능을 비교 분석한 그래프이다. 심전도 주기 2에서 MFCCs 특징 추출 방법과 제안한 특징 추출 방법을 이용한 인식 성능이 가장 높게 분석되었으며 EEMD 특징 추출 방법은 주기 3에서 높게 되었고, 주기

4 이후부터 모두 조금씩 감소했다. 제안한 특징 추출 방법을 이용한 인식 성능은 주기 2에서 95.7%로 기존 특징 추출 방법보다 높게 분석되었고, EEMD는 주기 3에서 93.4%, MFCCs는 95.2%로 분석되었다.




그림 42. 정규화 후 기존, 제안한 특징을 이용한 인식 성능 비교

그림 42는 정규화 후 기존 다차원 특징 추출과 제안한 다차원 특징 추출 방법의 인식 성능을 비교 분석한 그래프이다. 심전도 주기 2에서 제안한 방법과 EEMD 특징 추출 방법을 이용한 인식 성능이 가장 높게 분석되었으며 MFCCs 특징 추출 방법은 주기 4에서 가장 높게 분석되었고, 주기 5 이후부터 모두 조금씩 감소했다. 제안한 특징 추출 방법을 이용한 인식 성능은 주기 2에서 97.1%로 기존 특징 추출 방법보다 높게 분석되었고, EEMD는 주기 2에서 95.1%, MFCCs는 주기 4에서 96.7%로 분석되었다. 모든 특징 추출 방법들이 정규화 전보다 후일 때 인식 성능이 평균 2% 향상되었으며 대체로 주기가 증가함에 따라 조금씩 저하되었다. 제안한 방법이 MFCCs보다 높게 분석되었으며, 주파수 영역에서 특징 추출하는 제안한 방법과 MFCCs 방법이

정규화를 고려하지 않아도 시간 영역 특징 추출 방법인 EEMD보다 높게 분석되었다.

제안한 사용자 인식 시스템의 신호처리 단계에서 제안한 정규화 방법과 특징 추출 단계에서 제안한 분해는 조정된 2D 스펙트로그램 다차원 특징 추출을 이용한 사용자 인식 시스템의 우수성을 확인하기 위해 기존 인식 시스템에 대한 인식 성능과 비교 분석하였다. 각 공용 DB 그룹들의 인식 성능들은 각 연구에서 제안한 인식 시스템으로부터 분석된 수치이고[51-58], 제안한 인식 시스템 성능과 비교 분석하였다. 그림 43은 인식 시스템의 성능을 비교한 그래프이다. 인식 성능은 각 공용 DB에서 단 차원, 다차원, 네트워크 기반 딥러닝을 이용한 인식 시스템과 제안한 2D 스펙트로그램을 이용한 인식 시스템 순서대로 비교 분석했다.




그림 43. 인식 시스템 성능 비교

인식 성능은 피형자 수에 영향을 받으며 피형자 수가 가장 낮은 MIT-BIH DB의 인식 성능 그룹부터 Arrhythmia DB, European DB, QT DB의 인식 성능 그룹 순서대로 높게 분석되었다. 피형자 수가 적은 MIT-BIH DB의 인식 성능 그룹에서 단 차원보다 다차원, 딥러닝의 인식 성능들은 0.1%, 0.2% 낮게 분

석되었으나 피험자 수가 많은 DB의 인식 성능 그룹에서는 단 차원 특징 추출을 이용한 인식 성능이 낮게 분석되었다. 기존 다차원 특징과 딥러닝에 의한 인식 성능은 유사하게 분석되었지만 제안한 2D 스펙트로그램을 이용한 인식 성능이 MIT-BIH DB에서 0.7%, QT DB에서 0.6%, European DB에서 0.6%, Arrhythmia DB에서 0.1% 우수하게 분석되었다.

표 15. 2D 스펙트로그램을 이용한 사용자 인식 시스템 성능 평가

DB	2D Spectrogram	Performance			
		Sen.	Spe.	Acc.	F1-s.
CU	One-dimensional	92.8%	95.7%	94.3%	94.9%
	Multidimensional	93.8%	97.2%	95%	95.3%
	2D convolution	96.1%	98.4%	97.1%	97.2%
MIT-BIH NSR	One-dimensional	98.9%	99.5%	99.2%	99.4%
	Multidimensional	100%	100%	100%	100%
	2D convolution	100%	100%	100%	100%
QT	One-dimensional	96.8%	93.2%	94.5%	94.8%
	Multidimensional	97.5%	94.9%	95.2%	95.7%
	2D convolution	98.2%	96.9%	98.1%	98.5%
European	One-dimensional	94.5%	95.8%	95.1%	95.6%
	Multidimensional	95.8%	97.2%	96.3%	96.8%
	2D convolution	98.1%	99.2%	98.7%	99.1%
Arrhythmia	One-dimensional	92.7%	94.9%	94.5%	95.2%
	Multidimensional	95.5%	96%	96.5%	96.7%
	2D convolution	98.2%	99.4%	99.1%	99.3%

제안한 2D 스펙트로그램을 이용하여 사용자 인식 시스템 모델을 평가하기 위해 민감도, 특이도, 정확도 성능을 각 DB에 따라 분석했고, 분해능 조정된 2D 스펙트로그램의 단 차원, 다차원 특징 벡터를 이용하여 KNN 기반 인식 성능과 딥러닝 기반 CNN에 의한 인식 성능을 표 15처럼 민감도, 특이도, 정확도, F1-score 순서대로 비교 분석했다. 분석 결과, 딥러닝 기반 CNN에 의해 2D 스펙트로그램의 합성곱 특징 벡터를 이용한 인식 성능이 단 차원과 다차원 구성된 특징 벡터보다 각 DB에서 모두 높게 분석됐다. 합성곱 특징 벡터를 이용한 인식 성능은 단 차원과 다차원 특징 벡터보다 CU-DB에서 2.8%, 2.1%, MIT-BIH DB에서 0.8%, 0%, QT DB에서 2.6%, 1.9%, European DB에서 3.6%, 2.4%, Arrhythmia DB에서 4.6%, 2.6% 높게 분석되었다.

본 논문에서는 제안한 다차원 특징 추출 방법이 우수함을 증명하기 위해 스펙트로그램의 분해능 조정에 따른 인식 성능 분석, 기존 다차원 특징 방법과 인식 성능 비교 분석, 기존 인식 시스템과 인식 성능을 비교 분석했다. 스펙트로그램의 시간 분해능을 조정하기 위해 TO의 수는 최소, 주파수 성분 수는 인식 성능이 수렴되는 값을 이용했을 때 인식 성능이 CU-DB와 공용 DB에서 최대로 분석되었다. 이는 시간에 따라 분포된 심전도의 형태학적 특징들이 스펙트로그램에서 시간 분해능이 높을 때 인식 성능을 향상할 수 있는 다차원 특징들로 확인하였다. 또한, 분해능을 최적화로 조정된 2D 스펙트로그램을 이용하여 제안한 정규화 방법을 적용했을 때 정규화 전보다 평균 2% 향상되어 분석되었다. 이는 정규화된 심전도를 이용한 다차원 특징 추출을 이용하면 인식 성능을 향상하는 다차원 특징들로 변환될 수 있다. 이에 따라 제안한 사용자 인식 시스템은 기존 인식 시스템과 각 공개 DB에서 비교했을 때 가장 우수하게 분석되었고 제안한 정규화, 다차원 특징 추출 단계가 포함된 인식 시스템은 인식 성능을 향상할 수 있는 기술로 증명하였다.

제5장 결론

본 연구는 심전도를 이용한 사용자 인식 시스템이 실생활에 적용되기 위해 동적 상태에서 심전도 신호가 취득될 때 발생하는 모션 아티팩트에 의해 인식 성능의 저하 문제, 다차원 특징에 의해 낮은 인식 정확도와 복잡한 네트워크에 의한 높은 시간 복잡성 문제를 해결하는 목적이 있다.

기존 정규화 방법들은 형태학적 특징을 고려하지 않거나 정규화를 위한 연산 과정이 복잡하고, 기존 다차원 특징 추출 방법들은 낮은 인식 정확도와 복잡한 네트워크 구조로 설계되었다. 본 연구는 인식 시스템의 전처리 단계에서 개인 고유의 형태학적 특징을 고려하여 적응형 유사도 필터 기반 정규화를 개발하였고 최적화로 분해능 조정된 2D 스펙트로그램 다차원 특징들을 낮은 히든 층 구조로 설계한 단일 CNN 네트워크로 활용하였다. 이에 따라, 아티팩트에 의해 발생하는 인식 성능의 저하 문제는 개인 고유의 형태학적 특징을 고려한 유사도 필터, 다차원 특징에 의해 낮은 인식 정확도는 분해능 조정된 2D 스펙트로그램, 복잡한 네트워크에 의한 높은 시간 복잡성 문제는 리사이즈된 입력 영상과 단일 네트워크로 해결하고자 하였다. 따라서 본 연구에서는 정적 및 동적 상태의 심전도를 취득하여 CU-DB로 구축하였고, 이를 적응형 유사도 필터 기반 정규화와 분해능 조정된 2D 스펙트로그램을 적용하였다. 본 연구에서 제안한 기법은 사용자 인식 시스템에서 심전도 신호의 잡음 제거 단계와 특징 데이터 분석 단계로 구성되고 사용자를 인식한다.

실생활을 고려하여 정적 상태에서 앉기, 눕기, 운동 후 앉기와 동적 상태에서 핸드폰 터치, 문 여닫기, 운동 중에 따라 심전도를 자체 취득한 CU-DB와 공개 DB인 MIT-BIH NSR, QT, European, Arrhythmia를 이용하여 제안한 정규화 방법과 다차원 특징 추출 방법의 성능을 기존 방법들과 비교 분석했

다. 기존 시간 CC, 주파수 OBPF, 위상 정규화 방법보다 제안한 정규화 방법의 평균 유사도 비율이 유클리디언 거리에서 4.18%, 1.36%, 6.81% 마할라노비스 거리에서 2.86%, 0.96%, 2.87% 코사인 유사도에서 4.08%, 1.58%, 5.99%로 높게 분석되었다. 이는 기존 정규화 방법보다 적응형 유사도 필터 기반 정규화된 정적 및 동적 상태의 심전도 형태학적 특징이 더욱 일치되었고 정규화 전보다 인식 성능이 평균 2% 개선되었다. 기존 EEMD와 MFCCs 다차원 특징 추출 방법보다 제안한 분해능 조정된 2D 스펙트로그램을 이용한 인식 성능이 CU-DB에서 2%, 0.4% 높게 분석됨에 따라 낮은 정확도의 문제를 해결했다. 제안한 2D 스펙트로그램을 이용한 인식 성능은 CU-DB에서 97.1%, MIT-BIH NSR DB에서 100%, QT DB에서 98.1%, European DB에서 98.7%로 분석되었다. 이는 기존 단 차원, 다차원, 네트워크 방법보다 최대 European DB에서 1.4%, 최소 Arrhythmia DB에서 0.1% 우수하게 분석되었다. 또한, 1/4 영상 크기의 2D 스펙트로그램을 이용하여 단일 네트워크 CNN에서 인식 성능이 유지되고 학습 경과 시간을 6초 단축하며 높은 시간 복잡성을 개선했다.

본 논문에서 실생활을 고려한 복합적 상태에서 취득한 심전도를 이용하여 사용자 인식 시스템 기반 연구를 진행했다. 복합적 상태의 심전도 DB를 통해 검증되었기 때문에 실생활에서 취득한 심전도 신호를 이용하면 적용할 수 있을 것으로 판단된다. 향후 과제로 지능형 차량을 위해 주행 실환경에 적용할 바이오인식 시스템과 딥러닝 기반 네트워크에서 심전도를 이용하여 인식 성능을 더욱 향상하기 위해 학습 데이터 수 증가, 네트워크 최적화와 경량 네트워크 설계 연구를 진행할 계획이다.

참고문헌

- [1] A. Burg, A. Chattopadhyay and K. Y. Lam, “Wireless communication and security issues for cyber-physical systems and the internet of things,” Proceedings of the IEEE, vol. 106, no. 1, pp. 38-60, Jan. 2018.
- [2] Y. H. Choi, “A company specializing in biometric systems: suprema,” Korea Investor Relations Service (KIRS), vol. 2020-155, Apr. 2020.
- [3] P. Drozdowski, C. Rathgeb, A. Dantcheva, N. Damer and C. Busch, “Demographic bias in biometrics: A survey on an emerging challenge,” IEEE Trans. Tech. Socie., vol. 1, no. 2, 89-103, Jun. 2020.
- [4] A. Dantcheva, P. Elia and A. Ross, “What else does your biometric data reveal? A survey on soft biometrics,” IEEE Trans. Inform. Foren. Secur., vol. 11, no. 3, pp. 441-467. Mar. 2016.
- [5] “Investigation of bio-information accident cases and countermeasures,” Financial Security Institute, Security Research Department, vol. 2016-010, Mar. 2016.
- [6] R. Das, E. Maiorana and P. Campisi, “EEG biometrics using visual stimuli: a longitudinal study,” IEEE Sign. Proc. Lett, vol. 23, no. 3, pp. 341-345, Mar. 2016.
- [7] G. H. Choi, H. Ko, W. Pedrycz, A. K. Singh and S. B. Pan, “Recognition system using fusion normalization based on morphological features of post-exercise ECG for intelligent biometrics,” Sensors, vol. 20, no. 24, pp. 1-16, Dec. 2020.
- [8] M. G. Kim and S. B. Pan, “Deep learning based on 1-D ensemble networks

- using ECG for real-time user recognition,” *IEEE Trans. Ind. Inform.*, vol. 15, no. 10, pp. 5656-5668, Oct. 2019.
- [9] S. Raj and K. C. Ray, “ECG signal analysis using DCT-based DOST and PSO optimized SVM,” *IEEE Trans. Instrum. Meas.*, vol. 66, no. 3, pp. 470-478, Jan. 2017.
- [10] A. Barros, D. Rosario, P. Resque and E. Cerqueira, “Heart of IoT: ECG as biometric sign for authentication and identification,” In *Proc. Int. Wirel. Communic. Mob. Comp. Conf. (IWCMC)*, pp. 307-312, Jun. 2019.
- [11] J. R. Pinto, J. S. Cardoso and A. Lourenco, “Evolution, current challenges, and future possibilities in ECG biometrics,” *IEEE Access*, vol. 6, pp. 34746-34776, Jun. 2018.
- [12] J. S. Kim, S. H. Kim and S. B. Pan, “Personal recognition using convolutional neural network with ECG coupling image,” *J. Ambient Intell. Humaniz. Comput.*, pp. 1-10, Jul. 2019.
- [13] T. M. Nazmy, H. El-Messiry and B. Al-Bokhity, “Adaptive neuro-fuzzy inference system for classification of ECG signals,” In *Proc. Int. Conf. Inform. Syst. (INFOS)*, pp. 1-6, Mar. 2010.
- [14] C. A. Steinberg, S. Abraham and C. A. Caceres, “Pattern recognition in the clinical electrocardiogram,” *IRE Trans. Biomed. Elect.*, vol. 9, no. 1, pp. 23-30, Jan. 1962.
- [15] E. Skordalakis, “Recognition of the shape of the ST segment in ECG waveforms,” *IEEE Trans. Biomed. Eng.*, vol. 10, pp. 972-974, Oct. 1986.
- [16] L. Biel, O. Pettersson, L. Philipson and P. Wide, “ECG analysis: a new approach in human identification,” *IEEE Trans. Instrum. Meas.*, vol. 50, no.

- 3, pp. 808-812, Jun. 2001.
- [17] D. Berwal, C. R. Vandana, S. Dewan, C. V. Jiji and M. S. Baghini, "Motion artifact removal in ambulatory ECG signal for heart rate variability analysis," *IEEE Sensors Journal*, vol. 19, no. 24, pp. 12432-12442, Sep. 2019.
- [18] C. H. Wu, W. X. Liu, M. S. Lin and J. J. Chen, "An ECG extraction and reconstruction system with dynamic EMG filtering implemented on an ARM chip," In *Proc. IEEE Int. Conf. Intell. Appl. Syst. Engin.(ICIASE)*, pp. 62-65, Apr. 2019.
- [19] Y. Zhong, L. Xu, L. Yan, Y. Shen and S. Wang, "Adaptive R-wave detection method in dynamic ECG with heavy EMG artifact," In *Proc. IEEE Int. Conf. Inform. Autom.*, pp. 83-87, Jun. 2012.
- [20] C. So-In, C. Phaudphut and K. Rujirakul, "Real-time ECG noise reduction with QRS complex detection for mobile health services," *Arabian J. for Sci. and Engr.*, vol. 40, no. 9, pp. 2503 -2514, May. 2015.
- [21] U. Satija, B. Ramkumar and M. S. Manikandan, "Automated ECG noise detection and classification system for unsupervised healthcare monitoring," *IEEE Jour. Biom. Heal. Inform.*, vol. 22, no. 3, pp. 722-732, Mar. 2017.
- [22] L. Smital, M. Vitek, J. Kozumplik and I. Provaznik, "Adaptive wavelet wiener filtering of ECG signals," *IEEE Trans. Biom. Eng.*, vol. 60, no. 2, pp. 437-445, Nov. 2012.
- [23] R. Vullings, B. De-Vries and J. W. Bergmans, "An adaptive Kalman filter for ECG signal enhancement," *IEEE Trans. Biom. Eng.*, vol. 58, no. 4, pp. 1094-1103, Dec. 2010.

- [24] S. Pouryayevali, S. Wahabi, S. Hari and D. Hatzinakos, “On establishing evaluation standards for ECG biometrics,” In Proc. IEEE Int. Conf. Acoust. Spee. Sig. Proces.(ICASSP), pp. 3774-3778, May. 2014.
- [25] J. S. Arteaga-Falconi, H. Al Osman and A. El Saddik, “ECG authentication for mobile devices,” IEEE Trans. Instrum. Meas., vol. 65, no. 3, pp. 591-600, Dec. 2015.
- [26] G. Zheng, H. Y. Zhang and S. Z. Ji, “ECG based identification under different physical status,” In Proc. Int. Conf. Mach. Lear. Cyber.(ICMLC) vol. 1, pp. 197-203, Jul. 2018.
- [27] S. J. Kang, S. Y. Lee, H. I., Cho and H. Park, “ECG authentication system design based on signal analysis in mobile and wearable devices,” IEEE Sign. Proc. Lett., vol. 23, no. 6, pp. 805-808, Jun. 2016.
- [28] S. Y. Chun, J. H. Kang, H. Kim, C. Lee, I. Oakley and S. P. Kim, “ECG based user authentication for wearable devices using short time Fourier transform,” In Proc. Int. Conf. Telecom. Sig. Proces.(TSP), pp. 656-659, Jun. 2016.
- [29] H. S. Choi, B. Lee and S. Yoon, “Biometric authentication using noisy electrocardiograms acquired by mobile sensors,” IEEE Access, vol. 4, pp. 1266-1273, May. 2016.
- [30] D. Sung, J. Kim, M. Koh and K. Park, “ECG authentication in post-exercise situation,” In Proc. Int. Conf. Eng. Med. Biol. Soc. (EMBC), pp. 446-449. Jul. 2017.
- [31] Z. Zhao, L. Yang, D. Chen and Y. Luo, “A human ECG identification system based on ensemble empirical mode decomposition”, Sensors, vol. 13,

- no. 5, pp. 6832-6864, 2013.
- [32] T. W. D. Shen, W. J. Tompkins and Y. H. Hu, "Implementation of a one-lead ECG human identification system on a normal population," *Jour. Eng. Comput. Innov.*, vol. 2, no. 1, pp. 12-21, Jan. 2011.
- [33] N. Belgacem, F. Bereksi-Reguig, A. Nait-Ali and R. Fournier, "Person identification system based on electrocardiogram signal using LabVIEW," *Int. Jour. Comp. Scien. Eng.*, vol. 4, no. 6, pp. 974-981, Jun. 2012.
- [34] S. Y. Chun, "Single pulse ECG-based small scale user authentication using guided filtering," In *proc. Int. Conf. In Biometrics(ICB)*, pp. 1-7, Jun. 2016.
- [35] M. Komeili, W. Louis, N. Armanfard and D. Hatzinakos, "On evaluating human recognition using electrocardiogram signals: From rest to exercise," In *proc. Canad. Conf. Elect. Comp. Eng. (CCECE)*, pp. 1-4, May. 2016.
- [36] T. Nobunaga, H. Tanaka, I. Tanahashi, T. Watanabe and Y. Hattori, "Optimised band-pass filter to ensure accurate ECG-based identification of exercising human subjects," *Electron. Lett.*, vol. 53, no. 4, pp. 222-224, Feb. 2017.
- [37] S. L. Lin, C. K. Chen, C. L. Lin, W. C. Yang and C. T. Chiang, "Individual identification based on chaotic electrocardiogram signals during muscular exercise," *IET Biom.*, vol. 3, no. 4, pp. 257-266, Dec. 2014.
- [38] S. Gutta and Q. Cheng, "Joint feature extraction and classifier design for ECG-based biometric recognition," *IEEE Jour. Biom. Heal. Inform.*, vol. 20, no. 2, pp. 460-468, Feb. 2015.
- [39] E. Bak, G. H. Choi and S. B. Pan, "ECG-based human identification system by temporal-amplitude combined feature vectors," *IEEE Access*, vol. 8, pp.

- 42217-42230, Feb. 2020.
- [40] H. Gurkan, U. Guz and B. S. Yarman, “A novel human identification system based on electrocardiogram features,” In Proc. IEEE Int. Symp. Sig. Circ. Syst. (ISSCS), pp. 1-4, Jul. 2013.
- [41] T. E. Chen, S. I. Yang, L. T. Ho and K. H. Tsai, et al., “MFCC feature extraction and KNN classification in ECG signals,” In Proc. Int. Conf. Inform. Tech. Comp. Elect. Engin.(ICITACEE), pp. 372-380, Sep. 2019.
- [42] G. Giannakakis, E. Trivizakis, M. Tsiknakis and K. Marias, “A novel multi-kernel 1D convolutional neural network for stress recognition from ECG,” In Proc. Int. Conf. Affec. Comp. Intell. Inter. Works.(ACIIW), pp. 1-4, Sep. 2019.
- [43] X. Xu, S. Jeong and J. Li, “Interpretation of electrocardiogram (ECG) rhythm by combined CNN and BiLSTM,” IEEE Access, vol. 8, pp. 125380-125388, Jul. 2020.
- [44] J. Pan and W. J. Tompkins, “A real-time QRS detection algorithm,” IEEE Trans. Biomed. Engin., vol. 3, pp. 230-236, Mar. 1985.
- [45] G. H. Choi, J. H. Jung, H. M. Moon, Y. T. Kim and S. B. Pan, “User authentication system based on baseline-corrected ECG for biometrics,” Intell. Autom. Soft Comp., vol. 25, no. 1, pp. 193-204, Mar. 2019.
- [46] G. H. Choi, E. S. Bak and S. B. Pan, “User identification system using 2D resized spectrogram features of ECG,” IEEE Access, vol. 7, no. 1, pp. 34862-34893, Mar. 2019.
- [47] S. Pathoumvanh, S. Airphaiboon, B. Prapochanung and T. Leauhatong, “ECG analysis for person identification,” In Proc. Int. Conf. Biomed. Eng., pp.

1-4, Oct. 2013.

- [48] Y. C. Yeh, “An analysis of ECG beats by using the mahalanobis distance method,” In Proc. Int. Conf. Innov. Comp. Inform. Cont.(ICICIC), pp. 1460-1463, Dec. 2009.
- [49] M. Li and X. Li, “Verification based ECG biometrics with cardiac irregular conditions using heartbeat level and segment level information fusion,” In Proc. IEEE Int. Conf. Acoust. Spe. Sig. Proces.(ICASSP), pp. 3769-3773, May. 2014.
- [50] S. S. Abdeldayem and T. Bourlai, “ECG-based human authentication using high-level spectro-temporal signal features,” In Proc. IEEE Int. Conf. Big Data, pp. 4984-4993, Dec. 2018.
- [51] C. Ye, B. V. K. V. Kumar and M. T. Coimbra, “Heartbeat classification using morphological and dynamic features of ECG signals,” IEEE Trans. Biomed. Eng., vol. 59, no. 10, pp. 2930-2941, Oct. 2012.
- [52] T. Ince, S. Kiranyaz and M. Gabbouj, “A generic and robust system for automated patient-specific classification of ECG signals,” IEEE Trans. Biomed. Eng., vol. 56, no. 5, pp. 1415-1426, May. 2009.
- [53] E. Alickovic and A. Subasi, “Medical decision support system for diagnosis of heart arrhythmia using DWT and random forests classifier,” J. Med. Syst., vol. 40, no. 4, pp. 1-12, Feb. 2016.
- [54] W. Louis, M. Komeili and D. Hatzinakos, “Continuous authentication using one-dimensional multi-resolution local binary patterns(1DMRLBP) in electrocardiogram biometrics,” IEEE Trans. Inform. Forens. Secur, vol. 1, no. 12, pp. 2818-2832, Dec. 2016.

- [55] S. Banerjee and M. Mitra, "Application of cross wavelet transform for ECG pattern analysis and classification," *IEEE Trans. Instrum. Meas.*, vol. 63, no. 2, pp.326-333, Sep. 2013.
- [56] O. S. Lih, E. Y. K. Ng and T. R. San, "Automated diagnosis of arrhythmia using combination of CNN and LSTM techniques with variable length heart beats," *Comp. Biol. Medic.*, vol. 102, pp. 278-287, Nov. 2018.
- [57] S. Kiranyaz, T. Ince and M. Gabbouj, "Real-Time patient-specific ECG classification by 1-D convolutional neural networks," *IEEE Trans. Biomed. Eng.*, vol. 63, no. 3, pp. 664-675, Aug. 2015.
- [58] U. R. Acharya, S. L. Oh and Y. Hagiwara, "A deep convolutional neural network model to classify heartbeats," *Comp. Biol. Medic.*, vol. 89, pp. 389-396. Oct. 2017.