



저작자표시 2.0 대한민국

이용자는 아래의 조건을 따르는 경우에 한하여 자유롭게

- 이 저작물을 복제, 배포, 전송, 전시, 공연 및 방송할 수 있습니다.
- 이차적 저작물을 작성할 수 있습니다.
- 이 저작물을 영리 목적으로 이용할 수 있습니다.

다음과 같은 조건을 따라야 합니다:



저작자표시. 귀하는 원저작자를 표시하여야 합니다.

- 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](#) 

2023년 8월

석사학위논문

LSTM과 Xception의 다차원 특징 융합
기반 심전도를 이용한 스트레스 분류에
관한 연구

조선대학교 대학원

전자공학과

송 철 호

LSTM과 Xception의 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류에 관한 연구

A Study on Stress Classification Using ECG Based on the
Multi-dimensional Feature Fusion of LSTM and Xception

2023년 8월 25일

조선대학교 대학원

전자공학과

송 철 호

LSTM과 Xception의 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류에 관한 연구

지도교수 반 성 범

이 논문을 공학석사학위신청 논문으로 제출함.

2023년 04월

조선대학교 대학원

전자공학과

송 철 호

송철호의 공학석사학위논문을 인준함

위원장	조선대학교 교수	<u>곽근창 (인)</u>
위원	조선대학교 교수	<u>최현식 (인)</u>
위원	조선대학교 교수	<u>반성범 (인)</u>

2023년 05월

조선대학교 대학원

목 차

제1장 서론	1
제1절 연구 배경 및 목적	1
제2절 연구 내용 및 방법	4
제2장 기존 심전도 신호를 이용한 스트레스 분류 기술 분석	6
제1절 1차원 특징을 이용한 스트레스 분류	6
제2절 2차원 특징을 이용한 스트레스 분류	9
제3장 제안하는 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류	14
제1절 심전도의 RR 간격 기반 이상치 신호 제거	15
제2절 심전도의 다차원 특징 융합을 이용한 스트레스 분류	20
1. 1차원 특징 데이터: HRV 특징 분석	21
2. 2차원 특징 데이터: STFT 기반 시간-주파수 특징 분석	22
3. 다차원 특징 융합을 이용한 스트레스 분류	23
제4장 실험 결과 및 분석	27
제5장 결론	38
참고문헌	40

표 목차

표 1. 기존 1차원 특징 정보 입력을 이용한 스트레스 분류 연구	7
표 2. 기존 2차원 특징 정보 입력을 이용한 스트레스 분류 연구	10
표 3. 사용된 주파수 대역의 HRV 특징 정보	22
표 4. WESAD Dataset의 심전도 데이터 내용	27
표 5. 실험 방식에 따른 성능 결과 비교	28
표 6. 특징 융합 방식에 따른 스트레스 분류 성능	32
표 7. LSTM 네트워크를 통해 분석된 특징 정보	33
표 8. Xception 네트워크를 통해 분석된 특징 정보	34
표 9. 특징 융합을 적용한 후 특징 정보	35
표 10. 기존 심전도 신호를 이용한 스트레스 분류 성능 비교	37

그림 목차

그림 1. 스트레스의 부정적 영향 사례	1
그림 2. R파 정점 검출 후 추출된 RR 간격 파형	5
그림 3. LSTM 네트워크에 입력되는 1차원 특징 벡터	5
그림 4. 심전도 신호	6
그림 5. HRV 특징을 이용한 스트레스 분류 연구 흐름도	8
그림 6. 심전도 신호의 스펙트로그램 이미지 변환 예시	10
그림 7. 시간 대역 및 주파수 대역에서 추출한 이미지 정보 예시	11
그림 8. 2차원 이미지 입력 예시: (a) 신호 이미지 (b) 이산 푸리에 변환 적용 이미지 (c) 가버 웨이블릿 변환 적용 이미지	12
그림 9. 연속 푸리에 변환 및 스케일로그램 변환 결과 이미지	13
그림 10. 제안하는 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류 흐름도	14
그림 11. 심장 주기가 반영되는 심전도의 형태학적 특징	16
그림 12. 잡음이 포함된 심전도 신호에 다양한 디지털 필터 적용 결과	17
그림 13. 잡음 제거 및 이상치 신호 제거 전처리 과정의 흐름도	17
그림 14. RR 간격 간 유사도 비교	19
그림 15. RR 간격 기반 유사도 비교를 통한 심전도의 이상치 신호 제거 과정	20
그림 16. 심전도 신호의 STFT 적용 및 스펙트로그램 변환	23
그림 17. 제안하는 다차원 특징 융합을 위한 네트워크 흐름도	25
그림 18. 가중치 평균 방식의 다차원 특징 정보 융합 과정	26
그림 19. 윈도우 길이에 따른 분할된 심전도 신호	29
그림 20. 윈도우 길이에 따른 네트워크 성능	30
그림 21. 심전도의 이상치 신호 제거 전·후 성능	31
그림 22. 다차원 특징 융합 적용에 따른 스트레스 분류 성능 결과	37

ABSTRACT

A Study on Stress Classification Using Electrocardiograms Based on the Multi-dimensional Feature Fusion of LSTM and Xception

Song, Cheol Ho

Advisor : Prof. Pan, Sungbum, Ph.D.

Department of Electronic Engineering

Graduate School of Chosun University

With the advancement of scientific technology and the rapid growth of the IT industry, human exposure to stress in the dynamic information society is on the rise. Prolonged exposure to stress poses a significant risk factor for various health issues such as cardiovascular diseases, compromised immune systems, and mood disorders. Therefore, research on stress classification is crucial in mitigating the adverse health outcomes associated with stress.

Current research on stress classification employs various approaches, ranging from self-report questionnaires to the utilization of biosignals. While self-report methods rely on subjective personal experiences and may suffer from bias and inaccuracy, utilizing biosignals allows for accurate

and objective analysis through quantitative data assessment. Commonly employed biosignals for stress classification include electrocardiograms(ECGs), electrodermal activity(EDA), blood volume pressure(BVP), pupil dilation(PD), and cortisol hormone levels. Among these, studies utilizing electrocardiograms, which offer insights into the body's autonomic nervous system response through heart rate variability analysis, have gained significant attention.

In existing research focusing on stress classification using electrocardiograms, digital filters are employed to mitigate signal noise. Additionally, stress is classified by analyzing feature information in a single-dimensional format. However, using digital filters to eliminate morphologically damaged electrocardiogram signals presents challenges. In the case of using only single-dimensional feature information, detailed and comprehensive analysis is not possible because there is a feature information area that cannot be analyzed in the corresponding dimension.

With these issues being addressed, this paper presents a novel stress classification method that addresses the limitations of existing techniques by leveraging the fusion of multi-dimensional features, employing Long Short-Term Memory(LSTM) and Xception networks, and effectively removing outlier signals from ECGs. We apply a two-fold approach to overcome the challenges associated with conventional stress classification methods utilizing ECGs. Firstly, outlier signals caused by motion artifacts are eliminated by detecting the R wave peak in the ECG and comparing the similarity between RR intervals. This innovative outlier removal technique surpasses the limitations of conventional noise removal methods relying on digital filtering. Secondly, we introduce multi-dimensional feature fusion to overcome the drawbacks of single-dimensional feature information. While one-dimensional features suffer from capturing frequency variations over

time, two-dimensional features need help in analyzing overall signal patterns, averages, and trends.

To address these issues, we extract nine heart rate variability(HRV) features from the ECG signal after outlier signal removal and input them as a one-dimensional feature vector into an LSTM network. Additionally, we utilize Short-Time Fourier Transform(STFT) to analyze the time-frequency information of the ECG signals and input the resulting spectrograms as two-dimensional images into an Xception network. Feature-level fusion is then applied according to feature information learned and analyzed by both networks. The proposed multi-dimensional feature fusion method effectively leverages the advantages of each dimension, enabling precise analysis and exhibiting high reliability in stress classification performance.

To evaluate the performance of the proposed stress classification method, we conducted experiments to assess the impact of window length variations for signal segmentation(5 seconds, 10 seconds, and 60 seconds), the effectiveness of outlier signal removal, and the influence of feature-level fusion. Ultimately, by removing outlier signals and utilizing a window length of 5 seconds for signal segmentation, along with multi-dimensional feature fusion employing a weighted average method, we achieved a stress classification performance of 99.51%, representing a significant improvement of over 1.25% compared to previous studies that relied solely on single-dimensional feature information from electrocardiograms. The results present the efficacy of the proposed stress classification method, demonstrating its potential to address existing limitations and achieve high-performance stress classification.

제1장 서론

제1절 연구 배경 및 목적

IT 산업의 발달로 급변하는 현대 사회에서 인류의 스트레스 노출은 가속화되고 있다. 스트레스는 개인이 부담감을 느끼는 정신적, 육체적 자극에 대한 복잡한 생리적, 심리적 반응을 말한다[1]. 이러한 스트레스는 신체적, 정신적 건강에 수많은 부정적인 영향을 미치고 있다[2]. 단기적인 스트레스는 개인의 성과를 향상시킬 수도 있지만, 지속적인 스트레스는 그림 1과 같이 심혈관 질환, 면역 체계 약화, 기분 장애 등 여러 가지 건강 문제를 유발할 수 있다[3-4]. 따라서 개인이 스트레스를 보다 효과적으로 관리하고, 질병 및 질환의 위험을 완화하기 위해 최적화된 프로그램이나 치료를 개발하는 데 스트레스 상태를 정확하게 분류하고 정량화하는 연구가 필요하다[5-7].



그림 1. 스트레스의 부정적 영향 사례

수년에 걸쳐 연구자들은 ‘자가 보고(Self-reporting) 설문지’에서 ‘생체신호’에 이르기까지 다양한 접근 방식을 통해 스트레스 분류를 연구했다. 자가 보고 기술은 개인의 주관적인 스트레스 경험에 대한 귀중한 통찰력(Valuable insights)을 제공하지만 편향되고 부정확할 수 있는 단점이 있다[8]. 반면 생체신호를 이용한 방법은 스트레스 분류에 대한 보다 객관적인 평가를 제공한다.

스트레스 분류를 위해 이용되는 대표적인 생체신호로는 심전도, 전기적 피부 반응, 혈압, 동공 확장, 코르티솔 수치 등이 있다. 이러한 생체신호는 개인 또는 그룹 간에 비교적 쉽게 분석할 수 있는 정량적 데이터를 생성하여 강력한 통계 분석을 용이하게 한다[9]. 하지만 각 생체신호가 갖는 잠재력에도 불구하고 정확도와 신뢰성은 환경 영향, 주관적 편향 등과 같은 다양한 요인에 의해 제한될 수 있다. 전기적 피부 반응은 습도 및 온도와 같은 환경 요인에 민감하며 동공 확장은 조명, 피로와 같은 다양한 요인의 영향을 받는다. 혈압은 지속적인 모니터링이 어렵고, 코르티솔 수치는 침습적 절차가 필요하며 음식 섭취와 같은 요인의 영향을 받는다[10-12]. 이러한 단점을 보완하기 위해 심장의 전기 활동을 기록하는 심전도가 스트레스 분류를 위한 유망한 도구로 부상했다. 심전도는 비침습성, 사용 용이성 및 지속적인 실시간 모니터링 기능을 포함하여 다른 생체신호에 비해 다양한 이점을 제공한다. 또한 심전도 파생 매개변수인 심박 변이도(HRV, Heart Rate Variability)는 스트레스에 대한 신체의 반응을 반영하는 자율 신경계(ANS, Autonomic Nervous System)의 활동에 대한 풍부한 정보를 제공한다.

스트레스 분류를 위한 심전도의 심박 변이도 분석은 연속적인 심장박동 사이의 시간 간격 변화에 대한 분석이며 심전도가 갖는 특성에 기반한다. 심전도의 파형은 서로 다른 심장 주기 단계에 해당하는 P파, QRS 복합체 및 T파와 같은 별개의 파동으로 구성된다. 심전도는 이러한 파동이 각 심장박동과 함께 규칙적인 패턴으로 반복되기 때문에 주기적인 특성을 가지고 있다. 이러한 심전도의 파형과 그 모양 사이의 시간 간격은 심장의 기능과 건강 상태에 대한 중요한 정보를 제공한다.

대표적으로 R파 정점 간의 시간 간격 변화에 기반한 심박 변이도 분석은 다양한 심장 질환을 진단하고 스트레스 수준을 평가할 수 있어 스트레스 분류에 유용한 도구이다[13]. 그러나 스트레스 분류의 정확성과 신뢰성에 영향을 미치는 모션 아티팩트(Motion Artifact)에 민감하다. 모션 아티팩트는 심전도 신호에 반영되는 피험자의 움직임, 외부 진동 등으로 인해 발생하는 교란을 말한다. 이러한 교란은 심전도 신호의 주기적 특성을 훼손하며, 심박 변이도 분석에 필수적인 R파 정점을 감지하는데 오류를 일으킨다. 이는 연속적인 심장박동 사이의 시간 간격(RR 간격) 계산에 부정확성을 유발하여 편향되거나 신뢰할 수 없는 심박 변이도 추정치를 초래한다[14-15]. 따라서, 심전도를 이용한 정확한 스트레스 분류를 위해 모션 아티팩트에 의한 이상치 신호 제거가 필요하다.

기존의 심전도를 이용한 스트레스 분류 연구들은 단일 차원의 특징을 사용한 모델로 진행하였다. 이는 스트레스 관련 생리적 변화의 전체적인 복잡성을 포착하기 어렵고 특정 측면에 편향되어 데이터에 대한 오분류 및 성능 저하를 야기한다. 즉, 단일 차원의 특징만을 이용하는 것은 스트레스 분류를 위한 모델의 무능력으로 인해 차선의 분류 정확도를 초래하며 최적의 성능을 나타낸다[16]. 따라서, 심전도에 반영된 복잡한 스트레스 패턴 정보를 정확하게 분석하기 위해 다차원의 특징 정보를 분석할 필요가 있다.

본 논문은 생체신호 중 하나인 심전도(ECG, Electrocardiogram)를 이용하여 높은 정확도로 스트레스를 분류 함으로써 이 분야에서 연구 및 실제 적용을 위한 새로운 길을 여는 것을 목표로 한다.

제2절 연구 내용 및 방법

심전도를 이용한 스트레스 분류 성능을 개선하려면 보다 정확하고 신뢰할 수 있는 양질의 데이터 정보가 필요하며 이를 위해 데이터의 다양한 측면을 고려해야 한다. 심전도 신호는 기록하는 중 외부 진동, 피험자 움직임으로 인해 발생하는 모션 아티팩트에 의해 원치 않는 영향을 받을 수 있다. 모션 아티팩트는 심전도 신호의 주기적 특성을 훼손하고 신호를 왜곡시켜 이상치 신호를 생성한다. 이는 정확한 측정값을 얻거나 신호 분석 및 해석에 영향을 미쳐 스트레스 분류를 어렵게 한다. 스트레스는 개인마다 다르게 영향을 미치는 복잡하고 다면적인 현상이다. 또한 생리학적, 심리적 요인도 스트레스 반응의 다양성에 기여한다. 이러한 복잡한 정보를 포함하는 스트레스 상태가 반영된 심전도 분석 시 단일 차원의 특징 정보는 스트레스 분류에 대한 포괄적인 이해를 제공하지 못한다.

본 논문에서는 신호의 주기적 특성이 훼손되어 정확하고 신뢰할 수 있는 분석이 어려운 문제를 해결하기 위해 모션 아티팩트로 인한 심전도의 이상치 신호를 제거한다. 심전도의 이상치 신호 제거는 신호에서 비정상적이거나 불규칙한 데이터 포인트를 식별하여 제거하는 과정을 말하며 제거된 후의 신호는 주기적 특성을 유지해야 한다. 이는 그림 2와 같이 심전도의 R파 정점 검출 후 연속되는 R파 정점 간 파형의 유사도 비교를 통해 이상치 신호 검출 및 제거가 가능하다.

다음으로 단일 차원의 특징 정보만을 사용했을 때, 스트레스 상태의 복잡한 정보를 분석한 결과를 신뢰하기 어려운 단점이 있다. 따라서, 스트레스 상태를 포괄적이고 면밀하게 분석할 수 있는 특징 정보 융합 적용을 제안한다. 심전도의 시간 대역과 주파수 대역에서 HRV 특징을 추출하여 그림 3과 같이 1차원의 특징 벡터 형태로 LSTM(Long Short Term Memory) 네트워크에 입력한다. 또한 STFT(Short Time Fourier Transform)를 이용하여 시간-주파수 영역을 분석하여 2차원의 스펙트로그램 변환 이미지 형태로 Xception 네트워크에 입력한다. 각 네트워크의 완전

연결 계층의 출력을 이용한 특징 수준 융합을 적용한다.

본 논문의 구성은 다음과 같다. 1장의 서론에 이어 2장에서는 기존 심전도 신호를 이용한 기술에 대해 분석한다. 3장에서는 본 논문에서 제안하는 심전도 신호의 이상치 신호 제거 및 다차원 특징 융합 기반의 스트레스 분류에 관해 설명한다. 4장에서는 제안하는 스트레스 분류 시스템에 대한 실험방법 및 결과를 분석하고 5장에서 결론에 대해 논한다.

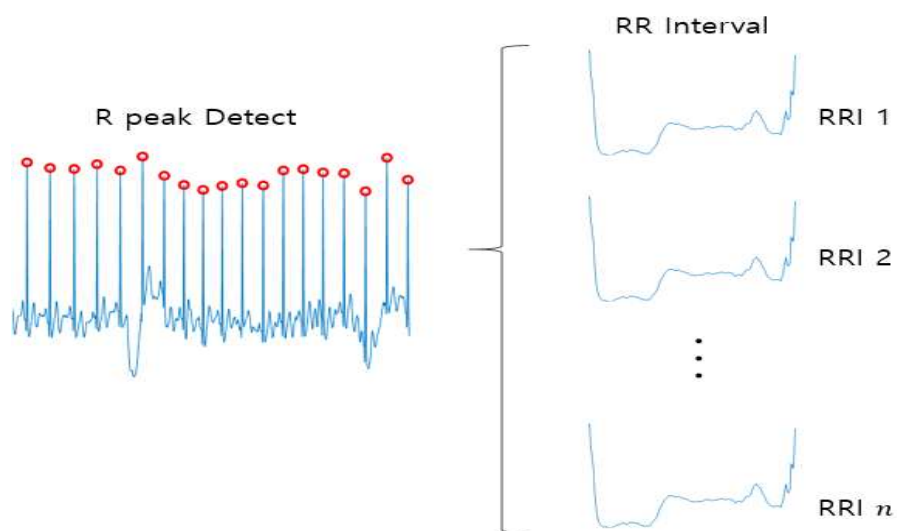


그림 2. R파 정점 검출 후 추출된 RR 간격 파형

Sequence_1	mHR_1	mRR_1	RMSSD_1	nHF_1	HF_1	LF_1	VLF_1	dLFHF_1	SVI_1
Sequence_2	mHR_2	mRR_2	RMSSD_2	nHF_2	HF_2	LF_2	VLF_2	dLFHF_2	SVI_2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
Sequence_n	mHR_n	mRR_n	RMSSD_n	nHF_n	HF_n	LF_n	VLF_n	dLFHF_n	SVI_n

그림 3. LSTM 네트워크에 입력되는 1차원 특징 벡터

제2장 기존 심전도 신호를 이용한 스트레스 분류 기술 분석

본 장에서는 기존 심전도 신호를 이용한 심박 변이도 분석 기반 스트레스 분류 연구와 2차원 특징 정보를 입력으로 하는 스트레스 분류 연구에 적용된 기술에 대해 분석한다. 심전도는 심장박동의 주기 중에 일어나는 심장의 전기적 활동 상태를 그래프상에 나타낸 것을 의미한다. 심전도 신호는 그림 4와 같으며 P파, QRS Complex 및 T파로 표시된 서로 다른 파동으로 구성되며 이를 한 주기로 하여 연속적으로 반복되는 주기적 특성을 나타낸다[17].




그림 4. 심전도 신호

제1절 1차원 특징 입력을 이용한 스트레스 분류

심전도 신호의 심박 변이도 분석을 이용한 스트레스 분류 연구는 심전도의 RR 간격 간 시간 변화량을 분석하여 연산을 통한 HRV 매개변수를 특징으로 사용한다. 심박 변이도를 통해 신체의 자율 신경계 반응을 통찰할 수 있으며, 스트레스 분류

연구에 유용한 도구로 사용된다. 표 1은 1차원 형태의 특징 정보를 이용하여 스트레스 분류를 진행한 연구에 관한 내용을 나타낸다.

표 1. 기존 1차원 특징 정보 입력을 이용한 스트레스 분류 연구

저자	데이터 베이스	ECG 입력	전처리	특징 추출	분류기	성능(%)
S. Mekruksavanich et al. [18]	WESAD [19]	1-D	버터워스 필터	분할된 신호	StressNext	87.1
P. Schmidt et al. [19]	WEASD	1-D	대역통과 필터	HRV	LDA	85.44
S.T. Chandrasekaran. et al. [20]	WESAD	1-D	-	HRV	축적 컴퓨팅, 로지스틱 회귀	93
N. Munla et al. [21]	Drive [22]	1-D	대역통과 필터	HRV	SVM-RBF	83.33

Mekruksavanich[18]의 연구에서 WESAD(Wearable Stress and Affect Detection) Dataset의 심전도 데이터로 실험을 진행하여 버터워스 필터와 최소-최대 정규화를 적용하여 전처리를 진행했다. 여기서 제안된 StressNext 네트워크를 이용하여 87.10%의 분류 성능을 나타냈다. Schmidt[19]의 연구에서는 WESAD Dataset의 심전도 신호 잡음 제거를 위해 대역통과필터를 적용하였으며, pNN50, nLF, nHF, mHR 등의 HRV 특징을 추출하였다. 추출된 특징 정보를 기반으로 LDA(Linear Discriminant Analysis) 분류기를 이용하여 85.44%의 스트레스 분류 성능을 보였다. Chandrasekaran[20]의 연구는 심전도 신호에 전처리를 적용하지 않고 HRV 특징을 추출하였다. 추출된 HRV 특징은 SDNN, RMSSD, NN50 등 총 5개를 추출하였으

며 추가적으로 NN50, pNN50, SDNN을 합한 값을 특징으로 이용하였다. SDNN은 시간 범위에서 전체 RR 간격의 표준편차를 의미한다. 주로 24시간에 걸쳐 계산되기 때문에 인위적으로 분할된 짧은 길이의 심전도에서 정량화하기에 적합하지 않은 특징이 있다. RMSSD는 연속되는 RR 간격 차이에 대한 제곱의 합을 평균하여 제곱근으로 표현한 것이다. 이는 짧은 길이의 심전도에서 심박변이 요소를 잘 나타내며, 부교감 신경 활동 정도를 나타낸다. NN50은 연속되는 RR 간격의 차이가 50ms를 초과하는 RR 간격의 개수를 뜻하며, 이를 백분율로 나타낸 것이 pNN50이다. 이 변수들은 짧은 길이의 심전도에서 심박 변이 요소를 반영하며, 부교감신경 활성을 나타내는 지표이다[23]. 축적 컴퓨팅과 로지스틱 회귀 방법을 이용하여 93%의 성능을 나타냈다. Munla[21]의 연구에서는 MIT-BIH에서 제공하는 Drive 공개 데이터베이스를 이용하여 그림 5[21]와 같은 흐름의 연구를 진행하였다.

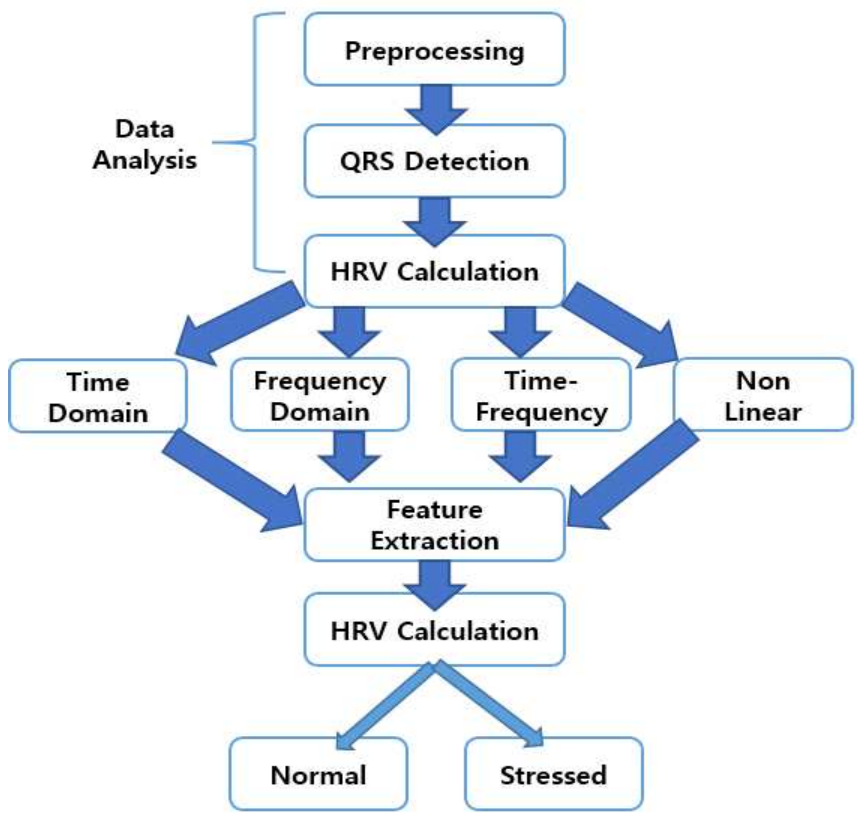


그림 5. HRV 특징을 이용한 스트레스 분류 연구 흐름도

심전도에 포함되는 60Hz의 근육 잡음 및 간섭 잡음을 줄이기 위해 대역 통과 필터를 이용하였다. 이후 심전도의 Pan&Tompkins 알고리즘을 통해 QRS Complex를 검출 후 R파 정점을 검출하였으며 이를 기반으로 HRV 특징을 추출하였다. 시간 및 주파수 대역에서 평균 심박동수를 의미하는 mHR을 포함하여 SDNN, VLF, LF 등 총 12개의 HRV 매개변수를 이용하였다. 분류기는 RBF 커널을 이용하는 SVM을 통해 83.33%의 스트레스 분류 성능을 나타냈다.

1차원의 특징 벡터를 분류기의 입력으로 사용하는 기존의 심전도를 이용한 스트레스 분류 연구에서는 전처리 단계에서 주로 디지털 필터링을 통한 잡음을 제거하였다. 또한 특징 추출 단계에서 시간 및 주파수 대역의 심박 변이도 분석을 통해 다양한 HRV 매개변수를 이용하였다.

제2절 2차원 특징 입력을 이용한 스트레스 분류

본 절에서는 심전도에서 추출된 특징 정보를 2차원의 형태로 네트워크에 입력한 스트레스 분류 연구에 대해 분석한다. 많은 연구에서 이용되는 특징 정보의 2차원 형태는 전처리 된 심전도 신호의 이미지 형태와 푸리에 변환(Fourier Transform)을 적용하여 시간-주파수 대역을 분석한 형태가 있다. 표 2는 기존의 2차원 특징 정보를 이용하여 스트레스 분류를 진행한 연구에 관한 자세한 내용을 나타낸다.

표 2. 기존 2차원 특징 정보 입력을 이용한 스트레스 분류 연구

저자	데이터 베이스	ECG 입력	특징 추출	분류기	성능(%)
L. Liakopoulos et al. [24]	WESAD	2-D	Spectrogram	CNN	96.79
M. G. Kang et al. [25]	WEASD, ST change [26]	2-D	Signal Image, FFT	CNN-LSTM	94.13 98.26
Z. Ahmad et al. [27]	자체 취득	2-D	GWT, DWT, Signal Image	CNN	85.45
M. Amin et al. [28]	Drive	2-D	CWT, Scalogram	Xception	98.11

Liakopoulos[24]의 연구는 WESAD Dataset의 심전도 데이터에 1분의 윈도우 길이를 적용하여 신호를 분할 하였다. 분할된 심전도 신호를 스펙트로그램(Spectrogram) 변환을 통해 그림 6[24]과 같이 2차원 이미지 형태를 구성하였다. 구성된 2차원 이미지를 CNN(Convolutional Neural Network) 네트워크에 입력하여 스트레스 분류 결과 96.79% 성능을 보였다.




그림 6. 심전도 신호의 스펙트로그램 이미지 변환 예시

Kang[25]의 연구에서는 WESAD Dataset과 ST Change Database를 혼합하여 사용한다. 잡음 제거를 위해 150Hz 차단 주파수를 갖는 저역 통과 필터(Low Pass Filter)를 적용하였다. 심전도의 R파와 S파 차이를 기반으로 스트레스 상태의 정보를 분류하였다. 네트워크 입력을 위한 2차원의 이미지 데이터는 시간 대역과 주파수 대역에서 분석되었다. 시간 대역에서 심전도 신호의 파형을 이미지로 표현하였고, 주파수 대역에서 고속 푸리에 변환(FFT, Fast Fourier Transform) 적용 후 스펙트로그램 변환 이미지로 나타났다. 시간 대역과 주파수 대역에서 나타낸 특징 정보의 2차원 이미지 형태는 그림 7[25]과 같다. 스트레스 분류 성능을 확인하기 위해 CNN-LSTM을 이용하였으며, 분류 성능 결과 시간 대역에서 94.13%, 주파수 대역에서 98.26%의 성능을 나타냈다.

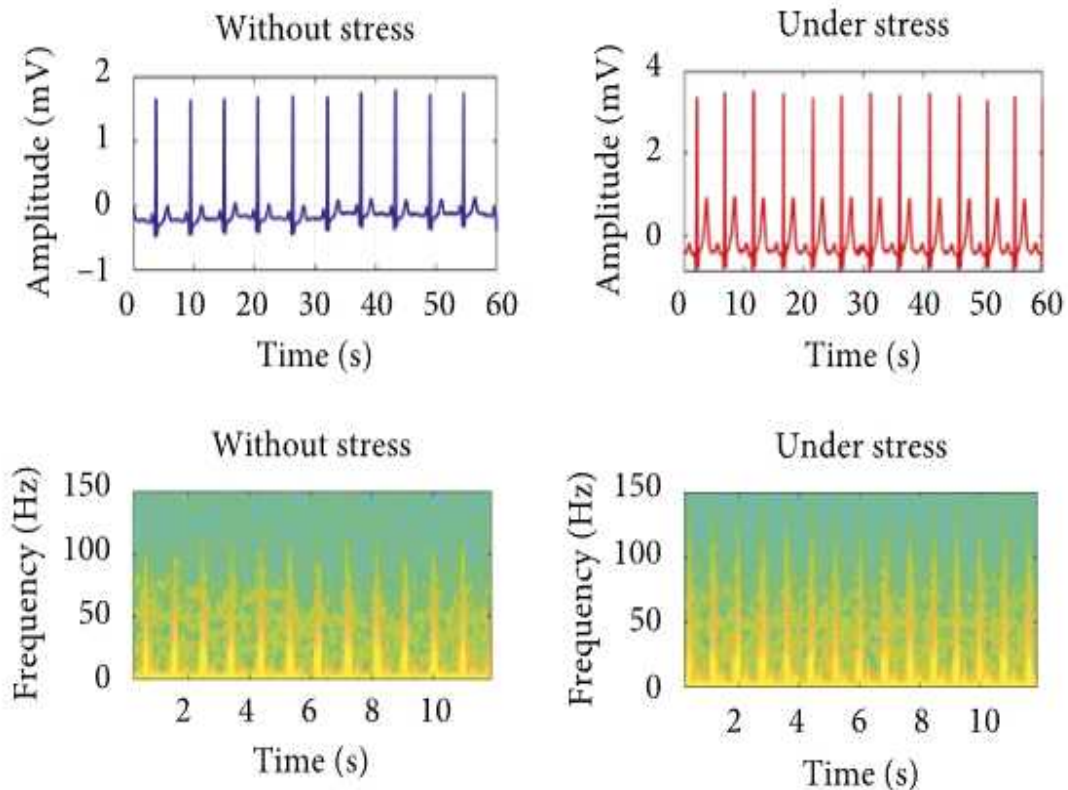


그림 7. 시간 대역 및 주파수 대역에서 추출한 이미지 정보 예시

Ahmad[27]의 연구는 6분간의 롤러코스터 시뮬레이션 환경의 스트레스 환경을 조성하여 15명의 피험자에게서 심전도를 자체 취득한 데이터를 이용하였다. 네트워크 입력을 위한 2차원의 이미지 형성은 신호 이미지, 이산 푸리에 변환(Discrete Fourier Transform), 가버 웨이블릿 변환(Gabor Wavelet Transform) 3가지로 진행하였다. 심전도로부터 신호 이미지 형성은 심전도의 연속적인 RR 간격을 시계열 세그먼트로 나열하여 이미지로 표현하였다. 공간 도메인 이미지를 주파수 도메인 이미지로 변환하기 위해 이산 푸리에 변환을 적용하여 이미지로 나타냈다. 또한 시간-주파수 대역 분석을 위해 가버 웨이블릿 변환을 적용하였으며 이미지로 변환된 3가지의 입력 형태는 그림 8[27]과 같다. 스트레스 분류를 위해 CNN 네트워크를 사용하였으며, 3가지 이미지 입력에 대해 결정 수준 융합을 진행하여 85.45%의 성능을 나타냈다.

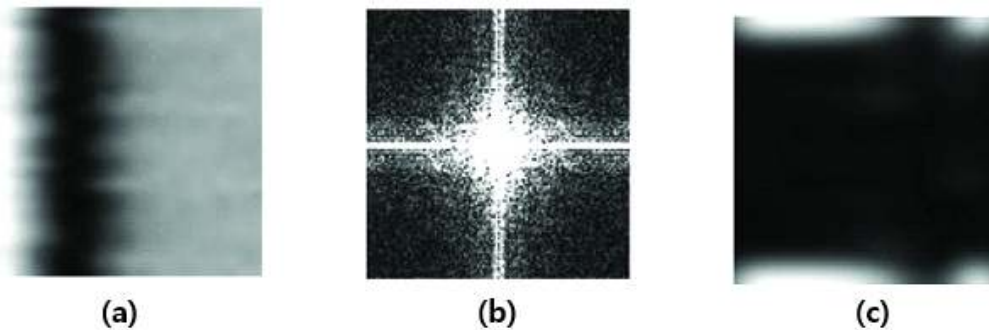


그림 8. 2차원 이미지 입력 예시: (a) 신호 이미지 (b) 이산 푸리에 변환 적용 이미지 (c) 가버 웨이블릿 변환 적용 이미지

Amin[28]은 운전자의 건강으로 인한 위험을 줄이기 위해 운전자의 스트레스 감지 연구를 진행하였다. 이를 위해 Physionet에서 제공하는 공용 데이터베이스인 Drive Database를 이용하였다. 전처리 단계에서 잡음 제거를 위해 0.5~100Hz 버터워스 대역의 대역 통과 필터와, 50Hz의 노치 필터(Notch Filter)를 적용하였다. 특징 추출 단계에서 심전도 신호의 시간-주파수 구성 요소 분석을 위해 연속 웨이

블릿 변환(Continuous Wavelet Transform)을 통해 분석하였으며 스케일로그램 (Scalogram)변환을 통해 그림 9[28]와 같이 이미지 형태의 입력을 구성하였다.

기존 심전도를 이용한 스트레스 분류 연구들은 전처리 단계에서 잡음 제거를 하지 않거나, 디지털 필터링을 통한 잡음 제거를 적용하였다. 하지만 이러한 전처리 방식은 심전도의 주기적 특성이 훼손된 이상치 신호가 제거되지 않으며, 이는 스트레스 분류 성능의 저하를 야기한다. 또한 스트레스 상태를 포함하는 심전도를 분석 후 1차원과 2차원 각각의 단일 차원 특징 정보를 이용하여 스트레스 분류 성능을 확인하였다. 다만 단일 차원의 특징 정보만을 이용하는 경우 심전도에 포함된 스트레스 정보를 정확하게 분석하지 못한다. 즉, 1차원의 특징 정보는 신호 전체의 추세나 평균과 같은 정보를 분석할 수 있지만 시간 경과에 따른 주파수 변화 정보는 분석이 불가하다. 반대로 2차원 형태의 특징 정보는 시간이 지남에 따라 변화하는 주파수 정보를 분석할 수 있지만, 1차원의 특징 정보를 통해 분석할 수 있는 정보에 대한 통찰이 불가하다. 따라서 복잡한 정보를 내포하는 스트레스 상태의 심전도를 정확하게 분석하기 위해서는 1차원과 2차원 형태의 특징 정보를 아우르는 다차원 특징 융합을 통한 분석이 필요하다.

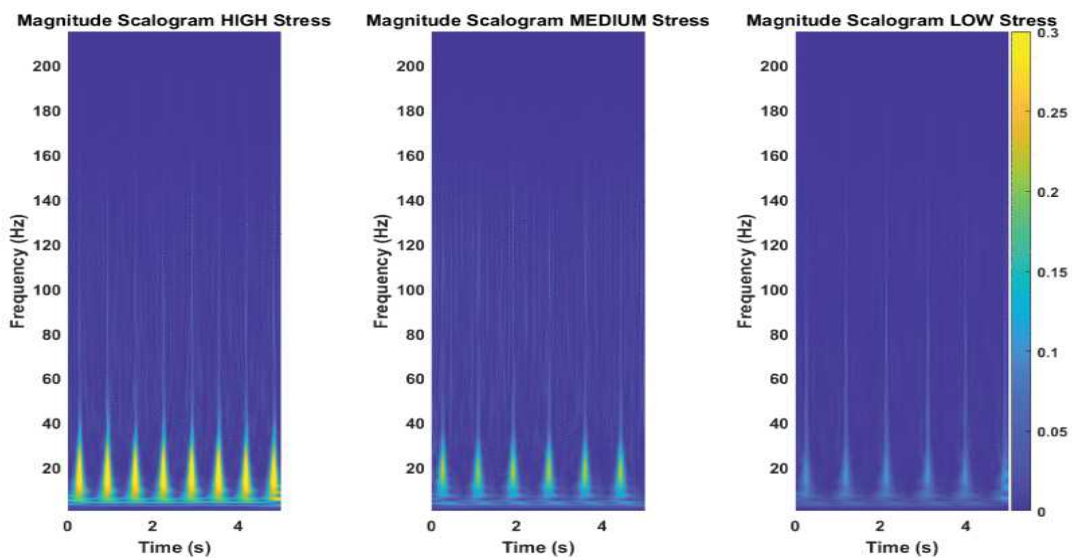


그림 9. 연속 푸리에 변환 및 스케일로그램 변환 결과 이미지

제3장 제안하는 다차원 특징 융합 기반 심전도를 이 용한 스트레스 분류

본 장에서는 모션 아티팩트로 인한 잡음이 제거되지 않아 심전도의 주기적 특성이 상실된 문제를 해결하기 위해 심전도 신호의 이상치 신호를 제거하는 전처리 방법과 복잡한 스트레스 상태의 면밀한 분석을 위해 1차원의 특징 정보와 2차원의 특징 정보의 특징 수준 융합을 적용한 스트레스 분류 방법에 대해 설명한다. 그림 10은 본 논문에서 제안하는 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류에 대한 전체적인 흐름도를 나타낸다.

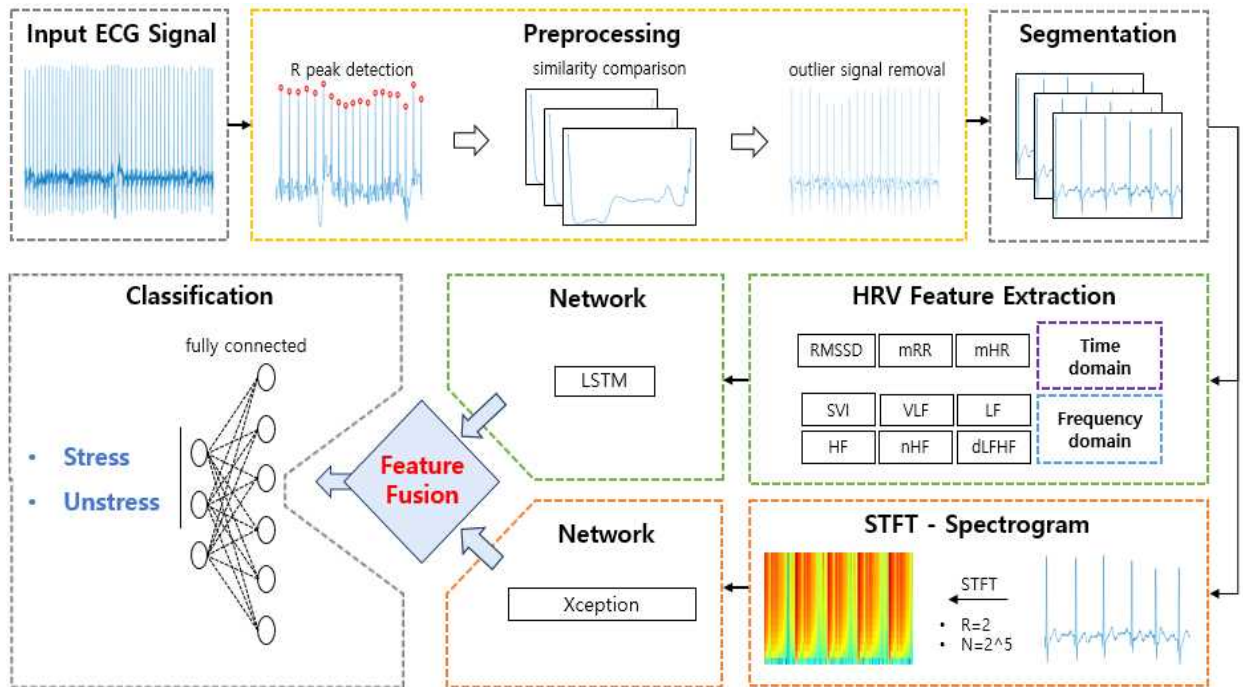


그림 10. 제안하는 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류 흐름도

먼저, 모션 아티팩트로 인해 발생하는 심전도의 이상치 신호를 제거하는 전처리 과정을 진행한다. Pan&Tompkins 기반의 알고리즘을 적용하여 심전도의 QRS

Complex를 식별하고 기울기 변화 포착을 통한 R파 정점을 검출한다. 이후 검출된 R파 정점을 기반으로 심전도의 RR 간격으로 유사도를 비교한다. 이 과정은 대표 RR 간격을 선정하고 선정된 대표 신호와 서로 다른 나머지 RR 간격 간 유사도를 비교하는 과정이다. 이를 통해 임계값을 설정하고, 임계값 미만의 유사도를 보이는 신호 검출을 통해 심전도의 이상치 신호를 제거한다. 이상치 신호가 제거된 전체 심전도 신호를 일정 간격으로 분할 한 후 특징 추출을 진행한다. 특징 추출 단계는 다차원 특징 정보를 이용하기 위해 1차원의 특징 정보와 2차원의 특징 정보를 추출한다. 1차원의 특징 정보는 심전도의 HRV 특징을 시간 대역과 주파수 대역에서 총 9개의 특징을 벡터 형태로 나타낸다. 2차원의 특징 정보는 심전도 신호에 STFT를 적용하여 시간-주파수 대역을 분석하고 이를 스펙트로그램 변환을 통해 2차원 이미지 형태로 나타낸다. 마지막으로 1차원의 특징 정보는 LSTM 네트워크의 입력으로, 2차원의 특징 정보는 CNN에 입력하여 학습을 진행한다. 각 네트워크의 학습 결과를 바탕으로 특징 수준의 융합 적용을 통해 심전도를 이용한 스트레스 분류 성능을 확인한다.

제1절 심전도의 RR 간격 기반 이상치 신호 제거

심전도 신호는 심장에서 생성되는 전기적 활동의 기록이다. 심전도는 심박수 측정, 생체인식, 심혈관 질환 진단, 감정 인식, 스트레스 검출과 같은 다양한 의료 분야에서 비침습적 도구로 활용되고 있다[29]. 심장 활동 주기를 반영하는 심전도는 그림 11과 같이 심방의 탈분극으로 인한 P파, 심실의 탈분극을 의미하는 QRS Complex, 심실의 재분극에 의해 발생하는 T파를 한 주기로 구성되며 연속적으로 반복되는 주기적 특성을 갖는다[30-31].




그림 11. 심장 주기가 반영되는 심전도의 형태학적 특징

심전도를 측정하는 중에 다양한 잡음이 심전도 신호에 기록될 수 있다. 이는 심전도의 정보 식별을 방해하는 요소로 작용한다. 따라서, 생체신호를 이용하는 연구에서 잡음 제거는 중요한 문제이며 전처리 단계에서 필수적이다. 심전도에 기록될 수 있는 소음에 의한 잡음, 전력선 잡음, 전극 잡음 등의 잡음들을 제거할 수 있는 쉽고 유용한 도구로써 주로 대역 통과 필터[32], 중앙값 필터[33], 이동 평균 필터[34]와 같은 다양한 디지털 필터링 방식이 이용된다. 그러나, 원본 신호에 디지털 필터만을 이용하여 잡음을 제거하는 경우는 그림 12와 같이 모션 아티팩트로 인한 신호의 형태학적 특성이 훼손된 이상치 신호를 제거하지 못하는 문제가 있다.

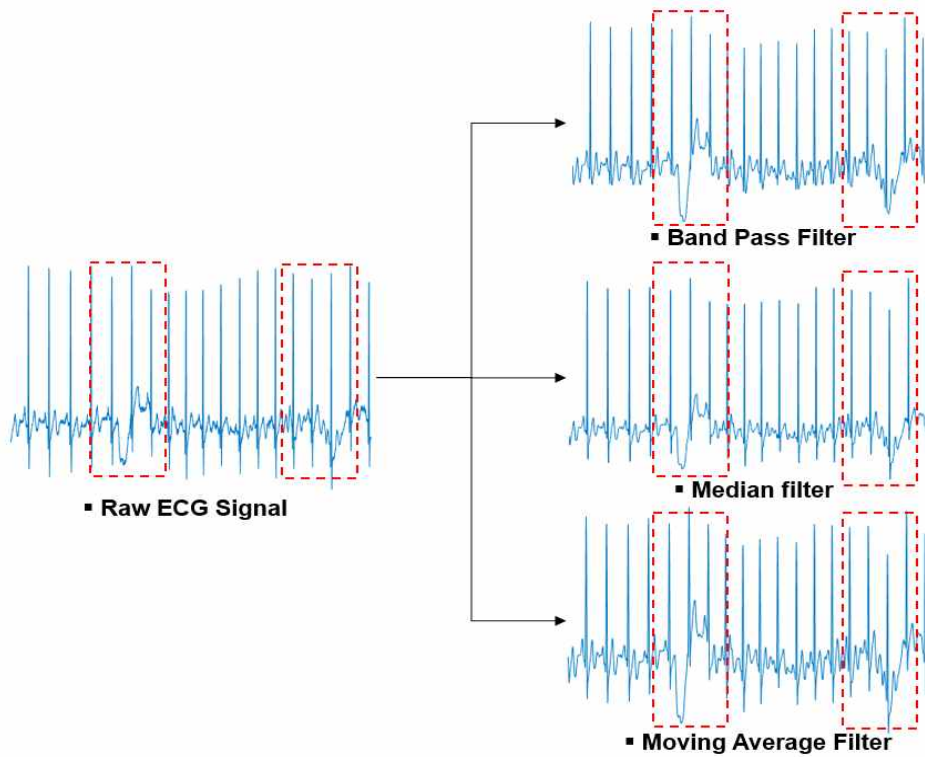


그림 12. 잡음이 포함된 심전도 신호에 다양한 디지털 필터 적용 결과

그러므로, 심전도를 이용한 스트레스 분류를 진행할 때, 불필요한 정보를 포함하는 잡음을 제거하고, 정보 분석에 오류를 일으키는 이상치 신호 제거가 필요하다. 본 논문에서 심전도의 잡음 제거 및 이상치 신호 제거 과정을 포함하는 신호 전처리 과정의 흐름도는 그림 13과 같다.

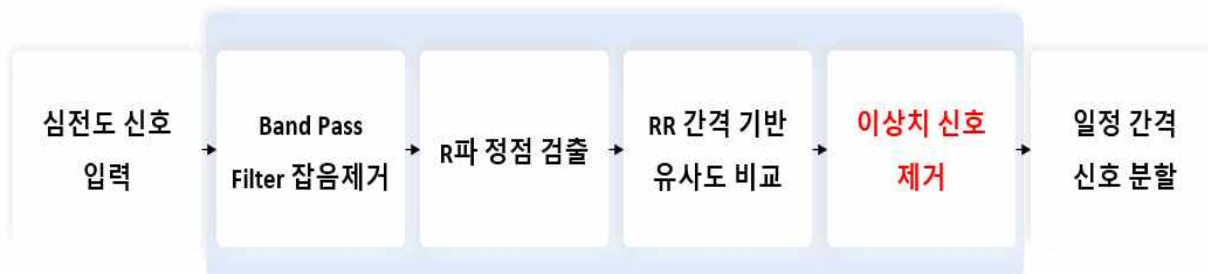


그림 13. 잡음 제거 및 이상치 신호 제거 전처리 과정의 흐름도

WESAD Dataset의 심전도 원본 신호에 Pan&Tompkins 기반의 알고리즘을 이용하여 대역 통과 필터 및 R파 정점 검출을 진행한다. 먼저 저역 통과 필터와 고역 통과 필터(High Pass Filter)의 조합으로 이루어진 대역 통과 필터를 이용하여 불필요한 잡음을 제거한다. 본 논문에서 사용된 대역 통과 필터의 차단 주파수는 0.001-100Hz로 차단 주파수 대역 이내의 주파수 정보는 통과시키고 이외 대역의 주파수 정보는 감쇠된다. 이는 스트레스 상태를 포함하는 심전도의 매우 낮은 주파수(VLF, Very Low Frequency)의 정보까지 분석하기 위함이다. 필터링을 통해 잡음이 제거된 심전도 신호에 Pan&Tompkins 기반의 알고리즘을 적용하여 R파 정점을 검출한다. 이 과정은 먼저 심전도의 5-15Hz 대역에서 QRS Complex를 분리한다. 이후 QRS Complex의 경사도를 구하여 가장 가파른 부분의 정보를 기반으로 이루어진 알고리즘을 통해 심전도의 R파 정점을 검출한다. 검출된 R파 정점을 기반으로 심전도의 RR 간격을 추출하여 유사도 비교를 진행한다. RR 간격 간의 유사도는 두 벡터 간의 코사인 각도를 결정하는 데 사용되는 척도인 코사인 유사도를 통해 계산되며 수식 (1)과 같다.

$$\text{Cosine Similarity} = \frac{A \cdot B}{\|A\| \|B\|} \quad (1)$$

식의 A와 B는 벡터, $A \cdot B$ 는 두 벡터 간의 내적을 나타내며 코사인 유사도를 통한 출력은 -1에서 1의 값을 나타낸다. -1은 서로 완전히 반대되는 경우, 0은 서로 독립적인 경우, 1은 서로 완전히 같은 경우를 의미하며 이를 통해 유사도 비교가 가능하다. 본 논문에서 심전도의 RR 간격 간의 유사도 비교는 그림 14와 같다.

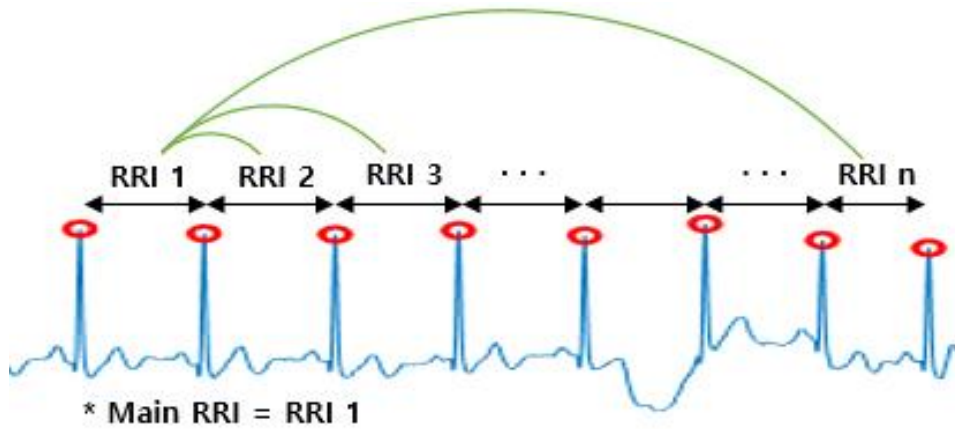


그림 14. RR 간격 간 유사도 비교

추출된 연속적인 RR 간격 신호 중 대표 신호를 선정하고 선정된 대표 신호와 나머지 RR 간격의 심전도 신호 간의 유사도를 비교하여 임계값을 설정하였다. 임계값은 수식 (2)에 의해 연산된다.

$$Th = \text{Cosine Similarity Average} * \alpha \quad (2)$$

수식 (2)의 Th 는 임계값을 나타내며, α 는 임계값 설정을 위한 가중치를 의미한다. 따라서, 임계값은 심전도의 RR 간격 간 코사인 유사도 비교 후 전체 유사도의 평균에 가중치를 부여하여 설정된다. 본 논문에서 가중치는 0.95를 적용하였으며, 임계값 미만의 유사도를 보이는 RR 간격의 이상치 신호를 검출하여 제거하였다. 유사도 비교를 통한 이상치 신호 검출 및 제거 과정은 그림 15와 같다.

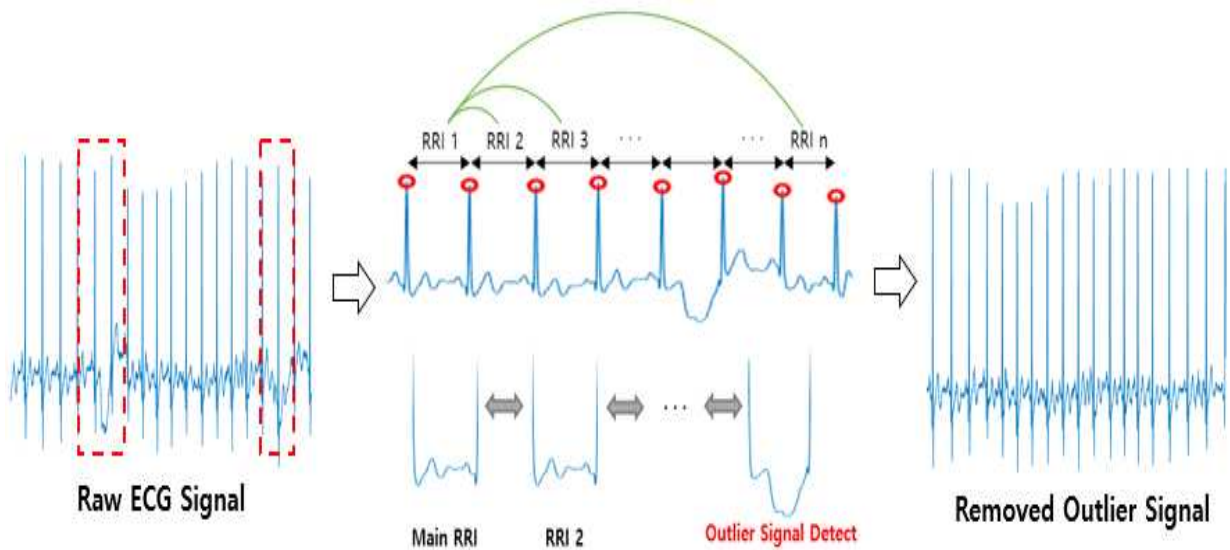


그림 15. RR 간격 기반 유사도 비교를 통한 심전도의 이상치 신호 제거 과정

이상치 신호가 제거된 심전도 신호에서 다차원의 특징을 추출하기 위해 일정한 간격으로 신호를 분할한다. 길이가 5초인 윈도우를 90% 중첩하여 신호를 분할 하였으며, 이는 데이터 증대 및 복잡하고 다양한 스트레스 상태의 정보를 내포하는 심전도를 정밀하게 분석하기 위함이다.

제2절 심전도 다차원 특징 융합을 이용한 스트레스 분류

본 논문에서는 전처리 과정을 마친 심전도 신호를 이용하여 특징을 추출하고 추출된 특징 정보를 융합하여 스트레스를 분류 함으로써 성능의 향상과 높은 신뢰성을 갖도록 한다. 특징 추출 과정에서는 두 가지 주요 단계로 구성된다. 첫 번째 단계에서는 HRV 특징이 추출되어 LSTM 네트워크의 입력으로 사용된다. 두 번째 단계에서는 심전도에 STFT를 적용하여 스펙트로그램 이미지 데이터를 생성한다. 이 데이터는 Xception 네트워크에 대한 입력으로 사용된다.

1. 1차원 특징 데이터: HRV 특징 분석

스트레스 상태에서 신체의 반응 정보를 반영하고 있는 HRV의 특징을 추출한다. HRV 특징 추출 과정은 전처리 된 심전도 데이터의 시간 대역 및 주파수 대역에서 총 9가지 주요 특징을 계산한다. 시간 대역에서 mRR, mHR, RMSSD의 3가지 특징을 추출하며, R파 정점 간 시간 간격의 평균 의미하는 mRR은 수식 (3)에 의해 연산된다. 또한 평균 심박수를 의미하는 mHR은 수식 (4)에 의해, 인접한 RR 간격의 차이에 대한 제곱의 합을 평균하여 제곱근으로 표현한 RMSSD는 수식 (5)에 의해 각각 연산 된다.

$$mRR = \frac{\sum_{i=1}^N (RR_i)}{N} \quad (3)$$

$$mHR = \frac{\sum_{i=1}^N (60000/RR_i)}{N} \quad (4)$$

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (RR_{i+1} - RR_i)^2} \quad (5)$$

주파수 대역에서는 총 6개의 특징을 추출하며 이를 위해 고속 푸리에 변환을 적용하여 분석한다. 고주파대의 HF(High Frequency)는 부교감 신경계의 활동 정보 분석이 가능하고, 저주파대의 LF(Low Frequency)는 교감 신경계와 부교감 신경계의 활동 정보 분석이 가능하다. HF와 LF 정보를 기반으로 추출할 수 있는 주파수 대역의 6개 특징에 대한 의의와 주파수 대역은 표 3[23]과 같으며, 추출되는 시간

및 주파수 대역의 HRV 특징 정보는 1차원의 특징 벡터 형태로 LSTM 네트워크에 입력된다.

표 3. 사용된 주파수 대역의 HRV 특징 정보

Features	Description	Frequency band	Units
HF	Power in high frequency band	0.15 ~ 0.4Hz	ms^2
LF	Power in low frequency band	0.04 ~ 0.15Hz	ms^2
VLF	Power in very low frequency band	$\leq 0.04Hz$	ms^2
nHF	Normalized HF $nHF = HF / (Total\ Power - VLF) * 100$		%
dLFHF	$LF - HF$		
SVI	LF / HF		

2. 2차원 특징 데이터: STFT 기반 시간-주파수 특징 분석

심전도 신호는 시간이 지남에 따라 신호의 속성이 변하는 비정상 신호 (Non-stationary Signal)이다. 따라서, 단일의 주파수 대역 정보만으로는 변화하는 속성을 설명하기 어렵다[35]. 본 논문에서는 비정상 신호인 심전도 신호를 분석하기 위해 STFT를 적용하여 시간-주파수 특징을 추출한다. 이때 STFT 적용 식은 수식 (6)과 같다.

$$STFT(\tau, \omega) = \int_{-\infty}^{\infty} x(\tau)w(\tau-t)e^{-j\omega t} dt \quad (6)$$

$x(\tau)$ 는 분석이 되는 입력 신호를 의미하며, 윈도우 함수 $w(\tau-t)$ 를 이용하여 FFT를 통해 계산되어 시간-주파수를 분석한다. STFT 적용 시 Hamming Window의 윈도우

우 길이(R)는 2, FFT의 해상도(N)는 2^5 로 설정하였다. 최종적으로 전처리 된 심전도 신호에 STFT를 적용하고 스펙트로그램 변환을 통해 그림 16과 같이 2차원의 이미지 데이터를 구성하였으며 이 데이터는 Xception 네트워크의 입력으로 사용된다.

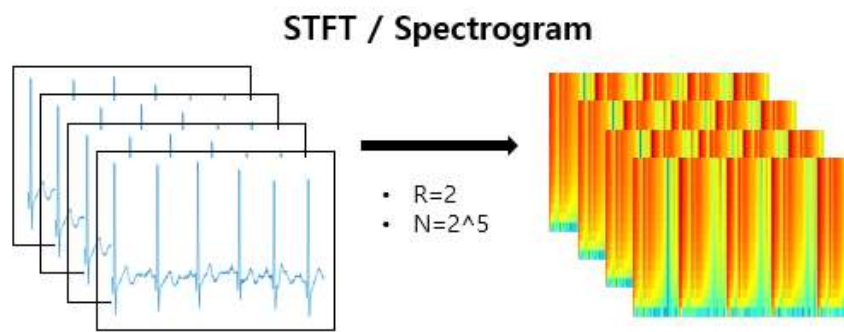


그림 16. 심전도 신호의 STFT 적용 및 스펙트로그램 변환

3. 다차원 특징 융합을 이용한 스트레스 분류

1차원 또는 2차원으로 표현되는 단일 차원의 특징 정보만을 따로 사용하면 데이터에 포함된 중요한 정보를 놓칠 수 있다. 각 차원의 특징은 심전도 신호의 서로 다른 측면을 캡처하기 때문이다. HRV 특징 정보인 1차원의 특징은 심장박동의 변동성과 규칙성에 대한 중요한 정보를 제공한다. 그러나, 신호의 주파수 정보가 시간의 경과에 따라 어떻게 변하는지에 대한 정보를 얻을 수 없다. 스펙트로그램과 같은 2차원의 특징은 시간 변화에 따른 심전도 신호의 주파수 정보 변화 양상을 더욱 자세하게 분석할 수 있다. 하지만 1차원의 HRV 특징에서 얻을 수 있는 신호의 전체적인 추세 또는 평균, 시간 도메인의 특정 패턴과 같은 측면의 정보를 분석하기 어렵다. 그러므로 본 논문에서는 심장박동의 변동성과 규칙성에 대한 1차원의 특징 정보와 신호의 자세한 시간-주파수 분석에 따른 2차원 특징 정보를

융합하여 스트레스 분류 성능 향상을 확인한다.

다양한 유형의 데이터를 처리하기 위해 특정 신경망을 선택할 때 각 네트워크의 강점과 특성을 고려해야 한다. LSTM 네트워크는 순환 신경망(RNN)의 한 유형으로 순차 데이터 처리에 뛰어난 성능을 보이며 시간적 종속성이 있는 생리적 신호를 처리하기에 적합하다. 따라서, HRV와 같은 시계열 데이터에 적합하며 심장 박동 사이의 시간 변화에 대한 정보인 HRV 특징의 변화량에 대한 시퀀스는 LSTM에 적합하다. Xception 네트워크는 심층적으로 분리 가능한 컨볼루션을 활용하여 데이터의 공간 계층을 처리하는 컨볼루션 신경망(CNN, Convolutional Neural Network) 유형이다. 복잡성을 단순화하고 성능을 향상시키는 것을 목표로 Inception 구조에서 개선되어 설계되었다. 이 네트워크의 핵심 아이디어는 일반적인 CNN 구조에서 사용하는 컨볼루션을 대체하는 깊이별 분리 가능 컨볼루션을 사용하는 것이다. 공간 특징과 채널별 특징 학습을 분리하여 많은 유형의 이미지 데이터에 보다 효율적이고 효과적인 장점이 있다. 이로 인해, 서로 다른 주파수 간의 공간 상관 관계와 시간 경과에 따른 변화를 매핑하여 스펙트로그램 이미지에서 공간 계층 구조를 효과적으로 학습할 수 있다. 따라서, 심전도 신호의 2차원 스펙트로그램 이미지 데이터는 시간-주파수 대역을 표현하는 이미지로 Xception을 통해 공간 계층 구조를 효과적으로 학습할 수 있다.

LSTM 및 Xception 네트워크가 각각 1차원 및 2차원의 특징 정보를 분석한 후 특징 수준 융합을 진행한다. 융합된 특징 정보를 다시 완전 연결 계층의 입력으로 사용하여 최종 스트레스 분류 성능을 확인한다. 각 네트워크의 구조와 다차원 특징 융합 흐름은 그림 17과 같다. 본 논문에서 적용한 특징 융합 적용 방식은 연결, 평균, 최대값, 가중치 평균, 곱셈, 덧셈의 총 6가지 융합 방식을 적용하여 성능을 비교한다. 가중치 평균 방식을 위한 각 네트워크의 특징 정보에 대한 가중치는 각 네트워크의 정확도를 기반으로 산정되며 수식 (7-8)과 같다. 산정된 가중치를 이용하여 가중치 평균 방식의 특징 정보 융합은 수식 (9)에 의해 연산 된다.

가중치 평균 방식을 이용하여 다차원 특징 융합을 통한 스트레스 분류 과정은 그림 18과 같다.




그림 17. 제안하는 다차원 특징 융합을 위한 네트워크 흐름도

$$LSTM\ weight = \frac{LSTM\ accuracy}{Xception\ accuracy + LSTM\ accuracy} \quad (7)$$

$$Xception\ weight = \frac{Xception\ accuracy}{Xception\ accuracy + LSTM\ accuracy} \quad (8)$$

$$Fusion = Xception\ Features(Xception\ weight) + LSTM\ Features(LSTM\ weight) \quad (9)$$

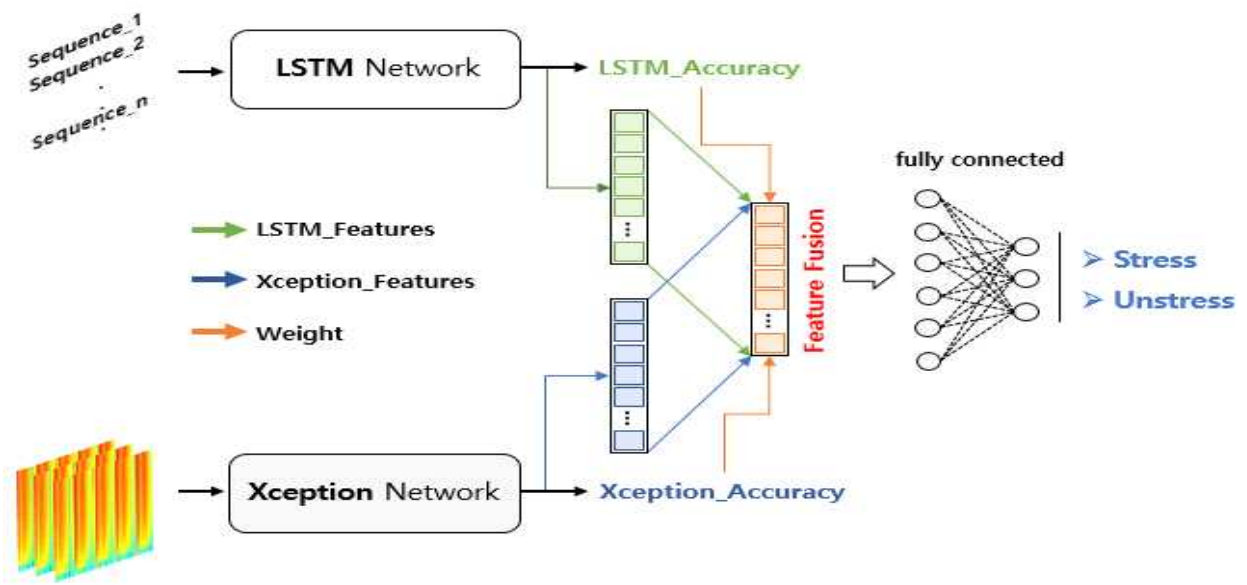


그림 18. 가중치 평균 방식의 다차원 특징 정보 융합 과정

제4장 실험 결과 및 분석

본 논문에서 제안하는 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류 성능 재현을 위해 스트레스 상태를 포함하는 심전도 신호의 대표적인 오픈 데이터베이스인 WESAD Dataset을 사용하였다. 해당 데이터베이스가 내포하는 구성은 표 4와 같다.

표 4. WESAD Dataset의 심전도 데이터 내용

구분	내용
인원(명)	15
신호	심전도(ECG)
취득 장비	RespiBAN
장비 장착 위치	가슴
샘플링 주파수(Hz)	700
정서적 상태	중립, 스트레스(TSST), 오락
취득 시간(분)	중립: 약 20 스트레스: 약 10 오락: 약 6

피험자 인원은 총 15명으로 구성하였으며, RespiBan 장비를 가슴에 착용하여 700Hz의 샘플링 주파수로 심전도 데이터를 수집했다. 해당 심전도 데이터는 중립, 스트레스, 오락의 세 가지 다른 정서적 상태를 포함한다. 중립 상태는 약 20분간 기록되었으며 피험자가 앉거나 서서 편안한 상태에서 유도되었다. 스트레스 상태는 약 10분 동안 TSST(Trier Social Stress Test)[36] 환경 노출을 통해 취득되었다. TSST는 피험자에게 급성 스트레스를 유발하여 생리적, 심리적 반응을 연구하

기 위해 널리 사용되는 실험 절차이다. 평가적 판단, 사회적 감시 및 성과 압박과 같은 스트레스가 많은 사회적 상황을 시뮬레이션하는 것을 목표로 압박 면접 상황, 암산 작업 등의 절차로 구성된다. 오락 상태는 피험자들이 11개의 재미있는 비디오 클립을 시청하는 약 6분 동안 취득되었다. 따라서, 본 논문에서는 세 가지의 다중 감정 상태(중립, 스트레스, 오락)의 심전도 데이터를 이용하여 스트레스 상태와 스트레스가 아닌 상태(중립, 오락)를 분류하는 것을 목표로 한다.


스트레스 분류를 위해 데이터는 스트레스 상태 10분, 중립과 오락 상태를 결합하여 스트레스가 아닌 상태(비 스트레스) 26분으로 구성한다. 비 스트레스 상태의 데이터가 스트레스 상태의 데이터보다 더 긴 길이를 갖기 때문에, 스트레스 상태의 데이터 길이와 동일하도록 랜덤하게 10분 길이를 추출한다. 정렬된 데이터는 학습에 80%, 테스트에 20%로 랜덤하게 분류하여 실험한다.

제안한 스트레스 분류 시스템의 성능을 확인하기 위해 실험은 표 5와 같은 실험을 진행한다. 실험1에서는 윈도우 길이별 네트워크 성능을 확인하고, 실험2에서는 데이터 융합을 적용한 성능 결과를 확인한다. 각 실험에서 확인하는 성능 결과는 이상치 신호 제거 전·후를 각각 비교한다.


표 5. 실험 방식에 따른 성능 결과 비교

단계	실험 내용	사용한 데이터	실험 결과 (%)		비고
			전	후	
1	윈도우 길이 별 LSTM, Xception의 성능 확인	WESAD Dataset 60s, 10s, 5s	윈도우 변화에 따른 성능 분석		-
2	이상치 신호 제거 성능 확인	WESAD Dataset 5s	97.12	98.92	Xception
3	다차원 특징 융합을 적용한 성능 확인	WESAD Dataset 5s	LSTM: 81.42 Xception: 98.92	99.51	이상치 제거 후


생체신호를 분할하는 윈도우 길이에 따른 성능을 확인하기 위해 실험을 진행한다. 실험은 1차원 특징 정보에 적합한 LSTM 네트워크와, 2차원 이미지 데이터에 적합한 Xception 네트워크를 이용한다. 윈도우 길이에 따른 성능 결과는 그림 18과 같다. 윈도우 길이는 5초, 10초, 60초로 설정하였으며, 윈도우 길이에 따라 분할되는 신호의 길이는 그림 19와 같다. 실험 결과, 그림 20과 같이 LSTM과 Xception 모두에서 윈도우 길이가 제일 짧은 5초일 때, 각각 78.25%, 97.12%로 가장 높은 성능을 나타냈다. 윈도우 길이가 늘어날수록 스트레스 분류 성능이 저하됨을 보였으며, 이는 윈도우 길이가 짧을수록 심전도의 스트레스 정보를 정밀하게 포착할 수 있음을 확인하였다.



(a) 5sec Segmented Signal



(b) 10sec Segmented Signal



(c) 60sec Segmented Signal

그림 19. 윈도우 길이에 따른 분할된 심전도 신호

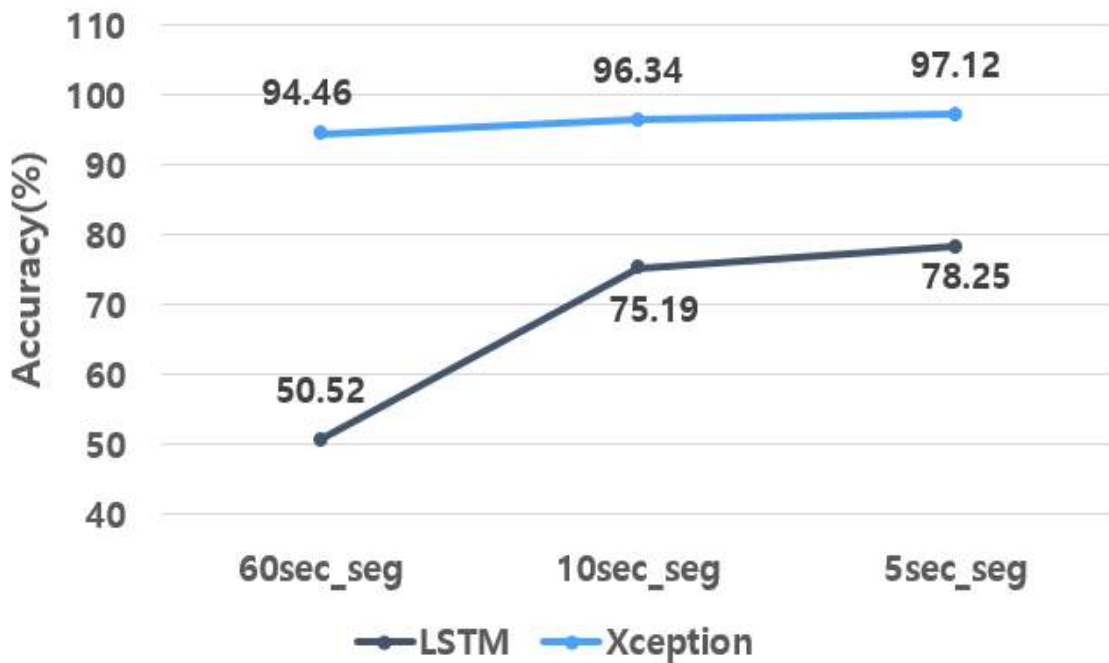


그림 20. 윈도우 길이에 따른 네트워크 성능

다음으로 심전도 신호의 이상치 신호 제거 전·후의 성능을 분석하기 위한 실험을 진행한다. 심전도의 이상치 신호 제거 전·후의 성능 결과는 그림 21과 같다. 실험은 원본 심전도 신호와 본 논문에서 적용한 RR 간격 기반의 유사도 비교 후 이상치 신호가 제거된 신호를 이용하여 성능을 확인한다. 이전 실험 결과에 따라, 가장 높은 성능을 보인 윈도우 길이 5초로 분할된 심전도 신호를 이용한다. 실험 결과, 심전도의 이상치 신호 제거 후 LSTM과 Xception 각각 81.42%, 98.92%의 성능으로 이상치 신호 제거 전에 비해 각각 3.17%, 1.8% 향상되었다. 그림 15와 같은 방법으로 심전도 기반 스트레스 분류에 영향을 주는 이상치 신호를 제거하여 성능이 향상됨을 확인하였다.

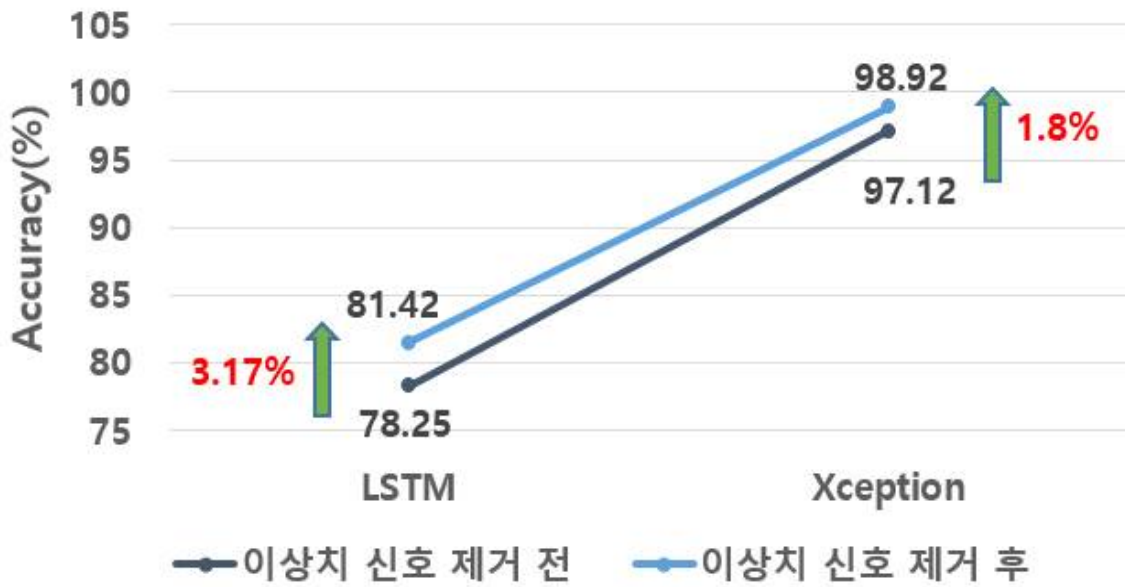


그림 21. 심전도의 이상치 신호 제거 전·후 성능 비교

이후, 다차원 특징 융합을 적용한 성능을 확인하기 위해 실험을 진행한다. 먼저 심전도를 이용하여 HRV 특징을 추출한다. 추출되는 HRV 특징은 시간 도메인에서 mRR, mHR, RMSSD를 추출하고, 주파수 도메인에서 nHF, HF, LF, VLF, dLFHF, SVI가 추출되어 총 9개의 특징을 추출하여 이용한다. 추출된 HRV 특징 정보는 1차원의 특징 벡터의 형태로 LSTM 네트워크에 입력된다. 다음으로, 심전도 신호에 STFT를 적용하여 시간 흐름에 따른 신호의 주파수 변화 정보를 분석한다. 분석된 정보는 스펙트로그램 변환을 통해 2차원의 이미지 형태로 Xception 네트워크에 입력된다. 네트워크에서 학습 및 분석되는 정보를 기반으로 각 네트워크의 완전 계층 출력 정보를 이용하여 특징 수준 융합을 적용한다. 본 논문에서 제안한 다차원 특징 수준 융합 방식은 6가지(단순 결합, 평균, 가중치 평균, 최댓값, 곱셈, 덧셈)의 방식을 적용하여 분류 성능을 확인한다. 신호 분할을 위한 윈도우 길이에 따른 다차원 특징 융합 성능을 확인하였으며, 결과는 표 6과 같다.

표 6. 특징 융합 방식에 따른 스트레스 분류 성능

(%)

	단순 결합	평균	가중치 평균	최댓값	곱셈	덧셈
60sec	97.45	97.43	97.79	97.4	95.98	97.4
10sec	98.65	98.65	98.75	98.47	98.61	98.63
5sec	99.44	99.49	99.51	99.45	99.43	99.44

LSTM과 Xception 기반의 다차원 특징 융합 적용 결과 곱셈을 제외한 5가지의 융합 방식 결과 윈도우 길이가 짧을수록 성능이 향상됨을 나타냈으며, 가중치 평균 방식이 다른 방식에 비해 높은 성능을 보인다. 가중치 평균 방식을 적용한 다차원 특징 융합 과정의 단계별 특징 벡터 예시는 표 7-9와 같다. 표 7과 8은 LSTM과 Xception 네트워크 각각에서 분석된 특징 벡터의 일부를 나타낸다. 비 스트레스인 경우 양의 벡터값을 갖는 반면 스트레스 상태인 경우 음의 벡터값을 갖는다. 다만, 표 7에서 나타내는 LSTM의 특징 벡터의 경우, 일부 잘못 분석된 특징으로 인해 반대의 부호 값을 가지며 이는 오분류로 인한 성능 저하를 초래한다.

표 7. LSTM 네트워크를 통해 분석된 특징 정보

LSTM	No	Feature_vector	Accuracy	Weight
Unstress	1	-0.12696	0.8188	0.4543
	2	-0.17882		
	3	0.152565		
	4	0.236177		
	5	0.212931		
	6	0.166967		
	7	0.205159		
	8	0.218348		
	9	0.22587		
	10	0.234049		
Stress	1	-0.18916		
	2	-0.18452		
	3	-0.19303		
	4	0.175056		
	5	0.054485		
	6	-0.18361		
	7	-0.18374		
	8	-0.18603		
	9	-0.185		
	10	-0.19025		

표 8. Xception 네트워크를 통해 분석된 특징 정보

Xception	No	Feature_vector	Accuracy	Weight
Unstress	1	4.346683	0.9832	0.5456
	2	8.364962		
	3	8.990179		
	4	9.69763		
	5	10.92341		
	6	10.5836		
	7	10.88024		
	8	8.962727		
	9	7.071857		
	10	8.197678		
Stress	1	-9.32111		
	2	-9.90295		
	3	-7.68996		
	4	-4.90823		
	5	-9.62089		
	6	-11.8255		
	7	-8.57018		
	8	-9.29892		
	9	-8.00733		
	10	-9.11876		

표 9. 특징 융합을 적용한 후 특징 정보

Fused	No	Feature_vector
Unstress	1	2.313968
	2	4.482873
	3	4.974582
	4	5.398575
	5	6.056826
	6	5.850534
	7	6.02974
	8	4.989493
	9	3.961206
	10	4.579198
Stress	1	-5.17177
	2	-5.48713
	3	-4.28354
	4	-2.59851
	5	-5.22463
	6	-6.53572
	7	-4.75958
	8	-5.15824
	9	-4.45305
	10	-5.06187

표 9는 각 네트워크의 정확도 값을 이용하여 수식 (7-9)의 가중치 평균 방식 특징 융합을 적용한 특징 벡터값을 나타낸다. 표 7에서 잘못 분석된 특징 정보가 가중치 평균 방식의 특징 융합을 통해 개선되었음을 확인할 수 있다.

따라서, 각 특징 수준 융합 방식을 적용한 스트레스 분류 성능은 5초의 윈도우 길이로 분할 한 신호를 이용하여 가중치 평균 방식의 다차원 특징 융합을 적용했을 때 99.51%의 가장 높은 성능을 보인다. 그림 22는 심전도의 이상치 신호 제거

및 가중치 평균 방식의 다차원 특징 융합을 적용한 윈도우 길이에 따른 성능 결과를 나타낸다.

기존 심전도 신호를 이용한 스트레스 분류 방법과 본 논문에서 제안한 스트레스 분류 성능 결과를 표 10과 같이 비교 분석하였다. S.T. Chandrasekaran[20] 및 M. G. Kang[25]은 동일한 WESAD Dataset을 이용하여 심전도 분석을 통한 스트레스 분류를 진행했다. Chandrasekaran[20]은 전처리를 적용하지 않고 3분 길이의 윈도우로 분할된 신호에서 시간 대역의 HRV 특징을 추출하였다. 머신러닝 기반의 분류기를 이용하여 93%의 스트레스 분류 성능을 확인하였다. Kang[25]은 차단 주파수 150Hz의 저역 통과 필터를 이용하여 잡음 제거를 하였으며 1분 길이의 분할된 신호를 사용하였다. 신호의 2차원 이미지와 FFT를 적용한 이미지를 딥러닝 기반의 네트워크에 입력하여 98.26%의 성능을 확인하였다. 따라서, 스트레스 상태를 포함하는 심전도를 분석하기 위해 적합한 방식의 잡음 제거 방식이 필요하며, 신호 분할을 위한 윈도우 길이가 짧을수록 스트레스 분류 성능이 높음을 보였다. 또한 머신러닝을 통한 분석보다 딥러닝 네트워크를 통한 분석이 적합할 수 있음을 의미한다. 앞서 분석된 장점을 포함하는 본 논문에서 제안한 스트레스 분류 방법은 99.51%로 기존 연구들과 비교했을 때, 1.25% 이상 향상됨을 확인하였다.

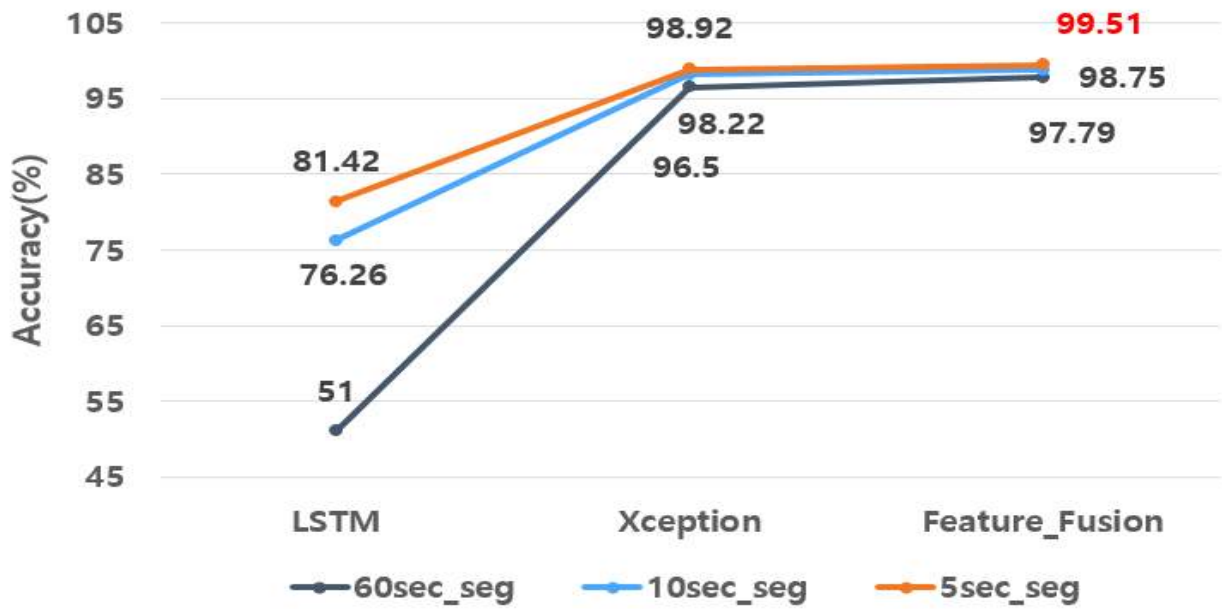


그림 22. 다차원 특징 융합 적용에 따른 스트레스 분류 성능 결과

표 10. 기존 심전도 신호를 이용한 스트레스 분류 성능 비교

저자	데이터 베이스	인원	전처리	신호 분할	특징 추출	ECG 입력	분류기	성능(%)
S.T. Chandrasekaran. et al. [20]	WESAD	15	-	3분	HRV (Time Domain)	1-D	축적 컴퓨팅, 로지스틱 회귀	93
M. G. Kang et al. [25]	WEASD, ST Change	15	저역 통과 필터 (150Hz)	1분	Signal Image, FFT	2-D	CNN-LSTM	Signal Image: 94.13 FFT: 98.26
Proposed Method	WESAD	15	이상치 신호 제거	5초	HRV STFT	1-D 2-D	1D: LSTM, 2D: Xception, Fusion	99.51

제5장 결론

기존 심전도 신호를 이용한 스트레스 분류 연구는 심전도 취득 시 신호에 포함되는 잡음을 제거하기 위해 적용이 쉽고 유용한 도구인 디지털 필터링 방식을 적용하고 있다. 하지만 이러한 필터링 방식은 모션 아티팩트에 의한 심전도 신호의 주기적, 형태학적 특성이 훼손된 부분인 이상치 신호를 제거하지 못하는 문제가 있다. 또한 기존 딥러닝 네트워크를 이용한 스트레스 분류 시, 단일 차원의 특징 정보만을 주로 이용하고 있다. 이는 특정 측면에 편향된 분석을 야기하고 복잡한 정보를 포함하는 스트레스 상태에 대해 포괄적인 분석이 불가하다. 즉, 1차원의 특징 정보는 시간 경과에 따른 주파수 분석이 어렵고, 2차원의 특징 정보는 신호 전체의 특정한 패턴, 추세, 평균 정보와 같은 특징의 분석이 어렵다.

본 논문에서는 기존의 문제점들을 해결하기 위해 이상치 신호를 제거한 심전도를 이용하여 LSTM과 Xception의 다차원 특징 융합 기반 스트레스 분류 방법을 제안하였다. 심전도의 이상치 신호 제거는 RR 간격 간의 유사도 비교를 통한 형태학적 정보를 이용함에 따라 기존의 디지털 필터링 방식에 비해 직접적인 이상치 신호 제거가 가능하였다. 제안한 다차원 특징 융합을 통해 1차원 및 2차원의 각 차원이 갖는 특징 분석의 한계를 상호 보완하여 극복하였다. 또한 각 차원에 적합한 네트워크를 사용하여 스트레스 상태의 특징 분석을 강화하였으며, 각 신경망 네트워크의 출력을 특징 수준에서 융합함으로써 신경망 아키텍처 고유 기능의 강점을 모두 활용할 수 있었다.

실험 결과, 5초의 윈도우 길이로 분할된 신호를 이용하여 각 차원의 특징 정보를 이용한 경우 LSTM에서 78.25%, Xception에서 97.12%의 비교적 낮은 성능을 보였다. 제안한 방법을 적용하여 심전도의 이상치 신호를 제거하였을 때, LSTM: 81.42%, xception: 98.92%로 이상치 신호 제거 전에 비해 각각 3.17%, 1.8%의 성능 향상을 확인하였다. 이후 각 차원의 특징 정보 융합을 6가지 방식으로 적용하

였으며, 가중치 평균 방식의 특징 융합 성능 결과가 99.51%로 가장 높았다. 따라서, 모션 아티팩트로 인한 잡음은 스트레스 분류를 위한 심전도 분석을 방해함을 확인하였으며, 심전도의 이상치 신호 제거를 통해 해결하였다. 또한 단일 차원의 특징 정보만을 이용하는 경우 각 차원에서의 정보 분석의 한계를 확인하였으며, 다차원 특징 수준 융합을 적용하여 문제점을 해결하였다. 그러므로, 본 논문에서 제안하는 LSTM 및 Xception의 다차원 특징 융합 기반 심전도를 이용한 스트레스 분류 방법이 우수한 성능을 보임을 확인하였다.

참고문헌

- [1] H. Y. Lee and H. B. Joo, "Stress and mental illness," Korean Medical Association, vol. 56, no. 6, pp. 471-477, Apr. 2013.
- [2] National Rehabilitation Center, Available online: <http://www.nrc.go.kr/portal/main.do>(accessed on 20 May 2023).
- [3] S. Hey, A. Gharbi, B. V. Haaren, K. Walter, N. König, and S. Löffler, "Continuous noninvasive pulse transit time measurement for psycho-physiological stress monitoring," In Proc. Int. Conf. eHealth. Telemed. Soc. Med.(eTELEMED), pp. 113-116, Feb. 2009.
- [4] A. O. Akmandor and N. K. Jha, "Keep the stress away with SoDA: stress detection and alleviation system," IEEE Trans. Mult. Sc. Comp. Sys., vol. 3, no. 4, pp. 722-727, Oct.-Dec. 2017.
- [5] S. Cohen, J. D. Denise, and G. E. Miller, "Psychological stress and disease," JAMA, vol. 298, no. 14, pp. 1685-1687, Oct. 2007.
- [6] S. L. Noble, "Control-theoretic treatment scheduling for posttraumatic stress disorder," In Proc. Am. Control Conf.(ACC), vol. 3, no. 4, pp. 269-282, Aug. 2013.
- [7] C. H. Song, J. S. Kim, G. H. Choi, and S. Pan, "Xception-based stress classification by removing ECG signal's outliers," The Journal of Korean Institute of Information Technology(JKIIT), vol. 22, no. 5, pp. 75-81, May. 2023.
- [8] K. Masood, B. Ahmed, J. Choi, and R. Gutierrez-Osuna, "Consistency and validity of self-reporting scores in stress measurement surveys," In Proc. Int. Conf. IEEE Eng. Med. Biol. Soc.(EMBC), pp. 4895-4898, Nov. 2012.

- [9] G. Giannakakis, D. Grigoriadis, K. Giannakaki, O. Simantiraki, A. Roniotis, and M. Tsiknakis, “Review on psychological stress detection using biosignals,” *IEEE Trans. Affect. Comput.*, vol. 13, no. 1, pp. 440-460, Jan.-Mar. 2022.
- [10] A. Fernandes, R. Helawar, R. Lokesh, T. Tari, and A. V. Shahapurkar, “Determination of stress using blood pressure and galvanic skin response,” In *Proc. Int. Conf. Commun. Netw. Technol.(ICCNT)*, pp. 165-168, Mar. 2015.
- [11] S. Baltacı and D. Gökçay, “Role of pupil dilation and facial temperature features in stress detection,” In *Proc. Signal Process. Comm. Appl. Conf.(SIU)*, pp. 1259-1262, Apr. 2014.
- [12] R. K. Nath and H. Thapliyal, “Smart wristband-based stress detection framework for older adults with cortisol as stress biomarker,” *IEEE Trans. Consum. Electron.*, vol. 67, no. 1, pp. 30-39, Feb. 2021.
- [13] M. Umair, N. Chalabianloo, C. Sas, and C. Ersoy, “HRV and stress: A mixed-methods approach for comparison of wearable heart rate sensors for biofeedback,” *IEEE Access*, vol. 9, pp. 14005-14024, Jan. 2021.
- [14] M. Blanco-Velasco, B. Weng, and K. E. Barner, “A new ECG enhancement algorithm for stress ECG tests,” In *Proc. Conf. Comput. Cardiol.(CinC)*, pp. 917-920, Sep. 2006.
- [15] 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*, vol. 19, no. 24, pp. 12432-12442, Dec. 2019.
- [16] S. M. Shahid, S. Ko, and S. Kwon, “Performance comparison of 1D

- and 2D convolutional neural networks for real-time classification of time series sensor data,” In Proc. Int. Conf. Inf. Netw.(ICOIN), pp. 507-511, Jan. 2022.
- [17] E. K. Roonizi and R. Sassi, “A signal decomposition model-based bayesian framework for ECG components separation,” IEEE Trans. on Signal Process., vol. 64, no. 3, pp. 665-674, Feb. 2016.
- [18] S. Mekruksavanich, N. Hnoohom, and A. Jitpattanakul, “A deep residual-based model on multi-branch aggregation for stress and emotion recognition through biosignals,” In Proc. Int. Conf. Elect. Engineer. Electro. Comp. Telecom. Inf. Technol.(ECTI-CON), pp. 1-4, May. 2022.
- [19] P. Schmidt, A. Reiss, R. Duerichen, C. MarbergerK, and V. Laerhoven, “Introducing WESAD, a multimodal dataset for wearable stress and affect detection,” In Proc. ACM Int. Conf. Multimodal Interaction, pp. 400-408, Oct. 2018.
- [20] S. T. Chandrasekaran, S. P. Bhanushali, I. Banerjee and A. Sanyal, “A bio-inspired reservoir-computer for real-time stress detection from ECG signal,” IEEE Solid-State Circuits Lett., vol. 3, pp. 290-293, Aug. 2020.
- [21] N. Munla, M. Khalil, A. Shahin, and A. Mourad, “Driver stress level detection using HRV analysis,” In Proc. Int. Conf. Biomed. Eng.(ICABME), pp. 61-64, Nov. 2015.
- [22] J. A. Healey and R. W. Picard, “Detecting stress during real-world driving tasks using physiological sensors,” IEEE Trans. Intell. Transp. Syst., vol. 6, no. 2, pp. 156-166, Jun. 2005.
- [23] K. J. Park and H. J. Jeong, “Assessing methods of heart rate

- variability,” J. Korean Soc. Clin. Neurophysiol., vol. 16, no. 2, pp. 49-54, Jan. 2014.
- [24] L. Liakopoulos, N. Stagakis, E. I. Zacharaki, and K. Moustakas, “CNN-based stress and emotion recognition in ambulatory settings,” In Proc. Int. Conf. Inf. Intell. Syst. Appl.(IISA), pp. 1-8, Jul. 2021.
- [25] M. G. Kang, S. H. Shin, J. H. Jung, and Y. T. Kim, “Classification of mental stress using CNN-LSTM algorithms with electrocardiogram signals,” J. Healthc. Eng. Intell., vol. 2021, Jun. 2021.
- [26] A. Goldberger, L. Amaral, L. Glass, J. Hausdorff, P. C. Ivanov, R. Mark, J. E. Mietus, G. B. Moody, C. K. Peng, and H. E. Stanley, “PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals,” Circulation, vol. 101, no. 23, pp. e215-e220, Jun. 2000.
- [27] Z. Ahmad and N. M. Khan, “Multi-level stress assessment using multi-domain fusion of ECG signal,” In Proc. Int. Conf. IEEE Eng. Med. Biol. Soc.(EMBC), pp. 4518-4521, Jul. 2020.
- [28] M. Amin, K. Ullah, M. Asif, A. Waheed, S. U. Haq, M. Zareei, and R. R. Biswal, “ECG-based driver’s stress detection using deep transfer learning and fuzzy logic approaches,” IEEE Access, vol. 10, pp. 29788-29809, Mar. 2022.
- [29] S. K. Berkaya, A. K. Uysal, E. S. Gunal, S. Ergin, S. Gunal, and M. B. Gulmezoglu, “A survey on ECG analysis,” Biomed. Signal Process. Control, vol. 43, no. 2, pp. 216-235, Mar. 2018.
- [30] J. L. Wayman, “Technical testing and evaluation of biometric identification devices,” In Proc. Int. Conf. Adv. Electr. Electron. Eng.(ICAEEE), pp. 1-4, Nov. 2018.

- [31] G. H. Choi, K. Lim, and S.B. Pan, “ Driver identification system using normalized electrocardiogram based on adaptive threshold filter for intelligent vehicles,” *Sensors*, vol. 21, no. 1, p. 202, Dec. 2020.
- [32] G. S. Mihov and D. H. Badarov, “Application of a reduced band-pass filter in the extraction of power-line interference from ECG signals,” In *Proc. XXIX Int. Sci. Conf. Electron.(ET)*, pp. 1-4, Sep. 2020.
- [33] S. Aadhirai and D. N. Jamal, “Feature extraction and analysis of renal abnormalities using fuzzy clustering segmentation and SIFT method,” In *Proc. Int. Conf. Biosig. Img. Instr.(ICBSII)*, pp. 1-5, Mar. 2017.
- [34] Y. W. Bai, W. Y. Chu, C. Y. Chen, Y. T. Lee, Y. C. Tsai, and C. H. Tsai, “The combination of Kaiser window and moving average for the low-pass filtering of the remote ECG signals,” In *Proc. IEEE Symp. Comput.-Based Med. Syst.*, pp. 273-278, Jun. 2004.
- [35] J. Huang, B. Chen, B. Yao, and W. He, “ECG arrhythmia classification using STFT-based spectrogram and convolutional neural network,” *IEEE Access*, vol. 7, pp. 92871-92880, Jul. 2019.
- [36] A. P. Allen, P. J. Kennedy, S. Dockray, J. F. Cryan, T. G. Diana, and G. Clarke, “The trier social stress test: principles and practice,” *Neurobiol. Stress*, vol. 6, pp. 113-126, Nov. 2016.