

스마트워치 기반 개인 이상 탐지를 위한 통계 및 재구성 방법 통합 접근

박주연[○], 박해름, 유재현

성신여자대학교 AI융합학부

20221365@sungshin.ac.kr, 20231367@sungshin.ac.kr, jhyoo@sungshin.ac.kr

An Integrated Statistical and Reconstruction-Based Approach for Personalized Anomaly Detection Using Smartwatches

JuYeon Park[○], HaeReum Park, JaeHyun Yoo

School of AI Convergence, Sungshin Women's University

20221365@sungshin.ac.kr, 20231367@sungshin.ac.kr, jhyoo@sungshin.ac.kr

요 약

본 논문에서는 스마트워치로 수집한 개인별 데이터를 기반으로 두 가지 이상 탐지 방법을 제안한다. 첫 번째는 K-means 클러스터링으로 사용자의 행동 상태를 모델링하고 Mahalanobis distance로 이상을 탐지하는 확률 기반 방법이며, 두 번째는 UniTS 기반 Transformer가 정상 패턴을 재구성하고 그 오차로 이상을 판별하는 재구성 기반 방법이다. 두 방법 모두 사전 레이블 없이 개인별 정상 패턴을 학습하는 비지도 방식을 채택하여 개인차가 큰 생체 신호 환경에서도 적용 가능하도록 설계하였다. 두 방법은 각각 해석 가능성과 시계열 패턴 포착 능력 측면에서 상이한 강점을 가진다. 실험 결과, 두 방법 모두 HR 급상승과 HRV 동반 감소라는 자율신경계 이상의 전형적 징후를 탐지하였으며 이는 생리적으로 유의미한 결과이다.

1. 서 론

스마트워치는 HR, HRV, 활동량 등의 생체 신호와 주변 음압, 조도 같은 환경 신호를 일상 속에서 수집할 수 있어, 건강 이상의 조기 감지 및 위험 상황의 1차 탐지 수단으로 가능성을 지닌다. 이상 탐지를 저전력 신호 기반의 1차 감지 모듈로 활용해 정밀 분석의 트리거로 삼는 구조가 실용적이다. 그러나 기존 이상 탐지 방식은 단순 임계값에 기반해 맥락 정보를 반영하지 못하고, 개인차가 큰 생체 신호에 범용 기준을 적용할 경우 오탐이 발생하기 쉽다.

* 이 논문은 경찰청이 지원한 '사회적 약자 보호 강화 기술 개발(www.kipot.or.kr)'의 지원을 받아 수행된 연구입니다.
[과제명: 저전력 복합측위, 근접탐색 기술 기반 범죄피해 안전조치 대상자 위치추적 통합관제 플랫폼 개발 / 과제번호: RS-2023-0023610]

이에 본 연구는 개인화된 정상 패턴을 자동으로 학습하기 위한 행동 상태별 정상 분포를 명시적으로 모델링할 수 있는 확률 기반 방법과 시계열 패턴 전체를 학습하는 재구성 기반 방법을 제안한다. 두 방법을 통해 스마트워치 기반 개인화 이상 탐지의 실용적 가능성을 탐색한다.

2. 데이터 수집

본 연구는 2인의 피험자가 각자의 스마트워치를 일상적으로 착용하며 수집한 개인별 시계열 데이터를 사용한다. 각 피험자의 데이터는 독립적으로 활용되어 통계 기반 및 재구성 기반 이상 탐지 모델의 학습과 평가에 각각 사용되었다.

데이터는 10초 간격으로 연속 수집되었으며, 생체 신호와 환경 신호의 두 범주로 구성된다. 생체 신호로는 심박수(HR),

심박변이도(HRV), 분당 걸음 수(steps)를 수집하였고, 환경 신호로는 주변 조도(lux) 및 음압 레벨(dBFS)을 수집하였다. 사용자가 일상적으로 방문하는 장소의 공간적 맥락을 반영하기 위해 Wi-Fi SSID로 사용자의 위치를 식별하는 장소 컨텍스트 정보를 함께 기록하였다.

3. 통계 기반 이상 탐지

3.1 특징 추출 및 정규화

수집된 데이터에서 물리적 기준과 유효성 변수에 따라 센서 이상값을 제거 후, 슬라이딩 윈도우를 적용한다. 각 윈도우의 모든 변수의 평균을 통계적 특징으로 추출하였고 장소 정보는 원-핫 인코딩 방식으로 반영하였다. 각 특징은 해당 구간의 전반적인 상태를 요약하는 값으로, 상태별 데이터 간의 관계성을 반영하는데 사용된다. 거리 기반 클러스터링에서 변수 간 스케일 차이의 영향을 제거하기 위해 StandardScaler로 각 특징을 정규화하였다.

3.2 K-means 기반 상태 모델링

추출된 특징 벡터를 기반으로 사용자의 행동 상태를 모델링하기 위해 K-means 클러스터링을 적용하였다. K-means는 비지도 학습 알고리즘으로 사용자별 베이스라인 데이터를 기반으로 상태를 구분할 수 있다. 정규화된 특징 벡터 x 에 대해 군집 내 분산을 최소화하도록 클러스터 중심을 반복적으로 갱신하며, 다음과 같은 목적 함수를 최소화한다. [1]

$$\sum_{i=1}^K \sum_{x \in C_i} \|x - \mu_i\|^2$$

여기서 C_i 는 i 번째 클러스터, μ_i 는 해당 클러스터의 중심이다. 데이터를 모두 정상 상태로 정의하여 각 클러스터를 정상 모드(mode)로 표현하고, 이를 이상 탐지의 기준으로 활용한다.

3.3 Mahalanobis 기반 이상 탐지

입력 데이터에 모드를 판별한 후, 각 모드의 정상 패턴을 기반으로 이상 탐지를 수행한다. 데이터와 모드 간의 차이를 파악하기 위해 Mahalanobis distance를 사용하였다. 동일한 센서 값이라도 상태에 따라 정상 여부가 달라질 수 있으므로 모드별 임계값을 $T = 0.99$ 로 설정하여 이상치를 감지하였다. Mahalanobis distance는 다음과 같이 정의된다.


$$D^2 = (x - \mu)^T \Sigma^{-1} (x - \mu)$$

여기서 Σ 는 해당 상태의 공분산 행렬을 의미한다. 계산된 거리는 anomaly score로 사용되며, 설정된 임계값과 비교하여 이상 여부를 판단한다.

3.4 결과 및 평가

제안한 방법의 성능을 분석하기 위해 탐지 데이터에 대해 모드별 PCA 시각화를 수행하였다. 탐지 데이터는 실제 측정 데이터를 기반으로, 외부 활동 상태에서 심박 변동성이 없는 경우와 주거 환경에서 높은 심박수와 낮은 HRV를 가지는 경우와 같은 이상 시나리오를 가정하여 수정하였다.

Mode 0은 주거 환경에서 낮은 HR과 활동량, 낮은 조도 및 소음을 특징으로 하는 정적 상태로, 휴식 또는 수면 상태로 해석된다. Mode 1은 근무 환경에서 심박수와 활동량이 증가한 일상 활동 상태를 반영한다. 전체적으로 PCA 시각화 결과, 이상 데이터는 동일 모드 내 정상 데이터 분포의 경계 또는 저밀도 영역에 위치하여 확률 기반 이상 탐지가 효과적으로 동작함을 확인하였다.



[그림 1] 통계 기반 이상 탐지 데이터 PCA 그래프

4. 재구성 기반 이상 탐지

4.1 특징 추출 및 시퀀스 구성

데이터에 대해 크기 5분, 이동 간격 2.5분의 슬라이딩 윈도우를 적용하여 인접 윈도우 간 50%가 중첩되도록 하였다. 각 윈도우에서 [표 1]과 같이 다섯 범주의 특징을 추출하였다. 모델 입력을 위해 연속 윈도우를 길이 $L = 8$ 의 시퀀스로 묶었다. 각 시퀀스는 과거 구간(PAST, $P = 4$)과 미래 구간(MASK, $M = 4$)으로 구성된다.

[표 1] 추출한 특징 정의

범주	특징명	설명
심박수 (HR)	hr_mean, hr_trend, hr_std	윈도우 내 평균, 추세, 표준편차
심박변이도 (HRV)	hrv_mean, hrv_std, hrv_valid_ratio	평균, 표준편차, 측정 신뢰도 비율
활동량	steps_mean, steps_std	분당 걸음 수 평균 및 표준편차
환경	dbfs_mean, hour_sin, hour_cos	주변 음압 레벨 평균 및 시간 원형 인코딩
윈도우 간 변화량	delta_hr_mean, delta_hrv_mean	직전 윈도우 대비 HR, HRV 변화량

4.2 UniTS 기반 모델 구조

본 연구는 통합 다중 태스크 시계열 모델인 UniTS [2] 아키텍처를 기반으로, 과거 구간의 데이터 패턴으로부터 미래 구간을 재구성하는 방식으로 이상을 탐지한다. 입력 시퀀스에서 미래 구간($t > P$)의 목표 특징(HR, HRV)은 학습 가능한 마스크 토큰으로 대체하고, 모델이 과거 패턴만을 참조해 이를 복원하도록 학습한다. 보조 특징(활동량, 시간, 장소 맥락)은 마스킹하지 않고 재구성의 맥락 정보로 활용한다. 마스킹된 입력은 다음과 같이 정의되며, 여기서 $\mathbf{x}_t^{\text{aux}}$ 는 시점 t 의 보조 특징 벡터이다.

$$\tilde{\mathbf{x}}_t = \begin{cases} \mathbf{x}_t & (t \leq P) \\ [\mathbf{m}; \mathbf{x}_t^{\text{aux}}] & (t > P) \end{cases}$$

모델은 토큰 임베딩, Transformer 인코더, 재구성 헤드의 세 모듈로 구성된다. 토큰 임베딩 레이어는 각 시점의 특징 벡터를 임베딩 차원 $d_{\text{model}} = 128$ 로 선형 투영하고 위치 임베딩($\mathbf{p}_{\text{pos}}$)을 더하여, Transformer 인코더가 과거 구간을 참조해 마스킹된 미래 구간을 복원한다.

$$\mathbf{H} = \text{Linear}(\tilde{\mathbf{X}}) + \mathbf{p}_{\text{pos}}$$

재구성 헤드는 미래 구간의 인코더 출력을 목표 특징으로 선형 투영하여 최종 재구성 값 $\hat{\mathbf{y}} \in \mathbb{R}^{M \times n_{\text{target}}}$ 을 출력한다.


4.3 재구성 오차 기반 이상 탐지

모델은 정상 데이터만을 학습하므로 학습 과정에서 관찰되지 않은 이상 패턴에 대해 높은 재구성 오차를 출력한다. 각 윈도우의 이상 점수는 미래 구간의 재구성 MSE로 정의하고, HRV 측정 신뢰도가 낮은 경우 오차 기여도를 0.3배로 줄여 허위 탐지를 완화하였다. 이상 판정 기준은 훈련 오차 분포에 대해 극단값 이론 기반의 POT (Peaks Over Threshold) 방법으로 결정한다. 훈련 오차의 95번째 백분위수를 기준값으로 이를 초과하는 오차에 일반화 파레토 분포(GPD)를 적합하여 위험 수준 $q = 0.005$ 에 해당하는 임계값 z_q 를 산출한다. 최종 이상 판정은 보정 오차 e^{adj} 의 임계값 z_q 를 초과하는지에 따라 결정된다.

$$\hat{\mathbf{y}}^{\text{anomaly}} = 1[e^{\text{adj}} > z_q]$$

4.4 결과 및 평가

재구성 오차 분석 결과, 대부분의 정상 윈도우는 오차 0.02 미만에 분포하였고, POT 기반 임계값 0.1444는 정상 분포와 분리된 극단 영역에 위치하였다. 테스트 구간에서 임계값을 초과한 이상 윈도우는 총 6개(약 1.5%)이며, 최대 오차는 정상 평균 대비 약 38배에 달하였다. 이는 모델이 정상 패턴은 안정적으로 재구성하면서 이상 구간은 명확히 구분하였음을 보여준다.



[그림 2] 하루 동안 HR, HRV 및 재구성 오차 시계열과 임계값 초과 이상 구간

[그림 2]에 따르면 이상 탐지 구간에서는 HR이 100~122bpm으로 상승하고 HRV가 17~29ms로 감소하는 양상이 나타났다. 이는 교감신경 우세 또는 자율신경계 불안정 상태와 관련된 생리적 변화로 해석된다.

5. 결론

본 연구에서는 스마트워치 데이터를 이용해 확률 및 재구성 기반의 이상 탐지를 구현하고 검증하였다. 확률 기반 방법은 적은 데이터로도 베이스라인 구축이 가능하고 추론 복잡도가 낮아 경량 환경에 적합하며, 이상 원인을 특징값의 편차로 직접 설명할 수 있어 해석 가능성이 높다. 재구성 기반 방법은 데이터의 복합적 시계열 이탈 패턴을 포착하며, 단일 시점의 값이 아닌 시간적 흐름 전체를 학습하기 때문에 일시적인 노이즈나 순간적 변동에 덜 민감하고 지속적인 이상 패턴을 보다 안정적으로 탐지할 수 있다.

두 방법 모두 생리적으로 유의미한 이상 구간을 도메인 지식과 일치하는 방식으로 탐지하였음을 확인하였다. 다만 두 방법 모두 실제 레이블 없이 가정된 시나리오 기반으로 평가되어 정량적 검증에 제약이 있으며, 단일 사용자 데이터에 의존하므로 다양한 사용자 환경에서의 일반화 가능성에 대한 추가 검증이 필요하다. 향후에는 수집 데이터와 피험자 수를 확대하고, 두 방법의 탐지 결과의 양상별 방향으로 발전시켜 신뢰도를 높일 계획이다.

참 고 문 헌

- [1] J. MacQueen, "Some Methods for Classification and Analysis of Multivariate Observations," Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, Vol. 1, pp. 281–297, 1967.
- [2] Gao, S., Koker, T., Queen, O., Hartvigsen, T., Tsiligkaridis, T., Zitnik, M., "UniTS: A Unified Multi-Task Time Series Model," Advances in Neural Information Processing Systems (NeurIPS 2024), Vol. 37, 2024.