

스마트 돌봄 환경을 위한 움직임 센서 기반 시계열 이상행동 예측 모델 설계

김지현, 이성학, 방진숙*

*호서대학교 컴퓨터공학부

e-mail: suri0323@naver.com / reia02verse@gmail.com / bluegony@hoseo.edu

Design of a Time-Series Anomaly Prediction Model Based on Motion Sensors for Smart Care Environments

Ji-hyeon Kim, Seong-hak Lee, Jin-suk Bang*

*Dept. of Computer Engineering, Hoseo University

요 약

고령화 심화로 독거노인의 고독사, 장시간 움직임 부족에 따른 욕창, 돌봄 인력 부족이 중대한 사회 문제로 대두되고 있다. 이러한 문제를 완화하기 위해서는 착용 부담이 없는 비침습·무구속 방식으로 사용자의 움직임을 실시간 감지하고, 위험 징후를 조기에 예측·경고하는 기술이 필요하다. 단순 임계값 기반 규칙은 개인별 활동 편차와 시간적 맥락을 충분히 반영하지 못하므로 시계열의 구조를 학습하는 인공지능 접근이 요구된다. 본 연구는 압력 기반 움직임 센서에서 수집한 시계열 데이터를 이용하여 환자의 위험을 4단계 수준으로 감지·예측하는 모델을 설계한다. 위험을 판단하는 이상 현상은 장시간 무움직임, 동일 체압 분포의 지속으로 추정되는 자세 고정, 과한 뒤척임으로 나타나는 불편·통증 신호, 침대 이탈/재착석 패턴의 비정상 반복 등으로 정의한다. 시계열 특성을 효과적으로 포착하기 위해 CNN-LSTM 계열과 Temporal Convolutional Network(TCN) 두 구조를 적용하였다. CNN-LSTM은 국소 패턴을 추출하고 LSTM으로 시간적 종속성을 모델링하는 데 강점이 있고, TCN은 인과팽창 합성곱 기반으로 장기 의존성을 효율적으로 학습하며 병렬 연산에 유리하다. 4단계의 위두 모델의 구조 설계를 정립하고 동일 데이터 조건에서 비교함으로써 압력센서 시계열의 이상 징후 조기 인지에 적합한 최적 설계 방향을 도출한다. 본 연구의 결과는 단순 경고를 넘어 요양·재택 돌봄 환경에서의 선제 대응 시나리오로 확장될 수 있으며, 동일한 설계를 저자원 MCU, 임베디드로 이식해 상시 온디바이스 감지 체계를 구현하는 기반이 된다. 본 설계 논문은 움직임 센서 시계열에 특화된 AI 구조의 정교한 설계·비교 프레임워크를 제시하여 스마트 돌봄 분야의 재현 가능한 베이스라인과 설계 지침을 제공한다.

1. 서론

최근 한국 사회는 급격한 고령화에 따라 독거노인 가구 증가, 고독사, 돌봄 인력 부족 등 새로운 사회 문제가 주목받고 있다. 이는 개인의 삶의 질을 위협하는 동시에 사회 전반의 돌봄 부담을 심화시키는 요인으로 작용한다. 특히 거동이 불편한 노인이나 환자의 경우 장시간 움직임 부족은 욕창과 같은 심각한 합병증을 유발할 수 있다. 따라서 착용 부담이 없는 비침습적 센서를 활용하여 움직임을 실시간 감지하고 위험 징후를 조기에 예측하는 기술이 필요하다.

기존의 임계값 기반 감지 시스템은 개인별 활동 편차나 시간적 맥락을 충분히 반영하지 못해 불필요한 알람을 발생시키거나 실제 위험 상황을 놓칠 수 있다. 이를 보완하기 위해서는 시계열 데이터의 시간적 패턴과 복잡한 상관관계를 학습할 수 있는 인공지능 모델의 도입이 요구된다.

본 연구는 스마트 매트 압력 센서를 통해 수집된 시계열 데이터를 활용하여 장시간 부동자세, 자세 고정, 과도한 뒤척임, 비정상적 침대 이탈 등 이상 행동을 감지하고 환자의 위험도를 4단계로 예측하는 딥러닝 모델을 설계한다. 이를 위해 단기 패턴 추출과 시간적 종속성 학습에 강점이 있는 CNN-LSTM 모델과 장기 의존성 학습에 효율적인 Temporal Convolutional Network(TCN)를 적용하여 동일 조건에서 성능을 비교한다. 연구 결과는 단순 경고를 넘어 요양 및 재택 돌봄 현장에서 활용 가능한 선제 대응 체계 마련에 기여할 수 있다. 또한 제안된 모델을 MCU나 임베디드 환경으로 이식함으로써 상시 온디바이스 감지 체계를 구현할 기반을 제공한다. 궁극적으로 본 연구는 압력 센서 시계열 데이터에 특화된 AI 모델 설계 및 비교 프레임워크를 제시하여 스마트 돌봄 분야의 연구자들에게 재현 가능한 기준과 명확한 설계 지침을 제공하고자 한다.

2. 관련 연구

최근 시계열 데이터 기반의 분석 모델은 다양한 센서 데이터를 활용하여 인간의 상태와 행동을 정량적으로 파악하는 데 널리 적용되고 있다. 특히 CNN과 LSTM을 결합하거나 TCN 기반 모델을 적용하는 사례가 증가하면서, 단기적인 움직임 변화와 장기적인 패턴 누적을 동시에 고려하는 연구가 활발히 진행되고 있다.

CNN-LSTM 계열 모델은 지역적인 특징 추출과 시간적 의존성 학습을 동시에 수행할 수 있다는 점에서 주목받고 있다. 웨어러블 센서 데이터를 CNN-LSTM에 self-attention을 추가한 구조로 처리한 연구에서는 다양한 human activity recognition(HAR) 데이터셋에서 기존 CNN 또는 RNN 기반 모델보다 우수한 성능이 보고되었다[1]. 또 다른 연구에서는 DeepConvLSTM 구조를 경량화하여 TinyML 환경에서도 높은 정확도와 실시간성을 유지할 수 있음을 보여주었다[2].

한편, TCN은 팽창 합성곱(dilated convolution)과 잔차 연결(residual connection)을 통해 긴 시계열 의존성을 효율적으로 처리할 수 있는 장점이 있다. ResNet-TCN과 attention을 결합한 연구에서는 단일 채널 EEG 기반 수면 단계 분류에서 86% 이상의 정확도를 달성하였으며[3], Multi-Level TCN 구조를 적용한 연구에서는 intra-epoch 및 inter-epoch 문맥, 장시간 추세를 동시에 학습할 수 있음이 확인되었다[4].

센서 데이터를 활용한 모델 학습은 수면·활동 인식뿐만 아니라 다양한 주제에서도 응용되고 있다. 좌석 압력 센서를 이용해 앉은 자세를 분류하는 시스템에서는 CNN 기반 딥러닝 모델이 압력 분포 패턴을 효과적으로 학습할 수 있음이 확인되었고[5], 뇌파(EEG) 신호를 활용하여 감정 상태를 분류하는 연구에서도 LSTM 구조가 효과적으로 적용되었다[6]. 또한 스마트홈 환경에서 IoT 센서 데이터를 활용한 연구에서는 TCN 기반 모델이 이상 행동 탐지와 낙상 감지에 성공적으로 적용된 바 있다[7].

이와 같이, CNN-LSTM 계열 하이브리드 구조와 TCN 기반 모델은 센서 데이터의 시간적 패턴을 효과적으로 학습할 수 있다는 점에서 공통적인 강점을 보인다. 그러나 기존 연구들은 주로 수면 단계 분석이나 일반적인 활동 인식에 초점을 두고 있으며, 압력 센서와 환경 센서를 동시에 활용하여 욕창 위험 단계를 장기적으로 예측하는 연구는 부족하다. 따라서 본 연구는 CNN-BiLSTM 모델과 TCN 모델을 직접 비교하여, 압력·온습도 센서 기반 욕창 위험 예측 문제에 적용함으로써 기존 연구의 한계를 보완하고자 한다.

3. 모델 설계

3.1 데이터 전처리

본 연구에서 사용된 데이터는 스마트 온열매트에 부착된 압력

센서(FSR 6개), 온도 센서, 습도 센서를 통해 수집된 시계열 데이터이다. 센서는 약 2초 간격으로 측정되며, 하나의 데이터 레코드는 [시간, FSR_top×3, FSR_bottom×3, 온도, 습도] 구조를 가진다.

FSR 값은 자세와 움직임에 따라 다르게 나타난다. 예를 들어, 상단 3개 센서값이 모두 2000 이상으로 측정될 경우, 상체에 압력이 집중되어 ‘상체 기울임’ 또는 ‘엎드림’ 상태일 가능성이 크다. 반대로 하단 3개 센서값이 낮고 상단 센서만 높다면 다리 쪽 자세 변화를 의미할 수 있다. 모든 센서 값이 큰 변화 없이 일정하다면 자세 유지 상태로 해석할 수 있다. 이러한 센서 패턴을 통해 환자의 미세한 움직임과 장시간 자세 고정을 모두 포착할 수 있다.

욕창 위험 단계는 기존 임상 가이드라인과 선행 연구 [8-10]를 참고하여 4단계로 분류하였다.

단계	명칭	동일 자세 유지 시간	압력 조건	온습도 조건
0단계	정상	< 30분	정상 범위	정상
1단계	주의	≥ 30분	센서 압력 ≥ 3000, 10분 이상 지속	온습도 상승
2단계	위험	≥ 2시간	과압 40분 이상	습도 ≥ 80% 또는 온도 > 34°C
3단계	매우 위험	≥ 4시간	국소 과압 지속 및 움직임 없음	습도 ≥ 90%

[표 1] 욕창 위험 단계 분류 기준

모델 입력은 센서 데이터를 일정 구간 단위의 윈도우로 분할한 결과이다. 단기 윈도우는 길이 60~120초, 보폭 10~30초로 설정하여 미세 움직임 패턴을 탐지하는 데 사용된다. 중·장기 윈도우는 길이 10~60분, 보폭 5~10분으로 설정하여 동일 자세의 지속 및 누적 위험을 탐지하는 데 활용된다. 최종 입력 텐서는 [batch_size, time_steps, 8 channels] 형태로 모델에 제공된다.

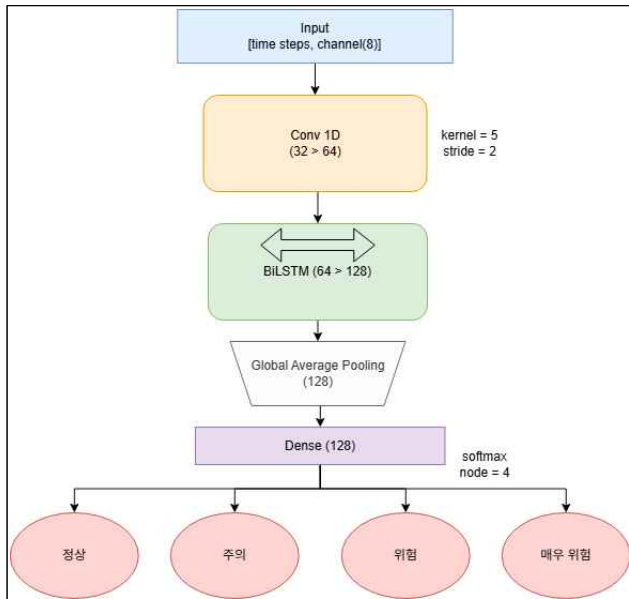
3.2 CNN-BiLSTM

CNN-BiLSTM 모델은 합성곱 신경망(Convolutional Neural Network, CNN)과 양방향 장단기 메모리 네트워크(Bidirectional LSTM)를 결합한 구조이다. CNN 계층은 입력 시계열에서 국소적 패턴(local pattern)을 감지하는 역할을 하며, 필터를 통해 압력 변화나 센서 간 불균형과 같은 저수준 특징을 자동으로 추출한다. 이러한 과정은 짧은 시간 간격 내에서 발생하는 급격한 체중 이동, 압력 집중, 미세 뒤척임 등과 같은 패턴을 효과적으로 포착할 수 있도록 한다.

다단계 Conv1D 블록을 통과한 특징 맵은 BiLSTM 계층으로 전달된다. BiLSTM은 순방향과 역방향의 두 LSTM 계층을 결합

한 구조로, 특정 시점의 상태를 예측할 때 앞선 시점뿐만 아니라 이후 시점의 정보까지 동시에 활용할 수 있다. 이는 압력 패턴이 시간에 따라 점진적으로 변화하거나 장기적으로 유지되는 상황(예: 동일 자세 유지)에 대해 더 정교한 분석을 가능하게 한다.

마지막으로 전역 평균 풀링(Global Average Pooling) 계층을 통해 전체 시퀀스 정보를 요약하고, 완전연결층(Dense Layer)과 Softmax 출력을 통해 욕창 위험 단계를 분류한다. 이 구조의 장점은 CNN이 세밀한 단기 패턴을 빠르게 감지하고, BiLSTM이 시간 의존적 누적 변화를 보정한다는 점이다. 기존 연구들에서도 CNN-LSTM 구조는 웨어러블 센서 기반 인간 활동 인식[11] 및 수면 단계 분류[12] 문제에서 효과적인 성능을 보인 바 있다. 본 연구에서는 CNN-BiLSTM이 미세한 자세 변화나 짧은 시간 간격에서 발생하는 위험 신호를 포착하여 초기 경고 성능을 향상할 것으로 기대된다.



[그림 1] CNN-BiLSTM 구조도

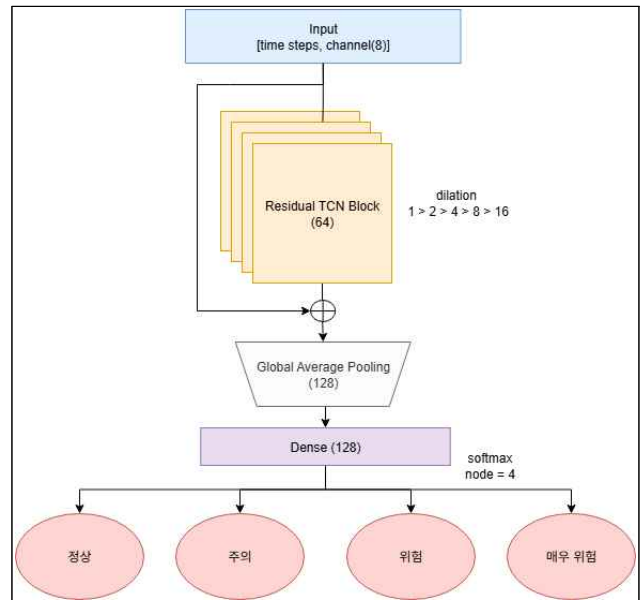
3.3 TCN

TCN은 시간적 합성곱(Temporal Convolution)을 기반으로 한 모델로, 팽창 합성곱(Dilated Convolution)과 잔차 연결(Residual Connection)을 핵심으로 한다. 팽창 합성곱은 합성곱 필터 사이에 공백(dilation)을 두어 한 층만으로도 넓은 시간 범위를 포착할 수 있게 하며, 여러 층을 쌓으면 수십 분에서 수 시간에 해당하는 시계열 문맥을 커버할 수 있다. 이러한 방식은 RNN처럼 순차적으로 계산하지 않아도 되기 때문에 병렬 연산이 가능하고, 학습 및 추론 속도에서 유리하다.

잔차 연결은 깊은 네트워크에서도 기울기 소실 문제를 완화하고 안정적인 학습을 돕는다. 본 연구에서 설계된 TCN은 3~5 크기의 커널을 사용하고, 팽창 계수(dilation factor)를 1, 2, 4, 8,

16으로 확장하여 시계열의 단기적 변동과 장기적 누적 패턴을 동시에 포착하도록 구성하였다. TCN에서 추출된 시계열 특징은 마지막에 공통된 분류기 구조를 거쳐 위험 단계로 매핑된다. 구체적으로, 전역 평균 풀링으로 시간 축 정보를 집약한 뒤 완전 연결층과 Softmax 계층을 통해 최종적인 위험 단계를 산출한다. 이 과정은 CNN-BiLSTM과 동일하나, TCN은 앞선 합성곱 블록에서 이미 장기적인 의존성과 누적 패턴을 효과적으로 반영하기 때문에, 결과적으로 장기 자세 유지와 환경 요인 누적에 따른 위험 단계 예측에서 더 유리하게 작용한다.

TCN의 특징은 단기 움직임 탐지보다는 장기간 자세 고정 및 압력 누적과 같은 중장기 패턴 학습에 적합하다는 점이다. EEG 기반 수면 단계 분류 연구에서는 ResNet-TCN+attention 구조가 86% 이상의 정확도를 보고하였으며[13], Multi-Level TCN 구조는 intra-epoch 및 inter-epoch 문맥뿐만 아니라 장시간 문맥까지 동시에 반영하여 성능을 향상한 바 있다[14]. 따라서 TCN은 욕창 위험 단계와 같이 시간 누적 효과가 중요한 문제에서 강점을 가지며, CNN-BiLSTM보다 장기적 위험 탐지에 유리할 것으로 기대된다.



[그림 2] TCN 구조도

4. 결 론

본 연구는 압력 기반 움직임 센서를 통해 수집된 시계열 데이터를 활용하여 환자의 위험 징후를 감지·예측하는 인공지능 모델을 설계하였다. 이를 위해 단기 패턴 추출과 시간적 종속성 학습에 강점을 지닌 CNN-LSTM과, 장기 의존성 학습과 병렬 처리에 유리한 TCN 구조를 적용하여 동일 조건에서 성능을 비교하였다. 그 결과, 단순 임계값 기반 방식이 가지는 한계를 보완하고 이상

행동을 보다 정교하게 인지할 수 있는 가능성을 확인하였다. 이는 단순 모니터링 수준을 넘어 환자의 안전을 위한 조기 대응 체계를 구축하는 데 의미를 갖는다. 그럼에도 불구하고 데이터가 제한된 환경에서 수집되었기 때문에 다양한 환자군과 실제 임상 환경을 충분히 반영하지 못하였고 본 논문에서는 AI 모델 구조의 설계와 비교에 집중하였으므로, 실제 시스템 통합이나 사용자 인터페이스 등 전체적인 돌봄 플랫폼으로의 확장은 다루지 못하였다. 또한 제안된 모델의 실시간성 검증은 시뮬레이션 수준에 머물러 있어, 실제 임베디드 환경에서의 성능 최적화와 안정성 검증이 추가적으로 필요하다. 향후 연구에서는 보다 다양한 환자 데이터를 확보하여 모델의 일반화 성능을 높이고, 이상행동 감지 결과를 보호자나 의료진에게 직관적으로 전달할 수 있는 사용자 맞춤형 알림 시스템과 연계할 예정이다. 종합하면, 본 연구는 압력 기반 움직임 센서 데이터를 활용한 시계열 이상행동 예측 문제에 대해 CNN-LSTM과 TCN 구조의 비교 설계를 제시함으로써, 스마트 돌봄 분야에서 재현 가능한 기준과 설계 지침을 마련하였다.

감사의 글

본 연구는 2025년 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학사업 지원을 받아 수행되었음(2025-0-00040)

참고문헌

- [1] Singh, D., et al. "DeepConvLSTM with self-attention for human activity decoding using wearable sensors." arXiv preprint arXiv:2005.00698, 2020.
- [2] Zhou, Z., et al. "Efficient human activity recognition on edge devices using DeepConv LSTM architectures." Scientific Reports, vol. 15, 2025.
- [3] Xu, Y., et al. "NAMRTNet: Automatic Classification of Sleep Stages Based on Improved ResNet-TCN Network and Attention Mechanism." Applied Sciences, vol. 13, no. 11, 2023.
- [4] Lv, Y., et al. "A Multilevel Temporal Context Network for Sleep Stage Classification." Frontiers in Neuroscience, vol. 16, 2022.
- [5] Tsai, C., et al. "SPRS: A Sitting Posture Recognition System Using Pressure Sensors and Machine Learning." Sensors, vol. 23, no. 13, 2023.
- [6] Alhagry, S., et al. "Emotion Recognition based on EEG using LSTM recurrent neural networks." International Journal of Advanced Computer Science and Applications, vol. 8, no. 10, 2017.
- [7] Wang, H., et al. "IoT-based abnormal activity detection using temporal convolutional networks." IEEE Internet of Things Journal, vol. 7, no. 5, 2020.
- [8] Edsberg, L. E., et al. "Revised National Pressure Ulcer Advisory Panel Pressure Injury Staging System." Journal of Wound, Ostomy and Continence Nursing, vol. 43, no. 6, 2016.
- [9] Zarei, E., et al. "Systematic Review for Risks of Pressure Injury and Prediction." Diagnostics, vol. 13, no. 17, 2023.
- [10] Chen, X., et al. "Prediction and Stage Classification of Pressure Ulcers in Intensive Care Patients." Diagnostics, vol. 15, no. 10, 2025.
- [11] Ordóñez, F. J., & Roggen, D. "Deep Convolutional and LSTM Recurrent Neural Networks for Multimodal Wearable Activity Recognition." Sensors, vol. 16, no. 1, 2016.
- [12] Zhang, X., et al. "Hybrid Deep Learning for Sleep Stage Classification." IEEE Access, vol. 7, 2019.
- [13] Xu, Y., et al. "NAMRTNet: Automatic Classification of Sleep Stages Based on Improved ResNet-TCN Network and Attention Mechanism." Applied Sciences, vol. 13, no. 11, 2023.
- [14] Lv, Y., et al. "A Multilevel Temporal Context Network for Sleep Stage Classification." Frontiers in Neuroscience, vol. 16, 2022.