

CNN 기반 HRV 분석을 통한 인지 과제 수행 능력 예측에 관한 연구

류형록, 강우석, 김경호
단국대학교

Classification of Cognitive Task Performance using HRV Features: A Convolutional Neural Network Approach

Hyeong-Rok Ryu, Woo-seok Kang, Kyung-Ho Kim
Dankook University


Abstract - 인지 부하(Cognitive Load)는 고도의 집중력이 요구되는 상황에서 판단 오류를 유발하는 핵심 요인이나, 기존의 기존의 자기보고식 평가는 주관성과 사후 응답 중심의 한계로 실시간·객관적 모니터링에 부적합하다. 이를 해결하고자 본 연구는 비침습적 PPG 센서로부터 얻은 심박변이도(HRV) 특징을 활용했다. 이를 딥러닝 모델과 결합하여 인지 과제(N-Back) 수행 능력을 객관적으로 예측하는 시스템의 가능성을 탐구했다. 실험 결과, 제안된 모델은 AUC 0.99, F1-Score 0.992를 달성하며 인지 부하에 따른 개인의 과제 수행 능력을 성공적으로 분류할 수 있음을 확인했다. 이는 심박 변이도(HRV)와 딥러닝을 결합한 비침습적 실시간 인지부하 모니터링 시스템 개발의 가능성을 시사한다.

1. 서 론

인지 부하(Cognitive Load)는 작업 효율과 안전성에 직결되는 핵심 개념으로, 과도할 경우 주의력 저하 및 의사결정 오류를 유발하여 다양한 현장에서 사고 발생 확률을 증가시킨다.[1] 현장에서는 NASA-TLX와 같은 자기보고식 도구가 쓰였지만 일관성 문제, 사후 응답 중심이라는 실시간성 한계가 존재한다.[2] 이러한 문제의식 속에서, 실시간 모니터링이 가능한 생리적 지표를 활용한 인지 부하 측정이 각광받고 있으며,[3] 특히 심박변이도(HRV)는 자율신경계 변화를 민감하게 반영하여 인지 부하 상태를 나타내는 대표 지표로 보고되었다.[4] 본 연구는 인지 과제(N-Back)의 정답률을 기준으로 '상위/하위'로 라벨링한 PPG 기반 심박변이도(HRV) 특징을 입력받아, '상위/하위'를 분류하는 CNN 모델을 제안하고 그 유효성을 검증한다.

2. 본 론


2.1 시스템 구성



〈그림 1〉 시스템 구성도

〈그림 1〉은 본 연구에서 제안하는 전체 시스템의 구성도이다. 시스템은 크게 데이터 수집 하드웨어, 데이터 전처리, 딥러닝 모델로 구성된다. 데이터 수집 단계에서는 컷볼에 부착된 PPG 센서로부터 아날로그 신호를 획득한다. 이 신호는 아날로그 필터링·증폭 회로를 거쳐 STM32 마이크로컨트롤러에서 디지털화되며, 펌웨어의 실시간 피크 검출 알고리즘이 심박 지점을 식별하여 최종적으로 심박간 간격(IBI, RR)을 산출한다. 산출된 심박간 간격(IBI, RR) 데이터는 Python 기반 환경에서 전처리된다. 먼저 과제 정답률을 기준으로 데이터를 '상위/하위'로 라벨링한 후, 심박변이도(HRV) 특징을 추출한다. 추출된 특징 벡터는 CNN 모델의 입력으로 사용되어, 지도학습 방식으로 인지 과제(N-Back) 수행 능력을 예측하도록 학습된다.

2.1.1 PPG 아날로그 회로




〈그림 2〉 PPG 아날로그 회로도

본 연구에서는 LED와 포토다이오드를 포함한 PPG 센서를 사용했다. PPG 신호 획득을 위한 아날로그 회로도이다. 포토다이오드 신호는 트랜스임피던스 증폭기에서 전압화된 뒤 0.3~30 Hz 대역으로 필터링되고 약 50배 증폭되어 버퍼를 거쳐 ADC로 입력된다.

2.1.2 디지털 신호 필터링

ARM사에서 제공하는 CMSIS-DSP 라이브러리를 이용하여 4차 IIR 대역 통과 디지털 필터를 구현하였다. 이는 PPG 신호의 유효 주파수 대역인 0.5Hz에서 5Hz 사이의 신호만 통과시켜 기저선 변동 및 고주파 잡음을 억제하였다.

2.1.3 심박 변이도(HRV) 특징



〈그림 2〉 심박간 간격(IBI, RR)와 심박 변이도(HRV) 특징

〈그림 2〉는 심박간 간격(IBI, RR)와 심박 변이도(HRV)이다. 심박 변이도(HRV)는 심박간 간격(IBI, RR)의 변화를 정량화한 지표로, 자율신경계의 활동 상태를 간접적으로 보여준다. 본 연구에서는 심박 변이도(HRV)를 시간 영역과 주파수 영역으로 나눠 분석하였다. 시간 영역에서는 심박간 간격(IBI, RR) 데이터의 통계적 특성을 계산했다. 심박 수준은 모든 RR 간격의 산술 평균인 MeanRR은 식(1)로 파악했으며, 총 변동성은 RR 간격의 표준편차인 SDNN은 식(2)로 산출했다. 또한, 연속된 RR 간격 차이의 제곱 평균 제곱근인 RMSSD는 식(3)으로 계산했다. 수식에서 RR_i 는 i 번째 심박 간격(ms)을, N 은 전체 심박수를 의미한다.

$$Mean\ RR = \frac{1}{N} \sum_{i=1}^N RR_i \quad - \text{식(1)}$$

$$SDNN = \sqrt{\frac{1}{N-1} \sum_{i=1}^N (RR_i - MeanRR)^2} \quad - \text{식(2)}$$

$$RMSSD = \sqrt{\frac{1}{N-1} \sum_{i=1}^{N-1} (RR_{i+1} - RR_i)^2} \quad - \text{식(3)}$$

주파수 영역에서는 심박간 간격(IBI, RR) 시계열을 스펙트럼으로 변환하여 파워를 분석했다. 먼저 주파수 f 에 대한 파워 분포인 파워 스펙트럼 밀도 $P(f)$ 를 계산한 뒤, 저주파(LF, 0.04~0.15Hz) 대역의 파워는 식(4)로, 고주파(HF, 0.15~0.40Hz) 대역의 파워는 식(5)로 산출했다. 자율신경계 균형을 나타내는


LF/HF Ratio는 식(6)으로 계산했으며, 이 지표는 인지 부하에 따라 증가하는 경향을 보인다.

$$LFpower = \int_{0.04}^{0.15} P(f)df \quad - \text{식(4)}$$

$$HFpower = \int_{0.15}^{0.40} P(f)df \quad - \text{식(5)}$$

$$LF/HF \text{ ratio} = \frac{LFpower}{HFpower} \quad - \text{식(6)}$$

2.1.4 모델 아키텍처




〈그림 3〉 CNN 모델 블록도

〈그림 3〉은 본 연구에서 제안한 CNN 구조로, 본 연구에서 사용한 모델은 CNN과 Transformer Encoder를 결합한 하이브리드 구조이다. 심박 변이도(HRV) 시퀀스를 60초 길이 윈도우를 4초 간격으로 총 12개의 시간 스텝 2차 데이터가 모델의 입력으로 입력된다. 입력은 두 개의 Conv - BN - GELU 블록으로 구성된 특징추출기에 입력된다. 시간×특징 축의 지역적 표현을 추출한 뒤, 이를 짧은 윈도우로 시퀀스 패치화하여 선형 임베딩을 거친 토큰 시퀀스로 변환한다. 이어 Transformer Encoder는 멀티헤드 셀프어텐션과 피드포워드 서브레이어로 구성되어 토큰 간 상관관계를 학습하고, CLS 토큰의 은닉 벡터를 통해 전역 맥락이 집약된 표현을 얻는다. 최종 분류기는 이 벡터를 저차원으로 축소한 뒤, 활성함수, 드롭아웃을 적용한 완전연결층으로 2차원 출력을 생성하며, 출력층에서 시그모이드 함수를 적용하여 '상위/하위' 이진 분류를 수행한다.

2.1.5 모델 학습 및 평가


모델의 성능은 5 Fold 교차 검증과 홀드아웃 테스트를 순차적으로 수행하여 검증했다. 먼저, 모델의 일반화 성능을 평가하기 위해 5 Fold 교차 검증을 실시했다. 이후, 학습 과정에 사용되지 않은 데이터로 최종 성능을 보고하고자 전체 데이터셋을 훈련(80%) 및 테스트(20%) 세트로 분할하여 홀드아웃 테스트를 진행했다. 모델 학습에는 인지 과제(N-Back) 정답률 중앙값을 기준으로 '상위/하위'로 라벨링된 데이터를 사용했으며, AdamW 옵티마이저(학습률 $3e-4$), 배치 사이즈 64, 드롭아웃 0.3을 공통 적용했다. 클래스 불균형 문제는 손실 함수에 가중치를 부여하여 완화했으며, 최종 성능은 AUC, 정확도, F1-Score로 정량 평가했다.

2.2 실험 결과




〈그림 4〉 상위/하위 그룹의 PPG 및 심박 변이도(HRV) 파형

〈그림 4〉은 인지 과제 수행 능력에 따른 하위(좌)와 상위(우)의 신호 패턴을 비교하여 보여준다. 각 그룹의 패턴은 (a) PPG 신호 파형, (b) MeanRR(파란색), SDNN(주황색), RMSSD(초록색), 그리고 (c) LF/HF Ratio의 그래프로 구성된다.



〈그림 5〉 CNN의 학습 및 검증 과정의 손실 그래프

〈그림 5〉는 Fold 5에서의 모델 학습 과정에 따른 손실 변화를 보여준다. X축은 에포크, Y축은 손실 값을 나타내며, 훈련 손실과 검증 손실이 표시된다. 학습 초기에 훈련 및 검증 손실 값이 모두 빠르게 감소하며 0.1 이하의 낮은 값으로 수렴했다. 이는 새로운 데이터에 대해서도 일반화 성능을 안정적으로 확보했음을 보여준다.



〈그림 6〉 CNN 데이터셋에 대한 혼동 행렬

〈그림 6〉는 Fold 5에서 모델의 분류 성능을 평가한 혼동 행렬이다. 총 140개(하위 그룹 80, 상위 그룹 60)의 검증 데이터에 대해, 모델은 약 99.3%의 높은 정확도를 달성했다. '상위/하위'의 F1-score는 각각 0.992, 0.994로 측정되어 클래스에 편향되지 않은 성능을 입증했다.

3. 결 론

본 연구는 심박 변이도(HRV) 특징과 딥러닝 모델을 활용하여 인지 과제(N-Back)의 수행 능력을 분류하는 시스템의 가능성을 탐구했다. 제안된 모델은 5 Fold 교차검증 및 홀드아웃 테스트를 통해 AUC 0.99, F1-Score 0.992로 인지 과제(N-Back) 수행 능력을 효과적으로 분류할 수 있음을 확인했다. 이는 심박변이도(HRV) 특징과 딥러닝 기술을 결합하여 작업자, 운전자, 군인 등 현장에서의 인지 부하를 객관적으로 모니터링하고, 사고 예방에 기여할 수 있음을 보여준다. 향후 다양한 인지 과제와 사용자 데이터를 추가해 일반화 성능을 강화하고, 임베디드 최적화로 실시간 구현이 기대된다.

감사의 글

본 실적은 단국대학교 산업기술연구소 소속 학부생 연구원이 참여하여 이룩한 연구성과물로서 해당 연구소는 2025년도 단국대학교 대학혁신지원사업 학부생 연구트랙제 사업의 지원을 받았다.

[참 고 문 헌]

- [1] 윤호성, 정은성, 김정룡, "헬리콥터 조종사의 정신적 작업부하가 생리적 반응과 주관적 반응에 미치는 영향", 대한인간공학회지, 제31권, 제1호, pp. 119-125, 2012.
- [2] Hart, S. G., & Staveland, L. E. (1988). Development of NASA-TLX (Task Load Index): Results of empirical and theoretical research. *Advances in Psychology*, 52, 139 - 183.
- [3] 김민아, 홍상기, 이강복, 김정균, "인지부하 감지를 위한 심박 변이도(HRV)와 PRV의 파라미터 중요도 분석", 전자공학회논문지, 제60권, 제5호, pp. 70-77, 2023.
- [4] Massaro, S., & Pecchia, L., "Heart rate variability (심박 변이도(HRV)) analysis: a methodology for organizational neuroscience", *Organizational Research Methods*, Vol. 22, No. 1, pp. 354-393, 2019.