

논문 2023-60-5-8

인지부하 감지를 위한 HRV와 PRV의 파라미터 중요도 분석

(Important Feature Analysis of HRV and PRV for Cognitive Load Detection)

김민아*, 홍상기**, 이강복**, 김정균***

(Kim Min-A, Hong Sang Gi, Lee Kangbok, and Kim Jeong-Kyun[©])

요약

인지부하를 분석하고 이해하는 것은 HCI(Human-Computer Interaction) 기술을 향상시키며 사고를 예방하는 중요 기술이다. 최근 인지부하의 분석에는 심박변이도 분석이 많이 이용되고 있으며, 웨어러블 기기의 사용이 보편화됨에 따라 Photoplethysmogram의 맥박변이도를 심박변이도 대신 사용하는 추세이다. 그러나, 맥박변이도와 심박변이도는 모든 경우에 대해 호환이 불가능하며 이들을 같은 알고리즘으로 분석하는 것은 정확도의 오차를 증가시킨다. 이에 본 연구는 각 파형의 중요 파라미터를 도출하여 두 파형 사이의 오차를 줄이고, 전체적인 정확도를 높이는 것이 목표이다. 주파수 영역, 시간 영역, 비선형 영역의 3가지 영역에서 총 37가지의 파라미터를 추출하여 XAI(explainable artificial interllingence)를 사용한 결과, 최대 73.8%의 정확도를 얻었으며 오차도 최대 1%미만으로 줄일 수 있었다. 또한, 추가적으로 t-test를 시행하여 파형 별 중요 파라미터를 분석한 결과, 심박변이도 분석에는 SD1/SD2가 중요한 파라미터이며, 맥박변이도 분석에는 NN20, pNN20이 중요한 파라미터임을 알 수 있었다.

Abstract

Analyzing and understanding cognitive load is an important skill for improving HCI (Human-Computer Interaction) skills and preventing accidents. Recently, heart rate variability analysis has been widely used for cognitive load analysis, and as the use of wearable devices becomes more common, the pulse rate variability of photoplethysmogram has been used as a substitute for heart rate variability. However, pulse rate variability and heart rate variability are not compatible in all cases, and analyzing them with the same algorithm increases the accuracy error. Therefore, the goal of this study is to reduce the error between the two waveforms and increase the overall accuracy by deriving the important parameters of each waveform. A total of 37 features were extracted from three domains, frequency domain, time domain, and nonlinear domain, and XAI (explainable artificial interllingence) was used. As a result, an accuracy of up to 73.8% was obtained, and the error was reduced to less than 1% at maximum. In addition, as a result of analyzing important features for each waveform by conducting a t-test, it was found that SD1/SD2 are important parameters for heart rate variability analysis, and NN20, pNN20 are important parameters for pulse rate variability analysis.

Keywords : Cognitive load, SHAP, Features, HRV, PRV

*비회원, 경희대학교 생체의공학과(Department of Biomedical Engineering, Kyung Hee University)

비회원, *정회원, 한국전자통신연구원 디지털융합연구소(Digital Convergence Research Laboratory, Electronics and Telecommunications Research Institute)

© Corresponding Author(E-mail : kim.jk@etri.re.kr)

※ 이 논문은 2023년도 과학기술정보통신부의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(2021-0-00751, 0.5mm 급 이하 초정밀 가시·비가시 정보 표출을 위한 다차원 시각화 디지털 트윈 프레임워크 기술 개발)

Received ; February 24, 2023

Revised ; March 19, 2023

Accepted ; April 5, 2023

I. 서론

인지 부하는 특정 상황 속에서 학습 대상이 인지적인 결정이나 학습을 하기까지 드는 정신적 노력의 수준을 말한다. 대상에게 들어오는 정보의 80%는 시각을 통해 얻어지기 때문에 일부 상황에서는 과도한 인지부하가 발생될 수 있으며, 이는 일상생활에서의 사고를 일으킬 수 있다^[1]. 이에 대상의 인지부하를 측정하고 정량화하는 것은 HCI(Human-Computer Interaction)의 다양한 응용분야에서 향상된 인터페이스를 제시하며, 사고 예방의 측면에서 중요하다. 인지부하의 정량적인 측정은 컴퓨터로 하여금 측정 대상의 상태를 판별할 수 있게 해주는데, 인지 과부하로 인한 스트레스, 인지 과부하로 인한 좌절, 낮은 수준의 인지 부하로 인한 지루함 등을 피할 수 있는 지표로 사용된다^[2].

최근 인지부하를 측정하기 위해 사용되는 주관적인 방식에는 SWAT, NASA-TLX 등이 있다^[3, 4]. 해당 평가 방식은 설문지의 형식으로 이루어지기에 방법이 간단하고 값이 저렴하다는 측면에서 장점이 있다. 그러나, 이는 문화적 차이, 개인의 기억 등에 쉽게 영향을 받아 왜곡될 가능성이 있기에 정량화하기 어렵다는 단점이 존재한다^[1].

이에 선행 연구들은 주관적인 인지부하 측정의 단점을 해결하기 위해서 Electrooculogram(EOG), Heart rate(HR), Electroencephalogram(EEG), Galvanic skin response(GSR), Electrocardiogram(ECG), Photoplethysmogram (PPG) 등 다양한 생체 신호를 도입하였다^[1, 5, 6]. 인간은 신체의 신경계 기능을 조정하여 외부 자극에 대해 반응하는데, 그 반응은 다양한 생체신호에서 각기 다른 생리적 파라미터로 감지된다^[7].

최근 스마트 위치가 보편화되며 스마트 위치에 내장된 센서를 이용하여 인지 부하를 분석하는 것은 일상 생활에서 착용 대상에 대한 사고의 위험을 줄일 수 있다. 또한, 스마트 위치(Samsung Galaxy Watch, Apple Watch)는 PPG 뿐만 아니라 ECG 검출도 가능하기에 많은 연구들은 기기를 통해 수집한 ECG, PPG 등 다양한 생체신호를 기반으로 HR, RRI(R-R interval)의 데이터를 시간, 주파수 축으로 감지하여 기계 학습 알고리즘을 통해 인지 부하를 추론한다. 그 중 스마트 위치에 내장되어 있는 웨어러블 PPG 센서는 손가락, 손목, 이마 등에서 산소 포화도 및 맥박 수를 편리하게 모니터링 할 수 있기 때문에 PPG는 연구 제안 및 임상 의료 행위에서 인지 부하 분석을 위한 ECG의 대체제로

사용된다.

생체신호의 박동 간격은 자율신경계 활동에 영향을 받기 때문에 역으로 자율 신경계의 활동을 유추할 수 있는 지표라고 알려져 있어 인지 부하의 분석에 많이 이용된다. 그 중 HRV(Heart Rate Variability)란 ECG의 RRI 변화를 분석하는 기법이며, 그와 유사한 박동간격 분석 방법으로는 PPG의 PPI(interval between peaks)변화를 나타낸 PRV(Pulse Rate Variability)가 있다^[8, 9]. HRV와 PRV는 심장박동에 의해 발생한다는 공통점이 존재하며, 특히 PRV의 경우 HRV에 비해 측정이 편리하다는 장점이 있어 보편적으로 HRV를 대신하여 많이 사용되고 있다^[10].

그러나, HRV와 PRV는 모든 상황에서 인지부하 판단에 있어 호환 가능한 지표가 아니다. PRV는 혈량 변화를 측정하는 방법인 PPG에 의해 유도되기에 혈관 운동성에 영향을 받을 수 있으므로 상황에 따라 HRV과 차이를 보일 수 있다^[10]. 또한, PPG는 주로 말초에서 측정되기에 ECG에 비해 펄스 전송 경로에 있어 다른 요인에 의해 영향을 많이 받아 PRV와 HRV의 신호는 동일한 정보를 가지고 있다고 보기 어려우며, 피험자가 신체 활동이나 정신적 스트레스를 겪고 있는 경우 두 신호 사이의 일관성은 낮아진다^[11]. Sun^[9]은 PPI와 RRI의 호환성을 5개의 그룹으로 나누어 검증한 결과, 노인 및 당뇨병 같은 환자에게는 PRV가 HRV의 대체 수단으로써 부적합한 것을 확인하였으며 인지부하같은 자율신경 기능을 평가할 때는 추가적인 연구가 필요하다고 주장하였다.

이에 본 연구는 ECG와 PPG에 기반한 인지부하 정확도 차이를 분석하고 그 간극을 줄이고자 open dataset 중 N-back task를 시행한 dataset인 MAUS^[6]만을 선별하였다. N-back test는 피실험자에게 시간에 따라 순차적으로 제시되는 정보 가운데 현재 제시된 자극이 n번 이전에 주어진 자극과 일치할 때 특정 행동반응을 요구하는 인지 과제이다. n의 조정을 통해 인지부하의 정도를 정량적으로 증가시킬 수 있어 인지부하를 분석하는 많은 연구에서 사용되고 있다^[12]. 본 연구에 사용된 MAUS는 PixArt PPG watch와 Procomp Infiniti를 통해 N-back task에 대한 생체신호를 수집하고 신호를 처리하였으며, 신호에 대한 다양한 파라미터를 추출하여 머신 러닝 기법을 통해 인지부하를 감지하였다^[6]. 해당 dataset은 인지부하에 관한 후속 연구에도 사용되었다^[13].

측정된 생체신호에 대한 인지부하의 정도를 판별하

기 위해서는 딥 러닝을 이용한 정확도의 연구가 중요하다^[14, 15]. 그러나, 그 정확도는 다소 낮은 편이기에 기존의 모델보다 상위의 모델이 요구된다. 특히 웨어러블 기기의 특성상 data 전송량의 한계점이 존재하기에 metadata를 이용하여 인지 부하의 파라미터를 검출하는 방법이 필요하다.

최근에는 XAI(explainable artificial intelligence)를 활용한 연구가 각 파라미터의 중요도와 정확도를 높일 수 있다는 점에서 주목받고 있으며^[16, 17], 본 연구에서는 각 신호에서 추출한 파라미터를 가지고 만든 metadata를 통해 전체적인 모델의 크기를 줄이고 정확도를 높일 수 있는 인지부하 검출 기법을 제안한다.

결과적으로 본 연구를 요약해보자면,

- MAUS의 dataset을 사용하여 기존의 연구보다 더 높은 수준의 정확도를 제시한다^[6, 13].
- 수집한 생체신호의 다양한 파라미터들을 바탕으로 통계적 분석과 XAI를 사용한 알고리즘을 통해 각 과정에서 우세한 파라미터들을 추출하여 정확도의 차이를 낮춘다.
- 추출한 파라미터들을 통해 더 적은 data 수로 더 높은 정확도를 도출하여 연산, 처리 능력에 제한된 웨어러블 기기에서도 일상의 인지부하를 관리할 수 있는 기반을 제시한다.

본 논문의 II장에서는 생체신호를 활용한 인지부하 선행 연구들을 소개하며, III장에서는 본 연구에서 사용된 dataset과 연구 접근 방식, 연구 과정에 대해 설명한다. IV장에서는 본 연구의 결과를 정리하며, V장에서는 연구의 한계점, 앞으로의 연구 방향에 대해 제시한다.

II. 선행 연구

CogLoad@UbiComp2020 competition에서는 Microsoft Band 2를 이용하여 PPG 신호를 측정하여 HR과 HRV를 샘플링하였고 해당 CogLoad dataset을 바탕으로 선행연구가 진행되었다^[2, 7, 14]. Borisov^[2]는 CogLoad dataset을 기반으로 mean, minimum, maximum, median, standard deviation, sum, skew의 파라미터들을 분석하여 8개의 LightGBM Ensemble model을 이용한 결과, 66%의 정확도를 얻었다. Tervonen^[7]는 같은 data set을 이용하여 각 data에서 157개의 파라미터들을 추출하고 XGBoost(extreme

gradient boosting)를 이용하여 30초 이하 창 길이의 비교 분석을 진행한 결과, 25초 길이의 창에서 가장 높은 67.6%의 정확도를 얻었다. 그러나, 해당 연구들^[2, 7]은 ECG가 아닌 PPG를 인지부하 판정 지표로 사용하였기에 정확도가 다소 낮은 것을 확인할 수 있다. 이는 MAUS^[6]의 결과에서도 볼 수 있는데, 모든 조건이 같은 상황에서 ECG의 정확도에 비해 PPG의 정확도가 더 낮은 것을 확인할 수 있다.

일반적으로 더 안정된 상태일수록 박동 간격의 변화 정도가 크기에 HRV는 복잡한 양상을 띄며, 반대로 인지부하가 증가하면 교감신경의 활동이 상승하여 심장박동이 빨라지면서 심장의 리듬이 일정해지기에 간격의 변화 정도는 줄어들어 HRV는 일정한 양상을 보인다^[18].

HRV는 일반적으로 시간 영역과 주파수 영역으로 그 파라미터를 나누어 분석할 수 있다. 시간 영역 분석에는 mRR(mean of RR interval), mHR(mean heart rate), SDRR(standard deviation of RRI), RMSSD(root mean square of successive differences) 등의 파라미터들이 사용되며, 주파수 영역 분석에는 VLF(very low frequency), LF(low frequency), HF(high frequency), LF/HF ratio 등의 파라미터들이 사용된다. Hao^[19]는 30명의 피실험자로부터 PPG를 측정하여 PRV를 추출한 후, 선형(시간 영역, 주파수 영역 분석) 및 비선형(Poincaré plot, scatter plot, sample entropy(SampEn) analysis) 분석, Pearson's correlation, t-test를 시행한 결과 HR, SDNN, RMSSD, HF, SD1, SD2 등 PRV에 관한 파라미터들이 인지 부하의 효과적인 식별에 있어 이론적인 근거를 제공함을 증명하였다.

Wang^[20]은 mathematics practice test를 하는 동안의 ECG와 PPG의 신호를 측정하고, 인지부하를 관찰기 위해 각 신호의 파라미터들을 융합하여 SVM(support vector machine), KNN(k-nearest neighbor), DT(decision tree), RF(random forest), XGBoost를 이용한 결과, RF는 최대 94.6%의 정확도를 보인다. Pettersson^[5]은 Maastricht Acute Stress Test 동안의 인지부하를 관찰하기 위해 EOG와 ECG를 측정하고 SVM, XGB, RF를 이용한 결과, RF는 최대 94.4%의 정확도를 보인다. 해당 연구들^[5, 20]은 인지부하에 있어 검출 정확도가 높게 도출되었으나, sampling rate이 다소 높다. 스마트 워치의 data 전송량은 한계가 있기에 앞선 연구들^[5, 20]보다 sampling rate을 낮추는 것이 중요하다. 표 1을 보면, 다음의 연구들^[6, 13]은 앞선 연구

들^[5, 20]보다 sampling rate이 낮은 것을 볼 수 있다. Beh^[6]는 22명의 참가자(2명은 여성)를 대상으로 N-back task를 진행하여 ECG, Fingertip-PPG, Wrist-PPG, GSR의 신호를 얻어 인지부하 dataset을 구축하였다. 구축된 dataset을 바탕으로 HRV를 분석하고 시간 영역과 주파수 영역에서의 파라미터를 추출하여 SVM을 이용한 결과, 최대 71.6%의 정확도를 도출하였다. Radhika^[13]는 HRV에서의 3개 주파수 대역 0-0.04Hz(VLF), 0.04Hz-0.15Hz(LF), 0.15Hz-0.4Hz(HF)으로부터 총 51개의 주파수 파라미터(Peak, relative power, logarithmic powers, absolute power...)을 추출하여 CRNN-SE를 이용한 결과 70.89%의 정확도를 보인다.

표 1. 인지부하 분석에 관한 선행연구
Table 1. Previous literature on cognitive load analysis.

Reference	Dataset	Signals(Hz)	Window Lengths	Model	Accuracy
Borisov ^[2]	Cog-Load	ST(1), GSR(1), HR(1), HRV(1)	30(s)	Ensemble model	0.66
Tervonen ^[7]	Cog-Load	ST(1), GSR(1), HR(1), HRV(1)	25(s)	XGBoost	0.676
Wang ^[20]	Not published	ECG(400) PPG(400)	-	SVM, KNN, DT, RF, XGBoost	0.946
Pettersson ^[5]	Not published	EOG(1000) ECG(1000)	45(s)	SVM, RF, XGBoost	0.944
Beh ^[6]	MAUS	ECG(256)	120(s)	SVM	0.716
Beh ^[6]	MAUS	PPG(256)	120(s)	SVM	0.667
Radhika ^[13]	MAUS	ECG(256)	-	CRNN-SE	0.7089

III. 실험

연구는 ECG, Fingertip-PPG dataset을 기반으로 시행되었으며 주파수 영역과 시간 영역에 대한 파라미터, poincaré plot에 대한 파라미터, 총 37개의 HRV, PRV 파라미터를 추출하였다. 더 적은 data수로 더 높은 인지 부하 분석 정확도를 얻고자 XAI를 통해 중요한 파라미터들이 선별되었으며, 해당 metadata를 바탕으로 SVM, RF, XGBoost을 통해 인지 부하 분석을 진행하였다.




그림 1. 인지 부하 분석 flowchart
Fig. 1. Cognitive load analysis flowchart.

3.1 MAUS data

MAUS data^[6]는 총 22명의 피실험자를 대상으로 ECG, Fingertip-PPG, GSR, Wrist-PPG를 휴식시간 포함 총 47분 동안 256Hz, 256Hz, 256Hz, 100Hz로 샘플링하여 측정한 dataset이다. 전반적인 인지부하 실험은 N-back task로 진행되었으며, trial 시작 전에 5분의 resting 시간을 가진 후 6번의 trial을 시행하였는데 각 trial 사이에는 NASA-TLX를 통한 2분의 주관적 평가 시간을 가졌다. 피실험자는 빠르게 지나가는 숫자 속에서 마지막 N번째 전의 한 자리 숫자를 기억해야 했으며, 자극의 번호와 N번째 전의 숫자가 같을 때 키보드를 눌러야 했다. N에 따라 정신적 부하의 정도는 달라졌으며, 0-back task는 낮은 정신적 부하로 2-back task와 3-back task는 높은 정신적 부하로 간주되었다.

3.2 데이터 가공

인지 부하를 분석하기 위해 우선적으로 MAUS data^[6]에서 HRV와 PRV를 추출하였다. trial 사이의 변화 정도를 정량적으로 파악하기 위해 피실험자 3번의 누락된 resting data를 제외하고 총 21명의 피실험자 data를 사용하여 2분에 90초 overlap을 진행하였으며, 사람마다 다른 baseline wander를 잡기 위해 일부 잡음을 제거한 후 peak detection을 시행하였다.

task 시행 중 키보드를 누르는 등의 움직임에 의해 기존의 생체신호 파형이 왜곡되어 peak이 판별이 불가능한 경우에는 cubic spline interpolation을 진행하여 data를 가공하였다.

3.3 특징 추출

인지부하의 정량적인 분석을 위해 HRV와 PRV에서 18개의 시간 영역 파라미터, 16개의 주파수 영역 파라미터, 3개의 비선형 영역 파라미터들을 추출하였으며, 표 2는 관련 파라미터들이다.

특히, 비선형 파라미터 추출을 위해 poincaré plot을 이용하였는데, 그림 2는 poincaré plot이며 현재 시간을 기준으로 x축은 현재 심장박동의 간격을, y축은 다음 심장박동의 간격을 나타내어 지속적으로 순환하는 심장박동의 상관 관계를 분석하였다. $y = x$ 의 기준선에 있는 점들은 현재와 미래의 심장박동이 동일하다는 것을 의미하며 기준선 아래의 점들은 두 심장박동 사이의 간격이 감소하고 HR이 증가했음을 의미한다^[19]. 반대로 기준선 위의 점들은 두 심장박동 사이의 간격이 증

표 2. HRV, PRV 관련 파라미터

Table 2. HRV, PRV parameters.

Time Features	Frequency Features	nonlinear Features
0) NNL_mean 1) NNL_min 2) NNL_max 3) HR_mean 4) HR_min 5) HR_max 6) HR_std 7) NNL_diff_mean 8) NNL_diff_min 9) NNL_diff_max 10) SDNN 11) REMSSD 12) SDSD 13) NN50 14) pNN50 15) NN20 16) pNN20 17) CV	18) VLF_peak 19) LF_peak 20) HF_peak 21) VLF_abs 22) LF_abs 23) HF_abs 24) VLF_rel 25) LF_rel 26) HF_rel 27) VLF_log 28) LF_log 29) HF_log 30) nLF 31) nHF 32) LF/HF 33) Total	34) SD1 35) SD2 36) SD1/SD2

가하고 HR이 감소했음을 의미한다^[19]. 해당 분석의 파라미터에는 SD1과 SD2가 있는데, SD1은 부교감 신경의 활성화 상태를 반영하는 단기 HRV 측정 파라미터이며, SD2는 교감 신경의 활성화 상태를 반영하는 장기 HRV 측정 파라미터이다^[19]. 따라서, poincaré plot의 SD1과 SD2는 심박의 비선형 동적 시스템을 확인할 수 있는 중요한 파라미터이다.




그림 2. RR interval poincaré plot

Fig. 2. RR interval poincaré plot.

3.4 특징 선별

본 연구에서는 XGBoost를 기반으로 SHAP을 통해 각 과형별 상위 15개의 파라미터를 선별하여 정확도를 추출한다. 또한, 독립 t-test도 진행하여 개별적인 p -value 값을 확인하고, 이를 토대로 인지부하 data에서 HRV와 PRV의 중요 파라미터를 분석하였다.

t-test는 두 그룹의 평균을 비교하는데 사용되는 통계 테스트^[21]로, 2개의 피실험 집단 차이에 대한 타당성을 검증하는 분석 방법이다. t-test를 통해 도출된 p -value 값은 분석 결과를 나타내는 파라미터로, p -value 값이 0.05보다 작을 때 두 집단은 유의미한 차이가 있다고 하며 값이 작을수록 두 집단의 차이에 대한 타당성과 신뢰성은 높아진다.

SHAP은 파라미터에 대한 기계학습 모델의 결과를 해석하는 방법이다^[16]. 각 파라미터의 기여도를 전체에서 해당 파라미터를 제외했을 때의 전체 결과 변화 정도로 표현하기에, 모델에 구애받지 않고 실제로 존재하는 변수들을 바탕으로 전체적인 영역에 대해 파라미터의 중요도를 계산한다는 장점이 있다.

3.5 인지부하 분석을 위한 정확도 분석

인지 부하의 분석은 생체 신호에서 선별된 파라미터들을 이용하여 SVM, RF, XGBoost를 통해 진행되었다. SVM은 두 클래스 간의 margin을 최대화하여 최적의 분리를 진행하는 이진 선형 분류 모델이다^[22]. 해당 모델은 딥 러닝과 ensemble 모델 이전에 가장 성능이 좋은 모델로 다양한 분야에서 활용되어 왔다. RF는 ensemble 모델로 다중 투표, 가중 평균을 사용하여 여러 트리를 결합하는 bagging 방법이 있다^[23, 24]. RF는 일부 데이터와 파라미터를 사용하여 학습하기 때문에 데이터 과적합 위험이 줄어든다. XGBoost는 속도 측면에서 gradient boosting 모델의 성능을 향상시킨 결정 트리 boosting 모델로 기존 GBM의 느린 수행 시간 문제를 해결하였으며 결손 값을 자체적으로 처리하는 알고리즘이다^[23, 25]. boosting 모델은 정확도를 높이고 손실 함수의 기울기를 최소화하고자 이전 분류기의 매개변수를 반복적으로 업데이트한다는 장점이 존재한다^[23].

SVM의 매개변수는 kernel = 'rbf'이며, RF의 매개변수는 number of trees= 50, random_state=123456 이다. XGBoost의 매개변수는 booster = gbtrees, objective = binary:logistic, eta = 0.018, max_depth = 15, gamma = 0.009, subsample = 0.98, colsample_bytree = 0.86 이다.

3.6 유효성 검증

유효성 평가를 위해 21명으로부터 추출한 294개의 전체 data 중 1명의 14개 data (정상 7개, 인지부하 7개)를 test data로 정하고, 이를 반복 교체하여 총 21번의 모델링을 진행하는 LOSO(Leave one Subject out cross validation) 방식을 선택하였다.

IV. 결 과

표 3은 t-test를 기반으로 추출한 p -value 값을 나타낸 것이며, 표 4는 XGBoost 기반 SHAP으로 추출한 파라미터 값에 근거하여 정확도가 높은 상위 15개의 파라미터를 정리한 것이다. p -value 값에 근거하여 같은 파라미터를 기준으로 보았을 때 HRV와 PRV에서 유의미한 차이를 보이는 파라미터는 8, 15, 16, 23, 26, 30,

31, 32, 36이다. 그 중, HRV에서 36의 파라미터는 p -value = 0.009 로 독립적인 통계 특징 분석에서도 PRV와 유의미한 차이가 존재하며, 전체적인(XAI) 파라미터 분석에서도 9번째 중요 파라미터에 존재한다. 이에 36은 HRV 분석에 있어 중요 파라미터라고 할 수 있다. 같은 방법으로, PRV에서 15, 16의 파라미터는 p -value = 0.035, 0.002 로 통계 특징 분석에서 HRV와 유의미한 차이가 존재하며, 전체적인 특징 분석에서도 12, 6번째 중요 파라미터에 존재한다. 이에 15, 16은 PRV 분석에 있어 중요 파라미터라고 할 수 있다.

더 나아가, 표 5는 p -value 값을 바탕으로 정확도가 높은 상위 15개의 파라미터를 순서대로 나타낸 것이다. 22, 33, 10의 파라미터는 HRV와 PRV의 SHAP 중요 파라미터에 공통적으로 포함되어 있으며, p -value 값의 상위 15개 파라미터 선별에도 모두 포함되어 있기에 파형에 대한 변이도의 분석에 유용한 파라미터라고 할 수 있다.

표 3. 파라미터별 p -value

Table 3. p -value for each parameter.

Feature Number	HRV_ p	PRV_ p	Feature Number	HRV_ p	PRV_ p
0	**0.005	**0.006	19	***0.000	***0.000
1	0.816	0.454	20	***0.000	*0.015
2	***0.000	***0.000	21	***0.000	***0.000
3	**0.006	**0.007	22	***0.000	***0.000
4	***0.000	**0.000	23	0.092	***0.001
5	0.818	0.505	24	0.272	0.493
6	***0.000	***0.000	25	0.516	0.930
7	**0.009	***0.000	26	*0.048	0.349
8	0.458	**0.006	27	***0.000	***0.000
9	**0.007	***0.000	28	***0.000	***0.000
10	***0.000	***0.000	29	**0.005	***0.000
11	*0.017	***0.000	30	*0.012	0.331
12	*0.026	***0.000	31	*0.012	0.331
13	***0.000	***0.000	32	*0.012	0.286
14	***0.000	***0.000	33	***0.000	***0.000
15	0.682	*0.035	34	*0.017	***0.000
16	0.170	**0.002	35	***0.000	***0.000
17	***0.000	***0.000	36	**0.009	0.835
18	0.415	0.160			

* $|p| < 0.05$, ** $|p| < 0.01$, *** $|p| < 0.001$

표 4. SHAP 기반 중요 파라미터 상위 15개 선별

Table 4. SHAP-based selection of the top 15 important parameters.

	Important Feature														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
HRV	20	22	9	19	33	1	24	23	36	0	2	28	10	5	16
PRV	1	33	17	35	10	16	36	20	6	22	5	15	19	9	0

표 5. p -value 상위 15개 파라미터 선별

Table 5. Selection of the top 15 p -value parameters.

	Important Feature														
	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
HRV	22	35	28	17	10	33	27	19	21	20	6	4	2	13	14
PRV	17	10	35	33	22	28	6	14	7	34	11	13	27	12	21

표 6은 각 모델에 대한 인지부하 분석 결과 정확도를 기존의 연구와 비교하여 나타낸 것이다. XAI를 이용하여 중요 파라미터를 선별한 결과, SVM 모델에서는 HRV와 PRV 사이의 정확도 차이를 1% 이내로 최소화할 수 있었으며, 그 외의 XGBoost 모델과 RF모델에 대해서는 정확도 차이를 2% 이내로 도출할 수 있었다. 또한, RF 모델에서 73.81%의 가장 높은 정확도를 도출한 점을

표 6. 인지 부하 분석 결과 정확도

Table 6. Accuracy of cognitive load analysis.

Reference	Feature	Model	Evaluation strategy	Accuracy
Beh ^[6]	HRV	SVM	LOSO	0.7160
Beh ^[6]	PRV	SVM	LOSO	0.6670
Radhika ^[13]	HRV	CRNN-SE	-	0.7089
Ours	HRV	SVM	LOSO	0.6973
		RF		0.7381
		XGBoost		0.7177
	PRV	SVM		0.6871
		RF		0.7177
		XGBoost		0.6905

통해 RF모델이 HRV와 PRV의 간극 완화 및 과형 분석에 적합한 성능을 가지고 있음을 확인하며 기존의 연구에 비해 향상된 결과를 보인다.

V. 결론 및 제언

본 연구에서는 정확도 높은 인지부하 분석을 위해 HRV와 PRV의 간극을 낮추고, 각 과형 분석에서의 중요 파라미터에 대해 제안한다. 스마트 워치가 대중화되고 있는 시점에서 PPG를 기반으로 한 PRV는 HRV를 완벽하게 대체할 수 없으며 이는 자율신경의 인지부하 분석에 취약한 단점이다. 이에 그 간극을 최대한 낮추고자 t-test와 SHAP를 이용하여 HRV와 PRV의 중요한 파라미터를 분석하고 정확도를 도출한 결과, PRV와 HRV의 정확도 차이를 줄일 수 있었으며 기존의 연구에 비해 전반적인 정확도를 향상시킬 수 있었다. 다만, 해당 연구는 MAUS^[6]의 data에 제한되어 있으며 추출된 중요 파라미터에 대해서는 임상적인 해석을 포함하지 않았기에, 향후 연구에서는 해당 알고리즘을 다양한 open data에 적용하여 임상적 해석을 포함하고자 한다.

REFERENCES

- [1] X. Fan, C. Zhao, X. Zhang, H. Luo, and W. Zhang, "Assessment of mental workload based on multi-physiological signals," *Technol Health Care*, vol. 28, no. S1, pp. 67-80, 2020.
- [2] V. Borisov, E. Kasneci, and G. Kasneci, "Robust cognitive load detection from wrist-band sensors," *Computers in Human Behavior Reports*, vol. 4, 100116, 2021.
- [3] G. B. Reid, T. E. Nygren, "The Subjective Workload Assessment Technique: A Scaling Procedure for Measuring Mental Workload," *Advances in Psychology*, vol. 52, pp. 185-218, 1988.
- [4] S. G. Hart, L. E. Staveland, "Development of NASA-TLX(Task Load Index): Results of Empirical and Theoretical Research," *Advances in Psychology*, vol. 52, pp. 139-183, 1988.
- [5] K. Pettersson, J. Tervonen, J. Närväinen, P. Henttonen, I. Mänttinen and J. Mäntyjärvi, "Selecting Feature Sets and Comparing Classification Methods for Cognitive State Estimation," *2020 IEEE 20th International Conference on Bioinformatics and Bioengineering (BIBE)*, pp. 683-690, 2020.
- [6] W. K. Beh, Y. H. Wu, A. Y. Wu, "MAUS: A Dataset for Mental Workload Assessment on N-back Task Using Wearable Sensor," *arXiv*, 2021.
- [7] J. Tervonen, K. Pettersson, and J. Mäntyjärvi, "Ultra-Short Window Length and Feature Importance Analysis for Cognitive Load Detection from Wearable Sensors," *Electronics*, vol 10, no 5, p. 613, 2021.
- [8] K. A. Park, J. U. Park, J. W. Lee, H. K. Yang, S. R. Yum, "Empirical Analysis on Elderly Stress in Public Transport Using Physiological Signals," *Journal of Transport Research*, vol 23, no 4, pp. 101-117, 2016.
- [9] C. K. Sun, C. C. Liu, W. M. Liu, H. T. Wu, R. M. Huang, A. B. Liu, "Compatibility of pulse-pulse intervals with R-R intervals in assessing cardiac autonomic function and its relation to risks of atherosclerosis", *Tzu Chi Medical Journal*, vol. 32, no. 1, pp. 41-46, 2019.
- [10] Y. L. Yang, H. Shin, "An Effect of Sampling Rate to the Time and Frequency Domain Analysis of Pulse Rate Variability," *The Transactions of the Korean Institute of Electrical Engineers*, vol. 65, no. 7, pp. 1247-1251, 2016.
- [11] H. Y. Jan, M. F. Chen, T. C. Fu et al, "Evaluation of Coherence Between ECG and PPG Derived Parameters on Heart Rate Variability and Respiration in Healthy Volunteers With/Without Controlled Breathing," *Journal of Medical and Biological Engineering*, vol. 39, pp. 783-795, 2019.
- [12] J. H. Kwon, E. Kim, J. Kim, C. H. Im, D. W. Kim, "Changes in Electrophysiological Activation Due to Different Levels of Cognitive Load," *Journal of Biomedical Engineering Research*, vol. 43, no. 1, pp. 52-60, 2022.
- [13] K. Radhika, R. Subramanian and V. R. M. Oruganti, "Joint Modality Features in Frequency Domain for Stress Detection," *IEEE Access*, vol. 10, pp. 57201-57211, 2022.
- [14] M. Gjoreski et al., "Cognitive Load Monitoring With Wearables-Lessons Learned From a Machine Learning Challenge," *IEEE Access*, vol. 9, pp. 103325-103336, 2021.
- [15] A. Salfinger, "Deep learning for cognitive load monitoring: a comparative evaluation," *Adjunct Proceedings of the 2020 ACM International Joint Conference on Pervasive and Ubiquitous Computing and Proceedings of the 2020 ACM*

- International Symposium on Wearable Computers*, pp. 462-467, 2020.
- [16] J. K. Kim, M. N. Bae, K. Lee, J. C. Kim, and S. G. Hong, "Explainable Artificial Intelligence and Wearable Sensor-Based Gait Analysis to Identify Patients with Osteopenia and Sarcopenia in Daily Life," *Biosensors(Basel)*, vol. 12, no. 3, p. 167, 2022.
- [17] Y. Y. Jo, Y. Cho, S. Y. Lee, J. M. Kwon, K. H. Kim, K. H. Jeon, S. Cho, J. Park, B. H. Oh, "Explainable artificial intelligence to detect atrial fibrillation using electrocardiogram," *International Journal of Cardiology*, vol. 328, pp. 104-110, 2021.
- [18] S. E. Park, J. H. Kim, G. W. Jeung, K. S. Kim, "Assesment of Heart Rate Variability by Integral Pulse Frequency Modulation Model," *The Transactions of the Korean Institute of Electrical Engineers*, vol. 64, no. 5, pp. 799-804, 2015.
- [19] T. Hao, X. Zheng, H. Wang, K. Xu, and S. Chen, "Linear and nonlinear analyses of heart rate variability signals under mental load," *Biomedical Signal Processing and Control*, vol. 77, p. 103758, 2022.
- [20] C. Wang, J. Guo, "A data-driven framework for learner's cognitive load detection using ECG-PPG physiological feature fusion and XGBoost classification," *Procedia Computer Science*, vol. 147, pp. 338-348, 2019.
- [21] T. K. Kim, "T test as a parametric statistic," *Korean J Anesthesiol*, vol. 68, no. 6, pp. 540-546, 2015.
- [22] E. H. Jang, K. W. Choi, A. Y. Kim, H. Y. Yu, H. J. Jeon, S. Byun, "Automated detection of panic disorder based on multimodal physiological signals using machine learning," *ETRI Journal*, pp. 1-14, 2022.
- [23] D. Zhang, L. Qian, B. Mao, C. Huang, B. Huang, and Y. Si, "A Data-Driven Design for Fault Detection of Wind Turbines Using Random Forests and XGboost," *IEEE Access*, vol. 6, pp. 21020-21031, 2018.
- [24] J. K. Kim, K. B. Lee, S. G. Hong, "ECG-based biometric authentication using random forest," *Journal of the Institute of Electronics and Information Engineers*, vol. 54, no. 6, pp. 100-105, 2017.
- [25] G. Park, J. Kim, "Study of Geometry Parameter Variation in Nanosheet Field Effect Transistor using Machine-learning Methods," *Journal of the Institute of Electronics and Information Engineers*, vol. 58, no. 8, pp. 43-48, 2021.

저 자 소 개



김민아(비회원)
2020년~현재 경희대학교
생체의공학과 재학중
2023년~현재 한국전자통신연구원
연구연구생

<주관심분야: 생체신호처리 및 분석>



홍상기(비회원)
1999년 부산대학교 전자공학과
석사졸업
2013년 충남대학교 전자공학과
박사졸업
2001년~현재 한국전자통신연구원
책임연구원

2016년~현재 과학기술연합대학원대학교 컴퓨터
소프트웨어전공 부교수

<주관심분야: IoT 단말 플랫폼, 센서 데이터 처리 및 융합, 임베디드 시스템, 디지털 신호처리>



이강복(비회원)
1993년 경북대학교 전자공학과
학사졸업
2000년 충북대학교
정보통신공학과 석사졸업
2002년 충북대학교
정보통신공학과 박사수료

1993년~2000년 LG 반도체(주) 선임연구원
2000년~현재 한국전자통신연구원 책임연구원
<주관심분야: IoT 디바이스, 생체신호처리, 위험
감지 및 예측>



김정균(정회원)
2015년 대구가톨릭대학교
의공학과 학사졸업
2017년 UST 컴퓨터소프트웨어
석사졸업
2022년 UST 컴퓨터소프트웨어
박사졸업

2022년~현재 한국전자통신연구원 Post-Doc
<주관심분야: 생체신호처리 및 분석, 머신러닝>

