

스마트워치를 통해 실시간 위치 추적되는 신변보호자의 자동 위협 인지 기술 개발

Development of automatic threat detection for real-time location-tracked personal protection via wearable devices

황규원, 유소희, 김지형, 오하은, 김하정, 유재현*

성신여자대학교 AI융합학부

Gyuwon Hwang, Sohee Yoo, Jiyoung Kim, Haeun Oh, Hajeong Kim, Jaehyun Yoo*

School of AI Convergence, Sungshin Women's University

연락처: 02-920-7695 이메일: jhyoo@sungshin.ac.kr

This paper presents the development of an algorithm for detecting physical and psychological threats to personal protection officers using smartwatch sensors, along with a monitoring application. Physical threat detection is defined as a problem of identifying four states using a 1D CNN based deep learning model with acceleration values from an Inertial Measurement Unit (IMU) as input. The four states are defined as walking, running, desk work, and threat. We analyzed the correlation between model identification accuracy and inference time through experiments. Psychological threat detection is defined as a problem of detecting whether the current wearer is in a normal or threatened state using a signal processing algorithm that extracts features from a Photoplethysmography (PPG) sensor and 1D CNN model based algorithm. Notably, motion artifacts due to user movement are a primary cause of PPG signal interference. To remove the effects of motion artifacts, we added a Gaussian Mixture Model (GMM) algorithm to improve inference performance. We derived threat detection performance through subject experiments using a VR horror experience game.

Keywords: Wearable device, smartwatch sensors, policing technology.

1. 서론

사회적 치안과학을 위해 신변보호자에게 보급되는 스마트 워치에는 여러 종류의 센서가 내장되어 있다. 본 연구는 가속도센서를 이용하여 물리적 위협 감지 알고리즘을 개발하고, Photoplethysmography (PPG) 센서를 이용하여 심리적 위협 감지를 개발한다. 각 알고리즘은 자체 제작한 워치 안드로이드 앱을 통해 실험자의 동작, VR게임을 통해 실시간 결과를 도출하였다. 2장에서는 가속도 센서를 이용한 동작 감지 알고리즘 설명과 실험 결과를 기술한다. 3장에서는 PPG 센서를 이용한 심리적 위협 감지 알고리즘 설명과 실험 결과를 설명하며, 4장은 결론을 맺는다.

2. 가속도 센서를 이용한 물리적 위협 감지

2.1. 학습 알고리즘

가속도센서를 통한 데이터 수집의 경우 스마트워치 SM-R900을 사용하여 50Hz의 속도로 가속도 센서 데이터를 수집하였다. 이 데이터는 일상과 위험 상황으로 분류된 동작을 구별하기 위해 사용되었으며, Signal Vector Magnitude (SVM)을 계산하여 다양한 신체 활동의 강도를 정량적으로 평가하였다 Doherty et al. (2017). 일상 상황의 동작은 '걷기', '뛰기', '책상 작업'을 포함하며, 위험 상황은 엎어치기, 밀치기 등 다양한 위험 동작을 통합하여 구성하였다. 주요 학습 모델로 Support Vector Machine (SVM), K-Nearest Neighbors (K-NN), Random Forest, Stochastic Gradient Descent (SCD), 그리고 One-Dimensional Convolutional Neural Network (1D CNN)을 사용하였다. 시간 영역에서는 원시 데이터를 직접 사용하고, 주파수 영역에서는 Fast Fourier Transform (FFT)를 통해 데이터를 변환하였다. 그림 1은 모델 구조를 나타낸다.




Fig. 1. 1D CNN structure in the frequency domain.

2.2. 알고리즘에 대한 비교 실험 결과

Table 1. Model accuracy in time domain and frequency domain.

Model	Accuracy	
	시간 영역	주파수 영역
SVM Kernel: RBF	0.7481	0.4614
SVM Kernel: Linear	0.6904	0.9430
K-NN	0.7610	0.9779
Random Forest	0.7610	0.9688
SGD	0.5882	0.9246
1D CNN	0.9564	0.9746

SM-R900의 가속도 센서로부터 수집된 데이터를 기반으로, 시간 영역과 주파수 영역에서 학습된 모델 별 성능을 평가하였다. 표 1의 결과에 따르면 대부분의 모델은 주파수 영역에서 시간 영역에 비해 더 나은 결과를 보여주었으며, 특히 SGD 모델은 주파수 영역에서 34% 향상되어 가장 눈에 띄는 개선을 보였다. 그러나 SVM 모델 중 RBF 커널은 주파수 영역에서 성능이 28.67% 감소하였다. 이를 통해 RBF 커널의 비선형 특성과 무한 차원 공간에서의 데이터 포인트 간 유사도 측정 방식이 주파수 영역의 데이터 변환에 불리함을 알 수 있다. 반면, 1D CNN은 모든 신호 영역에서 높은 정확도를 보여주지만, 시계열 분석에서 시간 영역은 중요 패턴을 포착하는 능력에 한계가 있어 주파수 영역에서 성능이 더 높게 나왔음을 알 수 있다 Yi et al. (2023).

2.3. 실시간 데이터를 통한 학습 알고리즘 검증

Table 2. Real-time validation results in time domain and frequency domain.

동작 분류	Accuracy	
	시간 영역	주파수 영역
걷기	99%	100%
뛰기	100%	93%
책상 작업	84%	88%
위험	74%	95%
total	89.25%	94%

표 2는 실시간 데이터 검증을 위해 개발된 웨어러블 위치 앱을 통해 각 클래스 별 5분 동안 동작을 수행한 분류 결과의 정확도를 보여준다. 학습 단계에서의 정확도는 시간 영역 95.64%, 주파수 영역 97.46%이다. 그러나 실제 웨어러블 환경에서는 두 신호 영역 모두 학습 단계에서 보다 정확도가 낮게 나타났으며, 이는 웨어러블 위치 사용 중 발생하는 불규칙한 움직임과 큰 동작 등이 성능에 부정적인 영향을 미친 것으로 보인다. 특히 팔의 큰 움직임이 감지된 경우, 모델은 위험 상황으로 잘못 판별하는

경우가 빈번히 관찰되었으며 실시간 환경에서의 알고리즘 최적화의 필요성을 시사한다.

3. PPG 센서를 이용한 심리적 위험 감지

3.1. PPG 신호 전처리 및 위험 감지 알고리즘

PPG 센서의 경우 움직임이나 외부 환경 등의 영향을 쉽게 받아 부정확한 신호를 제거할 필요성이 있으므로 대역 통과 필터를 사용하여 이를 제거한다 Pollreis et al. (2022). PPG 신호 데이터는 긍정 및 부정영상에 따라 파일을 나누어 모든 PPG 데이터를 저장한 뒤 데이터를 12초 단위로 나눈다. 나뉜 데이터는 특정 주파수 성분을 추출하기 위해 차단 주파수 0.5Hz부터 8Hz를 가진 대역 통과 필터(Band-pass filter)를 거친다. 노이즈로 인한 PPG 신호의 피크 검출 어려움 문제를 해결하고자 피크 수를 기반으로 유효 데이터를 판단한다. 이 과정을 거친 12초 단위의 유효 데이터 내에서 피크를 검출하고, 측정된 피크를 중심으로 13개 이전 및 14개 이후의 신호를 추출하여 1.1초 범위를 나타내는 특성 벡터로 변환한다 Lee, et al. (2019).

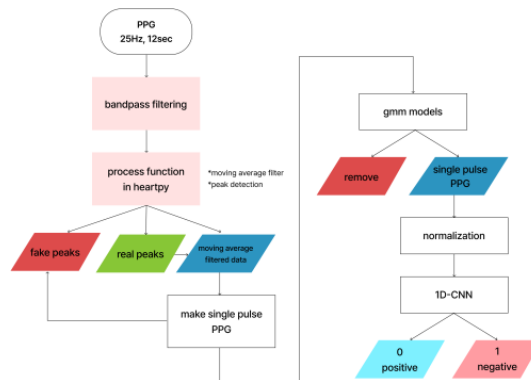


Fig. 2. Visualization of PPG signal preprocessing and prediction algorithm.

또한, 신호에서 긍정 및 부정 감정의 특징을 파악하기 위해 Gaussian Mixture Model (GMM)을 학습한다. 별도로 학습된 모델의 결과에서 한 벡터가 어느 감정에도 속하지 않으면 이상치로 판단 후 제거하고 최소-최대 정규화를 거쳐 전처리를 완료한다. GMM은 각 감정 별 데이터를 Normal과 Anomaly, 총 2개의 요소로 분류하도록 학습하여 평균을 기반으로 한 선택 방법을 통해 한 개의 클러스터를 채택하였다. 이후 훈련 데이터와 테스트 데이터를 일정 비율로 나누어 PPG 신호 학습에 최적 모델인 1D CNN 모델의 학습에 사용한다. 그림 2와 3은 각각 전체 프로세싱 과정과 추론 네트워크를 나타낸다.




Fig. 3. 1D-CNN model structure trained on PPG signals.

3.2. 실험 결과 및 결론

연구에 사용된 데이터 셋의 경우 피험자가 긍정적인 영상과 부정적인 영상을 보는 각각의 PPG 신호를 수집하였다. 실험에 참여한 20대 여성 12명은 1시간 30분으로 구성된 긍정 영상을 시청했고 이후 1세트가 10~20분으로 이루어진 5세트의 부정 영상을 시청했다. PPG 신호 수집은 위치를 실험 참가자들의 손목에 착용시켜 자체 개발한 위치 내의 어플로 측정하였다.

실험에서 수집된 PPG 신호 데이터는 노이즈를 제거하는 전처리 과정을 수행한 후, 위험 상황임을

감지하는 1D CNN 모델의 학습 데이터가 된다. 전처리가 완료된 81,270개의 피크 데이터는 39,609개의 부정 피크, 41,661개의 긍정 피크로 구성되며 전체 데이터의 랜덤한 20%가 Validation data가 된다. 0.01의 learning rate와 50번의 epoch를 통해 학습 결과 정확도 96.87%의 성능을 보여준다.

위험 인지 성능을 평가하기 위해 추가적으로 VR 공포 체험 게임을 활용한 실험을 진행하였다. VR 게임을 통해 수집된 PPG 신호 데이터는 동일한 전처리 과정을 거친 후 위험 인지 모델의 테스트 데이터로 사용하여 성능을 측정하였다. 여러 차례의 테스트를 통해 최적의 판단 기준을 도출한 결과, 판단 지수가 0.73을 초과하면 1로, 0 이상 0.73 이하이면 0으로 설정하였다. 그리고 12초 내에 1의 비율이 30% 이상일 때 이를 위험 상황으로 분류하였다. 이 기준에 따른 평가 결과, 해당 모델은 정확도 71.07%를 기록하여 다른 모델에 비해 우수한 성능을 보였다.




Fig. 4. Visualization of train data and VR test data.

그림 4는 긍정 및 부정 영상을 시청한 후 얻은 데이터를 전처리 알고리즘을 적용해 각각 파란색과 빨간색으로 시각화한 결과를 배경으로 하여 20대 여성이 VR 기기로 공포게임을 플레이하여 얻은 PPG 신호의 피크를 분홍색으로 시각화한 결과이다. 전처리 결과 분홍색은 예상대로 빨간색 피크 범위에 포함된 것을 확인할 수 있다.

4. 결론

본 연구는 신변보호자가 착용하는 위치의 수동 센서를 이용하여 위험을 받았을 때 자동으로 위험을 감지할 수 있는 알고리즘을 보고하였다. 동작 위험과 심리적 위험 두 가지 위험의 형태를 나누었으며 각자 실험자를 통해 고안한 알고리즘의 성능을 도출 및 분석하였다. 추후 연구에서는 중앙 모니터링 서버를 구현하여 신변보호자의 상태를 실시간으로 확인하는 시스템을 개발할 예정이다.

ACKNOWLEDGEMENT

이 논문은 경찰청이 지원한 '사회적 약자 보호 강화 기술 개발(www.kipot.or.kr)'의 지원을 받아 수행된 연구결과입니다. [과제명: 저전력 복합측위, 근접탐색 기술 기반 범죄피해 안전조치 대상자 위치추적 통합관제 플랫폼 개발 / 과제번호: RS-2023-00236101]

REFERENCES

- Doherty, A., Jackson, D., Hammerla, N., Plotz, T., Olivier, P., et al. 2017, Large Scale Population Assessment of Physical Activity Using Wrist Worn Accelerometers: The UK Biobank Study. PLoS ONE, 12(2), e0169649. <https://doi.org/10.1371/journal.pone.0169649>
- Yi, K., Zhang, Q., Cao, L., Wang, S., Long, G., et al. 2023, A Survey on Deep Learning based Time Series Analysis with Frequency Transformation. arXiv, <https://doi.org/10.48550/arXiv.2302.02173>
- Pollreisz, D., TaheriNejad, N., 2022, Detection and Removal of Motion Artifacts in PPG Signals, Mobile Netw Appl 27, 728–738, <https://doi.org/10.1007/s11036-019-01323-6>.
- Lee, M.S., Lee, Y.K., Pae, D.S., Lim, M.T., Kim, D.W., et al. 2019, Fast Emotion Recognition Based on Single Pulse PPG Signal with Convolutional Neural Network. Appl. Sci., 9, 3355. <https://doi.org/10.3390/app9163355>