

멀티포지션 스마트폰 센서 기반 고령자 보행 분석과 저지연 낙상감지 Bi-LSTM 모델 개발

김민석*, 안드레스 카세레스**, 김광현***

Multi-Position Smartphone Sensor - based Elderly Gait Analysis and Low-Latency Fall Detection Bi-LSTM Model Development

Min-Seok Kim*, Lismer Andres Caceres-Najarro**, and Gwang-Hyun Kim***

본 연구는 중소벤처기업부의 기술개발사업[RS-2025-02311567]과 2025년도 교육부 및 광주광역시의 재원으로 광주RISE센터의 지원을 받아 수행된 지역혁신중심 대학지원체계(RISE)의 결과임 (2025-RISE-05-013)

요약

본 연구는 멀티포지션 스마트폰 센서를 활용해 고령자의 보행지표 산출과 낙상감지를 통합 수행하는 저지연 알고리즘을 제안한다. 자체 앱(AIWalker)으로 손·허리·배·가방 4개 위치에서 100Hz로 데이터를 수집하고, 전처리·특징화 후 Bi-LSTM 기반 다중 과업(위치 분류, 보행지표 회귀, 낙상 이진분류)을 학습하였다. GaitRite 동시검증결과, 보행속도·보폭·걸음수 평균 오차율은 각각 7.5%, 8.0%, 7.2% 였고, 위치 분류 정확도는 92.0%, 낙상감지 정확도 93.3%(AUC 0.94)를 보였다. 엔드투엔드 평균 지연시간은 100 ms 이하로 측정되어 실시간 서비스 적용 가능성을 확인하였다. 본 연구는 실제 사용자 소지 위치 변동을 고려한 통합 모델과 저지연 처리 구조를 제시하였으며, 향후, 실외·다양한 지형과 고령자 실제 낙상 데이터로 일반화 검증예정이다.

Abstract

We propose a low-latency, integrated algorithm that jointly estimates gait metrics and detects falls using multi-position smartphone sensors. Time-series signals collected by a custom app (AIWalker) from four carry positions (hand, waist, belly, bag) are preprocessed and modeled with a Bi-LSTM multi-task network for position classification, regression of gait speed·step length·step count, and fall/no-fall detection. In concurrent validation with GaitRite, mean errors were 7.5% (gait speed), 8.0% (step length), 7.2% (step count); position classification achieved 92.0% accuracy, and fall detection reached 93.3% accuracy with AUC=0.94. End-to-end latency averaged <100 ms, enabling real-time deployment. The approach is robust to carry-position changes; future work will extend validation to outdoor terrains and real fall events in older adults.

Keywords

Bi-LSTM, elderly healthcare, fall detection, gait analysis, smartphone sensors

* 광주대학교 광정보통신학과 박사과정(공동1저자)

- ORCID: <https://orcid.org/0009-0007-3969-415X>

** 조선대학교 컴퓨터공학과 조교수(공동1저자)

- ORCID: <https://orcid.org/0000-0002-2784-0953>

*** 광주대학교 AI소프트웨어학과 교수(교신저자)

- ORCID: <https://orcid.org/0009-0003-2824-8331>

+ Received: Aug. 18, 2025, Revised: Oct. 01, 2025, Accepted: Oct. 04, 2025

+ Corresponding Author: Gwang-Hyun Kim

Dept. AI Software, Gwangju University, 277 Hyodbok-ro, Nam-gu, Gwangju, Korea

Tel.: +82-62-670-2459, Email: ghkim@gwangju.ac.kr

I. 서론

고령 인구의 증가와 함께 보행 정보는 노인의 신체 기능과 전반적 건강을 반영하는 지표로 확립되어 왔다[1]. 보행속도가 0.1 m/s 빠를수록 사망위험이 12% 감소했으며, 연령·성별 모델에 보행속도를 추가하면 장기 생존 예측이 개선됨을 확인하였다[2]. 이러한 근거는, 고령자의 보행 특성을 정밀 분석하고 낙상 위험을 조기에 감지하려는 임상·공중보건적 수요를 뒷받침한다. 보행 속도, 보폭, 보행 대칭성과 같은 시공간 보행지표는 신체 기능 저하·낙상 위험·신경퇴행성 질환의 초기 징후를 감지하는 데 활용 가능한 핵심 바이오마커로 활용 가능성이 크다 [3]-[5]. 특히, 근감소증 연구에서 보행지표는 근육량 및 근력 감소를 예측하는 디지털 바이오마커로서 주목받고 있으며, 국가 건강검진 체계와의 연계 가능성이 논의되고 있다. 기존의 보행 분석 기술은 주로 실험실 기반의 보행 매트나 웨어러블 장비를 활용한 방식이 중심이었으며, 대부분 허리, 발목 등 특정 위치에 고정된 센서를 장착해야 하는 구조로 제한되었다. 이러한 방식은 정밀도 면에서는 우수하나, 장비의 가격, 설치 환경 제약, 착용 불편감 등의 이유로 일상 환경에서의 장기적이고 지속적인 활용에 한계가 있었다. 또한 고령자의 착용 위치가 일정하지 않거나 센서 장착에 어려움이 있는 경우, 데이터 정확도와 신뢰도가 저하되는 문제도 지적되었다[6]-[8].

최근에는 스마트폰 및 다양한 스마트 디바이스(예: 스마트워치, 스마트인솔)에 내장된 센서(예: 가속도계, 자이로스코프)를 활용하여 보행 데이터를 수집하고 분석하는 시도가 활발히 이루어지고 있다. 스마트폰은 대부분의 사용자가 상시 소지하고 있으며, 다양한 신체 부위에 자연스럽게 휴대되기 때문에, 복수의 위치에서도 실시간 데이터를 수집할 수 있는 장점이 있다. 특히, 인공지능 기반의 시계열 분석 기술이 발전하면서 스마트폰 센서를 활용한 고령자 보행 분석 기술은 기존 시스템의 한계를 극복할 수 있는 대안으로 주목받고 있다[9]-[11]. WATCH-PD Study(2024)에서는 상용 스마트폰과 스마트워치를 이용해 보행속도, 보폭, 분당 걸음수(Cadence), 팔 스윙(Arm swing) 등의 주요 보행지표

를 장기간 추적하면서, 이러한 디지털 보행지표가 신경계 질환의 조기 진단과 기능 변화 추적에 유용함을 입증하였다[5]. 이처럼 스마트 디바이스 기반 보행 분석 기술은 실제 환경에서도 높은 적용 가능성을 보여주고 있다. 다만 실제 생활환경에서의 장기 모니터링과 즉각적 피드백을 동시에 만족시키는 시스템은 아직 제한적이다. 사용자는 손·허리·배·가방 등 다양한 위치에 스마트폰을 소지하므로, 위치 변동성과 방향 차이에 따른 센서 신호의 분산을 흡수하면서, 보행 지표 산출·낙상 감지·착용 위치 분류를 일관성 있게 통합 처리하고, 실사용 수준의 지연을 보장하는 기술이 요구된다. 본 연구는 이러한 요구를 충족하기 위해, 상용 스마트폰 내장 센서 기반의 멀티포지션 보행 분석·낙상 감지 통합 알고리즘을 제안하고 상용화 장비와의 동시 검증을 통해 신뢰성과 실용 가능성을 평가한다. 구체적으로, 공유 Bi-LSTM(Bidirectional Long Short-Term Memory) 인코더와 위치 분류, 낙상 이진 분류, 보행지표 회귀 기능의 다중 헤드 아키텍처를 설계하고, 100Hz 다채널 시계열 데이터에 대한 전처리·정규화·특징화 파이프라인을 확립하였다. 본 연구는 실제 사용자 소지 위치 변동을 고려한 통합 모델과 데이터 기반 정량 검증, 저지연 처리 구조를 제시하고자 한다.

II. 관련 연구

고령자의 낙상 예방과 보행 기능 유지에 대한 사회적 요구가 높아짐에 따라, 보행 분석 기술은 디지털 헬스케어 분야의 핵심 연구로 부상했다. 최근 연구들은 스마트폰이나 스마트워치의 관성측정장치(IMU, Inertial Measurement Unit)를 활용하여 실시간 데이터를 수집함으로써, 고가의 고정형 장비가 가진 한계를 보완하고 있다[4][9][12][13]. 이에 따라 본 장에서는 스마트폰/웨어러블 기반 보행분석의 세부 동향과 한계를 정리하고자 한다.

2.1 스마트폰 기반 보행분석 기술의 동향

초기 스마트폰 기반 보행 분석 연구들은 IMU를 활용해 보행 주기, 속도, 보폭 등 정량적 지표를 추

출하는 데 집중했다[5][6]. 대부분의 연구는 스마트폰을 허리나 발목 등 특정 위치에 고정된 상태에서 데이터를 수집했으며, 이를 통해 임상적 활용 가능성을 제시했다. 그러나 실제 사용자는 손, 가방, 주머니 등 매우 다양한 위치에 스마트폰을 소지하기 때문에, 착용 위치가 달라질 때마다 센서 데이터의 특성이 변해 알고리즘 성능이 저하되는 문제가 지속적으로 보고되었다[14]. 따라서, 본 연구는 사용자의 실제 소지 습관을 고려하여 다양한 착용 위치 변화에도 강건한 보행 분석 모델을 개발하는 것을 핵심 목표로 삼았다.

2.2 위치 변동성과 저지연 분석의 한계

GaitRite와 같은 전통적인 보행 분석 시스템은 높은 정밀도를 보장하지만, 특정 공간에 설치되어야 하므로 실시간 분석이나 장기적인 모니터링에는 한계가 명확하다[15]. 반면, 스마트폰은 휴대성이 높아 일상 속 장기 데이터를 확보하는 데 매우 유리하다. 이러한 장점을 바탕으로 스마트폰 센서 데이터와 딥러닝을 결합하여 보행 분류나 낙상을 감지하려는 시도가 증가하고 있다. 하지만 기존 연구들은 대부분 통제된 환경의 제한된 시나리오를 기반으로 하여, 실제 사용 환경에서 발생하는 위치 변화나 예측 불가능한 움직임까지는 충분히 고려하지 못했다[8][9]. 결국, 기술의 실용성을 확보하기 위해서는 실제 환경의 불확실성을 극복하고, 수집된 데이터를 즉각적으로 분석하여 사용자에게 피드백을 제공하는 저지연 처리 기술이 반드시 필요하다.

2.3 Bi-LSTM 기반 보행 시계열 분석의 가능성

보행은 시간의 흐름에 따른 연속적인 데이터이므로, 시계열 분석에 특화된 LSTM이나 Bi-LSTM과 같은 순환신경망 모델이 효과적인 해결책으로 활용되고 있다[16]. 특히 Bi-LSTM은 시간의 순방향과 역방향 흐름을 모두 학습하므로, 보행 주기처럼 과거와 미래의 움직임이 모두 중요한 패턴을 분석하는 데 강점을 보인다. 또한, 다양한 센서 입력 특성을 병렬적으로 처리하여 스마트폰 위치 분류, 걸음

수 계산, 보행속도 예측 등 여러 과업을 하나의 모델에서 통합적으로 처리할 수 있는 잠재력을 가지고 있다[17]. 이러한 특성에 착안하여, 본 연구는 복잡하고 다차원적인 보행 데이터를 단일 모델 내에서 효율적으로 처리하고, 위치 분류, 보행지표 산출, 낙상감지를 동시에 수행하기 위한 아키텍처로 Bi-LSTM을 채택했다.

2.4 연구의 차별성 및 연구 필요성

기존 연구들은 단일 착용 위치에 한정되거나, 여러 보행 지표와 낙상 감지를 통합적으로 처리하지 못하는 경우가 많았다. 본 연구는 이러한 한계를 극복하고자, 하나의 Bi-LSTM 모델 구조 내에서 ①스마트폰 착용 위치 자동 분류, ②주요 보행지표(속도, 보폭, 걸음수) 산출, ③ 낙상감지를 동시에 수행하는 통합 알고리즘을 제안한다. 특히, 고령자를 포함한 실제 사용자로부터 수집한 대규모 시나리오 데이터를 활용하고, 상용화 보행분석 장비와의 정량적 비교 검증을 통해 모델의 신뢰성과 실용성을 모두 확보했다는 점에서 기존 연구들과 차별화된다. 이는 실제 환경 기반의 저지연 통합 분석 시스템을 구현한 사례로서, 기술의 임상적 적용 가능성을 한 단계 높였다는 데 의의가 있다.

III. 연구방법

3.1 전체 연구개요

본 시스템은 멀티포지션 센서 동시 수집 → 전처리·특징추출 → Bi-LSTM 다중 과업(위치·낙상·보행지표) 동시 추론의 일관된 파이프라인으로 구성하였다. 각 단계의 정규화·필터링 규칙은 표 4와 5, 피쳐 목록은 표 7, 학습/추론 헤드 구성은 표 8에 요약하였다. 그림 1은 AIWalker 앱이 손·허리·배·가방 4개 위치에서 스마트폰 내장 13종 센서(가속도, 자이로, 중력, 회전벡터, 자기장, 기압, GPS 등)를 100Hz 샘플링 속도로 수집하고, 정렬·필터링·세그멘테이션을 거쳐 모델에 입력되는 흐름과, 추론 결과가 서버/앱으로 전달되는 과정을 요약하였다.

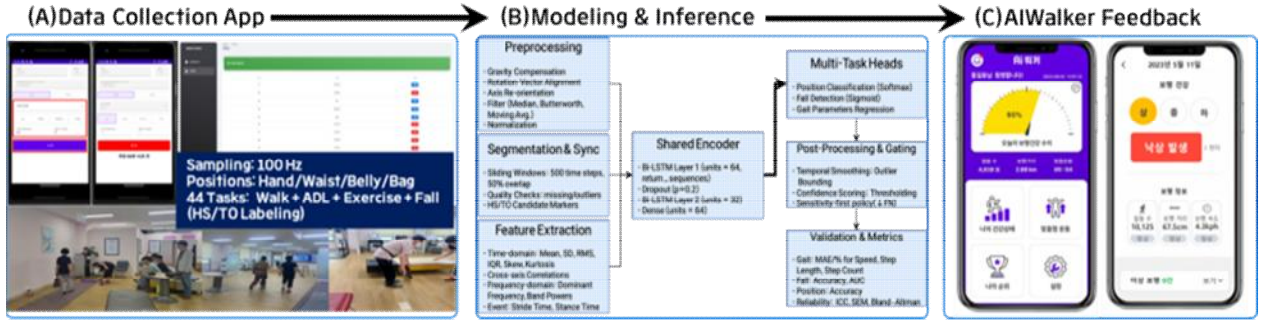


그림 1. 시스템 개요 (a) 데이터 수집 앱, (b) 모델링 및 추론, (c) AIWalker 피드백 앱

Fig. 1. System overview in three panels (a) Data-collection app, (b) Modeling & inference and (c) AIWalker feedback app

3.2 데이터 수집환경 및 시스템 구성

본 구현에서는 모델 추론 결과가 서버 측 데이터 베이스에 저장되고, 모바일 앱은 서버 DB에서 해당 결과를 조회하여 사용자 화면에 표시한다. 본 논문에서는 Bi-LSTM 공유 인코더 하부에 세 개의 출력 헤드(① 폰 위치 분류, ② 낙상 감지, ③ 보행지표 산출)를 병렬로 구성하였다. 고령자의 보행 특성을 정량적으로 분석하기 위해 스마트폰의 4개 위치별 센서 정보를 총 44종의 행동 시나리오를 정의하였으며(표 1), 시나리오는 실제 일상생활 및 임상적 응용 상황을 반영하여 네 가지 그룹으로 분류하였다.

표 1. 시나리오 분류체계

Table 1. Classification of data collection scenarios

Category	Scenario	Examples
Gait	3 types	Normal walking, fast walking, slow walking
ADL	20 types	Sitting down, standing up, stopping while walking, lifting objects
Exercise	17 types	Squat, lunge, marching in place, stair climbing and descending
Fall	4 types	Lateral fall, forward collapse, backward fall

시나리오는 단일 동작뿐 아니라, 동작 간 전이와 연속된 움직임을 포함 하도록 설계되어, 실제 환경과 유사한 시계열 데이터를 생성하였다. 행동 시나리오는 약 5~10초 길이의 시간 구단 단위로 반복 측정되었으며, 모든 실험은 스마트폰을 착용한 채 실내 트랙에서 수행하였다. 보행 동작의 경우 10m 직선 경로에서 시작점- 도착점을 최소 3회 왕복하도록 하였으며, 각 동작 후에는 체력 회복 시간을

충분히 확보하여 데이터의 생리적 안정성을 확보하였다. 낙상 유형은 고령자의 직접 시연이 현실적으로 어려우므로 20~65세 미만의 성인을 대상으로 실내 환경에서 매트리스를 이용한 안전 장비 하에 재현하였다. 낙상 동작은 높은 동적 가속도와 충격량을 특징으로 하며, 센서 데이터에서 급격한 변동 및 불규칙한 주파수 성분이 동반되므로 낙상감지 알고리즘 학습을 위한 핵심데이터 셋으로 활용되었다. 데이터 수집은 광주광역시 소재 빛고을건강타운 헬스케어 모니터링 센터에서 수행되었으며, 만 65세 이상 35명과 65세 미만 성인 15명이 참여하였다. 낙상과 같은 이벤트 데이터는 별도 안전시나리오로 추가 확보하였다. 본 연구는 IRB(최소위험, Level 1) 승인을 받았으며, 연구계획서 및 개인정보 동의서를 포함한 모든 심의 자료는 해당 위원회에 공식 기록되어 있다(승인번호: P01-202301-01-031, 심의일자: 2023.09.21). 모든 참가자는 참여 전 자발적 서면 동의 후 참여하였다.

3.3 데이터 전처리 및 피쳐추출

스마트폰 내장 센서로부터 수집된 시계열 데이터는 다채널, 고주파(100 Hz) 환경에서 취득됨에 따라 노이즈, 오차, 신체 위치 편차 등으로 인한 데이터 불안정성이 내포되어 있다. 따라서 본 연구에서는 신호처리 기반의 전처리 파이프라인을 구성하여 알고리즘 학습에 적합한 신뢰도 높은 입력 데이터를 구축하였다. 각 채널에서 수집된 원시 신호는 가속도(acc_x, acc_y, acc_z), 자이로스코프($gyro_x, gyro_y, gyro_z$), 회전벡터, 중력 등으로 구성되며, 표 2는 정규화 과정을 요약하여 설명하였다.

표 2. 데이터 정규화 과정 요약

Table 2. Summary of sensor data normalization

Processing step	Purpose and method
Gravity compensation	Extract linear acceleration for dynamic motion analysis by subtracting gravity components (gravity_x, gravity_y, gravity_z) to isolate vibration signals.
Rotation vector alignment	Use rotation vector sensors to minimize coordinate system errors across different mounting locations and unify reference coordinates.
Sensor axis reorientation	Correct axis misalignment due to differences in attachment orientation by applying coordinate transformation based on the orientation matrix.

고령자의 보행 패턴은 개별 특성(예: 떨림, 보폭 불균형 등)에 따라 고주파 노이즈가 유입되므로, 표 3과 같은 필터링 기법을 적용하였다. 이러한 복합 필터링을 통해, 시간영역 신호의 스무딩 처리와 동시에 힐 스트라이크(HS, Heel Strike) 감지를 위한 진폭 보존을 균형 있게 유지하였다. 센서 데이터는 100Hz 기준의 고정 길이 슬라이딩윈도우(Sliding window) 방식으로 분할되었으며, 보행 주기성 보전과 HS 이벤트 감지를 위해, 고주파 성분을 제거된 진폭 특성은 유지하도록 표 3과 같이 필터를 설계하였다. 중값필터는 짧은 구간의 이상치만 선별 제거하여 충격 이벤트의 신호피크를 보전하고, 4차 Butterworth(20 Hz 차단)는 생리학적으로 불필요한 고주파를 억제하며, 5-point 이동평균은 미세 진동을 평활화해 후속 HS/TO 검출의 임계값 안정성을 높일 수 있도록 하였다.

이와 함께, 센서 위치 간 데이터 동기화를 위해 공통 기준 타임스탬프 기반으로 4개 채널을 프레임 단위로 정렬하였다. 전처리된 시계열 데이터로부터 총 48개의 엔지니어드 피처를 추출하였으며, 이는 시간 영역 및 주파수 영역 특성을 반영한다. 이 중 낙상 분류 알고리즘에서는 고주파 대역의 피크 주기와 에너지 변화량이 주요 감별 인자로 활용되었다. 추출된 피처는 채널 간 크기 차이를 보정하기 위해 Z-score 정규화를 적용하였다. 이후 Bi-LSTM 입력 형식(3D: 시계열 길이 × 채널 수 × 피처 수)

에 맞게 구조화되었으며, 모델 학습 시 라벨 벡터는 One-hot encoding 방식으로 구성되었다. 전처리된 신호는 100Hz의 샘플링 속도를 기준으로 5초(500 샘플) 길이의 고정 길이 윈도우로 분할하고, 50% 중첩을 적용해 경계 손실을 최소화했다. 세부 규칙은 표 4와 같다.

표 3. 시계열데이터 필터링 기법

Table 3. Application of time-series filtering techniques

Filtering method	Purpose and application
Median filter	Removes transient outliers (spikes) occurring over a short time. Noise is suppressed by calculating the median of neighboring values within a 3 - 5 point window.
Low-pass filter (4th-order butterworth)	Eliminates high-frequency components above 20 Hz from the time-series signal to block physiologically irrelevant noise. A 4th-order Butterworth filter is applied to handle rapid signal changes.
Moving average filter	Smooths the time-series data using a 5-point sliding window. Reduces micro-vibrations from sensor noise or gait cycles, improving curve interpretability.

표 4. 윈도우 분할 및 시간 동기화 처리

Table 4. Window segmentation & time synchronization processing

Item	Description
Window size setting	Time-series data are segmented into 5-second windows (500 samples at 100Hz) to enable stable feature extraction for short actions.
Overlap handling	A 50% overlap is applied to prevent feature loss at the boundaries between sequential movements, increasing the number of training samples and ensuring boundary pattern continuity.
Time alignment criteria	Based on manual labeling timestamps from the Signal Labeler tool, window alignment is performed according to start/end timestamps. Interpolation using timestamps corrects time discrepancies among sensors and refines scenario boundaries.

중첩 적용은 보행 주기의 경계정보를 보전하여 낙상과 급가속 구간의 감지 민감도를 높이며, 라벨 시점 기준 정렬·보간은 착용 위치 간 비동기 문제

를 줄여 멀티포지션 학습의 정합성을 확보한다. 시간영역 특성만으로는 낙상·비낙상, 속도 단계의 경계를 충분히 분리하기 어렵다. 이에 표 5와 같이 FFT 중심주파수, 대역에너지 비율, 스펙트럴 엔트로피, 스펙트럴 슬로프 등 주파수 영역 특성을 병행 추출하였다.

표 5. 주파수 도메인 특성

Table 5. Frequency domain features

Feature	Description
FFT-based center frequency (CF)	Calculates the central frequency of the power spectrum using Fast Fourier Transform to analyze vibration characteristics by activity type.
Band energy distribution	Computes the proportion of signal energy within specific frequency bands (e.g., 0 - 5 Hz, 5 - 15 Hz, 15 - 25 Hz); low-frequency dominance in gait, high-frequency in falls.
Shannon entropy	Quantifies the information content of the time-series signal to assess activity complexity and predictability.
Spectral entropy	Measures the irregularity of frequency components to detect abnormal movements such as falls.
Spectral slope	Analyzes energy variation with increasing frequency; falls typically show a steep spectral slope.
Peak-to-peak ratio	Assesses the ratio between the dominant spectral peak and the overall energy distribution, highlighting amplified behavior segments.

낙상은 고주파 에너지 비중과 스펙트럴 슬로프가 가파르게 증가하는 패턴을 보였고, 보행은 0 - 5 Hz 저주파 지배와 뚜렷한 주기피크가 관찰되었다. 이들 특성은 4.3의 낙상감지 실험에서 민감도 향상에 기여하였다.

3.6 Bi-LSTM 기반 보행 분석 알고리즘 구현

본 연구에서는 시간 순차적 의존성이 강한 보행 및 낙상 데이터를 효과적으로 모델링하기 위해 양방향 순환신경망 구조인 Bi-LSTM을 기반으로 한 심층 신경망 모델을 설계하였다. 특히, 보행 중 발생하는

패턴의 전·후 맥락 정보를 동시에 학습함으로써, 위치 분류, 보행 지표 산출, 낙상감지 등 복합적인 시계열 분류 과제를 동시에 해결할 수 있는 구조로 주요 하이퍼파라미터 설정과, 모델 최적화를 위한 학습 기법을 포함하여 구성한 결과는 표 6과 같다.

표 6. 모델 아키텍처 및 학습 최적화 설정

Table 6. Model architecture and training hyperparameters

Parameter	Value	Purpose & effect
Time-series length	500 time steps	Ensures full gait cycles within a window
Batch size	64	Stable training and memory efficiency
Epochs	200	Convergence with early stopping
Learning rate	0.001	Balance between speed and stability
Optimizer	Adam	Fast convergence to near-global minima.
Dropout rate	0.3	Regularization to mitigate overfitting
Loss function	Categorical cross-entropy	Task-appropriate objectives
Early stopping	patience=10	Avoid over-training

이러한 계층 설계는 전방향 및 후방 시간 정보를 모두 활용하여 과거 및 미래 시점의 움직임 패턴을 동시 학습하도록 설계되었다. 모델 학습을 위해 수집된 전체 데이터는 총 데이터 수 약 3,500세트(이는 50명의 피험자를 대상으로 44종의 시나리오를 각각 3회 반복 측정하여 확보한 결과로, 개인별 평균 70개 이상의 시계열 세트가 포함) 이상의 시나리오별 시계열 윈도우, 훈련/검증/시험 분할은 각각 70%/ 15%/15%로, 라벨링 방식은 위치 분류 {BAG, BELLY, HAND, WAIST}→One-hot Encoding(4차원)으로 낙상감지는 {낙상, 정상}→Binary Encoding, 보행유형 분류는 {일반 보행, 느린 보행, 빠른 보행 등}→Multi-class로 구성하고 또한, 라벨 불균형 문제를 방지하기 위해 시나리오별 균등 분할 및 오버샘플링 기법을 적용하였다. Bi-LSTM 기반 보행 분석 모델의 성능 향상을 위해, 다양한 하이퍼파라미터를 체계적으로 조정하였으며, 학습 과정의 안정성과 일반화 성능을 확보하기 위한 정규화 및 초기화 전략을 병행하였다. 학습 중에는 검증손실 기준으로

early stopping을 적용하였으며, 모델 성능 향상을 위해 dropout과 정규화 초기화를 병행하였다. 또한 학습 성능 평가는 위치 분류, 보행 지표 회귀, 낙상감지 등 개별 모듈별로 분리하여 정확도, F1-score, AUC 등의 지표로 수행하였다.

IV. 연구결과

본 장에서는 본 연구에서 개발한 Bi-LSTM 기반 보행 분석 알고리즘이 실제로 도출한 보행 지표와 그 정확도를 정량적으로 평가한다. 또한, 스마트폰 부착 위치 분류, 낙상감지 정확도, 그리고 상용 보행 분석 장비(GaitRite)와의 비교 성능을 통해 본 시스템의 실용성과 임상 적용 가능성을 검증하였다.

4.1 보행 지표 산출 결과 및 GaitRite와의 비교

본 장의 모든 성능 수치는 3장에서 기술한 데이터 전처리·윈도우/동기화 규칙·학습 설정을 전제로 한 테스트 세트 기준 결과이며, AIWalker 알고리즘을 통해 도출한 보행지표는 보행속도, 보폭, 걸음수로 구성되어 선정된 10명의 피험자 전원을 대상으로 동일한 조건(10m 보행시험, 5회 반복)에서 실험을 수행(총 50회)하였으며, 이를 GaitRite와 동시 측정하여 비교하였다. 표 7의 값은 피험자별 5회 반복의 평균을 산출한 뒤, 대상자 10명의 평균을 제시하였다. 보행속도·보폭·걸음수의 평균 오차율은 모두 8% 이내였으며, 속도 $R^2=0.932$, 보폭 $R^2=0.918$, 걸음수 $R^2=0.911$ 로 높은 상관성을 확인하였다.

표 7. AIWalker - GaitRite 비교 결과
Table 7. Algorithm validation results

Metric	GaitRite measurement	AIWalker measurement	Mean error rate (%)
Gait speed(m/s)	1.07	0.99	7.50
Step length(m)	0.54	0.50	8.00
Step count	24.5	22.7	7.20

그림 2의 Bland - Altman 분석에서도 평균편차(-0.080 m/s)와 95% 일치한계(-0.105~-0.054 m/s) 내에 대부분 분포하여 측정 일관성을 보였다. 이는 스마트폰 기반 측정의 신뢰도를 뒷받침한다.

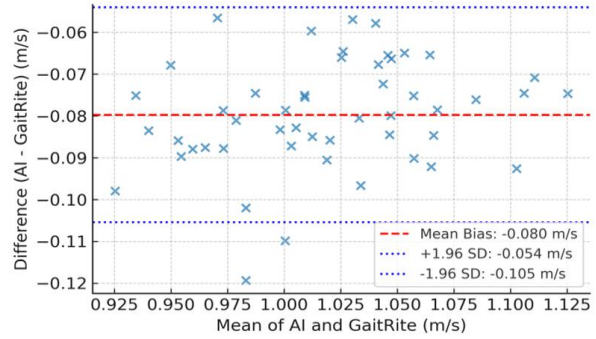


그림 2. AIWalker와 GaitRite 측정비교
Fig. 2. Bland - Altman Plot comparing AIWalker-estimated gait speed with GaitRite measurements

4.2 스마트폰 위치 분류 정확도

분류 평가는 테스트 세트 기준 혼동행렬로 위간 오분류 양상을 점검하였으며, 각 실제 클래스(행) 대비 예측 분포(열)의 백분율을 표 8에 요약하였다(표 8). 이어서, 4개 신체 부위에 부착된 스마트폰의 위치를 분류한 결과, 평균 정확도 92.0%, 정밀도 91.6%, 재현율 90.8%, F1-score 91.2%로 측정되었다.

표 8. 분류정확도 혼동행렬
Table 8. Classification accuracy confusion matrix

Actual \ predicted	Hand	Waist	Belly	Bag
Hand	94.10%	2.80%	2.10%	1.00%
Waist	3.00%	96.30%	0.70%	0.00%
Belly	1.80%	0.60%	96.70%	0.90%
Bag	2.40%	0.00%	1.30%	96.30%

허리/배는 거의 오차 없이 분류되었으며, 손과 가방 간 일부 혼동이 관찰되었으나, 전체 정확도에 미치는 영향은 제한적이었다. 따라서, 이는 착용 위치 자동 인지가 낙상감지·보행분석 파이프라인에서 위치별 최적 모델/임계값 선택에 유효함을 시사한다.

4.3 낙상감지 성능

본 연구에서는 총 4종의 낙상 시나리오와 ADL 데이터를 포함한 이진 분류를 구성하고, Bi-LSTM 기반 낙상감지 모델의 성능을 평가하였다. 전체 데이터셋은 실제 발생 빈도와 학습 균형을 고려하여 시나리오별로 균등 분할하였으며, 학습 데이터의 클

래스 불균형 문제를 해결하기 위해, 훈련 데이터셋에 한정하여 소수 클래스인 낙상 데이터에 소수 클래스 오버샘플링 기법인 SMOTE(Synthetic Minority Over-sampling Technique) 기법을 적용했다. 이 과정은 검증 및 테스트 데이터셋과 완전히 분리된 상태에서 진행하였고, 훈련 시 낙상과 비낙상 데이터의 비율을 1:1로 균등하게 조정하여 모델이 양쪽 클래스의 특성을 동등하게 학습하도록 설계했다. 낙상감지 민감도 91.8%, 특이도 90.2%, 정확도 93.3%, AUC 0.94로 나타났다. 이는 오탐지 비율이 8.2% 수준임을 의미하며, 치명적인 결과를 초래할 수 있는 낙상 감지 시스템의 특성을 고려할 때, 이 결과는 일부 오탐지를 감수하더라도 놓치는 낙상을 최소화하는 민감도 우선 접근법의 필요성을 시사한다. 감지 알고리즘은 시간영역 상 급격한 가속도 변화 및 고주파수 에너지 증가 구간을 중심으로 구성되었으며, 특히 측면 전도나 주저앉는 형태의 낙상에서 높은 감지율을 보였다. AVM(Acceleration Vector Magnitude) 기반 충격량, 빠른 푸리에 변환(FFT) 중심주파수, 저크(가속도 변화율, jerk) 변화량은 SHAP(Shapley Additive exPlanations) 분석을 통해 낙상 감지의 핵심 피처로 확인되었다. 본 논문에서는 낙상 감지 알고리즘의 구현과 성능지표를 중심으로 기술하였으며, 클래스 불균형 보정 전략, confusion matrix 기반 해석, cost-sensitive loss 적용과 운영 측면에서는 오탐지 최소화 기법 등 고도화된 기법 연구와 실제 환경 기반 오탐지 영향 분석은 추후 논문에서 보다 상세히 다룰 예정이다.

4.4 저지연 처리 성능 평가

본 수치는 NHN Cloud(16 vCPU, 225GB RAM) - Galaxy Note 10(안드로이드13) - 안정적 네트워크 조건에서 측정된 엔드투엔드 지연(수집→전송→서버 추론→서버 DB 저장 완료) 기준이다. 따라서 본 논문에서 보고하는 지연시간은 서버 DB에 결과가 기록되는 시점까지를 포함하며, 앱이 DB를 조회해 화면을 렌더링하는 단계는 제외한 지연시간을 측정하였다. 시험은 총 5회 반복 측정 결과 데이터는 초당 10개 이상 안정적으로 전송되었고, 단위 입력당 평

균 지연시간은 100 ms 이하로 측정되었다. 이를 통해 제안한 시스템은 데이터 수집부터 분석 결과 생성까지의 전체 응답시간이 1초 미만의 수준으로, 고령자의 저지연 낙상감지나 보행 상태 모니터링 서비스에 충분히 활용 가능성을 입증하였다.

V. 결론 및 향후 과제

5.1 결론

본 연구는 스마트폰 내장 센서를 이용해 4개 소지 위치에서 수집한 신호로부터 보행 지표(보행속도, 보폭, 걸음수)를 산출하고, 상용 레퍼런스 장비(GaitRite)와의 동시측정을 통해 정확도를 검증하였다. 모든 성능 수치는 3장에서 기술한 전처리 - 원도우/동기화 - 학습 설정을 전제로 한 테스트 세트 기준 결과이며, 검증은 10명의 피험자가 10m 보행시험을 5회 반복(총 50회) 수행한 데이터에 대해 이루어졌다(표 7). 표 7의 통계는 피험자별 5회 평균 → 대상자 10명 평균의 순서로 산출하였다.

종합하면, 제안한 AIWalker 파이프라인은 ①표준화된 전처리와 ②시간-의존적 보행 특성 학습을 통해 경량-저지연 구조를 유지하면서도 레퍼런스 대비 타당한 정합성을 보였으며, 실제 환경 적용 가능성을 확인하였다.

5.2 연구의 한계

첫 번째로, 본 연구의 동시측정 검증은 전체 데이터 수집 코호트 중 10명을 대상으로 수행되어 표본 크기와 대표성 측면에서 일반화에 제약이 있다. 특히 연령·성별·질환군 층화가 충분하지 않아 조건별(예: 보행 보조도구 사용, 보행 이상 유무) 성능 차이를 세밀하게 검토하기 어렵다. 향후에는 표본 규모를 확대하고 다기관 협력으로 외부 검증 세트를 확보하여, 층화 분석과 종단 추적을 통해 일반화 가능성과 안정성을 체계적으로 검증할 예정이다. 또한, 결과 해석의 신뢰도를 높이기 위해 Bland - Altman 일치 한계(LoA, Limits of Agreement), 급간 상관계수(ICC, Intraclass Correlation Coefficient), 측정

표준오차(SEM, Standard Error of Measurement)/최소 검출변화(MDC, Minimal Detectable Change) 및 공변량 통제 부분 상관·혼합효과모형 등 임상 통계 지표를 병행 보고하고, 소지 위치(손·허리·배·가방), 보행 속도(느림·보통·빠름), 환경(실내/실외)·표면·경사 조건에 따른 오차 성분 분해와 민감도 분석(윈도우 분할·동기화 규칙 변화)을 추가로 수행할 계획이다.

두 번째로, CNN(Convolutional Neural Network)/Transformer 계열의 고도화 모델은 성능 측면에서 경쟁력이 있을 수 있으나, 본 연구는 저지연 보행 분석을 핵심 목표로 하여 계산 복잡도·추론 지연·전력 소모의 제약을 중시하였다. 이에 Bi-LSTM을 채택하여 보행 시계열의 주기성·대칭성을 효율적으로 학습하면서 성능-지연 균형을 확보하고자 했다. 그럼에도 선택의 타당성을 보다 엄밀히 입증하기 위해, 향후 연구에서는 성능 지표(정확도·오차·강건성)와 함께 연산 지표(파라미터 수·FLOPs·추론 지연·전력)를 동시에 고려한 포괄 비교 실험을 수행하여 Bi-LSTM, 경량 CNN, 소형 Transformer/Conformer 등을 동일 데이터·동일 프로토콜로 벤치마킹할 예정이다.

세 번째로, 데이터 생태 측면에서도 한계가 존재한다. 낙상감지 모델은 일부 데이터가 젊은 성인의 모의 낙상에 기반하였기 때문에, 실제 고령자의 낙상 패턴과 운동역학적 차이를 완전히 반영하지 못할 가능성이 있다. 또한 본 연구의 검증 환경은 주로 실내 보행에 초점을 맞추었으므로, 향후 연구에서는 실외 환경, 다양한 지형(경사로, 계단 등) 및 네트워크 품질 변동 조건에서의 강건성 검증과 데이터 증강을 포함한 성능 평가가 필요하다. 이를 위해 안전 설계를 갖춘 하이브리드 수집 전략(시뮬레이션+실사용 이벤트)을 적용하고, 기기 이질성(기종·센서 샘플링률·소지 방향 임의성)에 따른 도메인 편차를 줄이기 위해 도메인 적응/일반화, 인스턴스 정규화, 테스트 타임 적응 등 강건성 기법을 도입할 계획이다.

마지막으로, 본 연구에서 제안한 저지연 보행 분석 및 낙상감지 기술을 다중 디지털 바이오마커 기반의 고령자 맞춤형 건강관리 플랫폼으로 확장함으로써, 가정·지역사회·의료기관 등 다양한 환경에서

고령자의 보행 변화를 장기적으로 모니터링하고 이상 징후를 조기에 감지하는 종합 헬스케어 솔루션으로 발전시킬 수 있을 것으로 기대된다. 이를 뒷받침하기 위해 데이터 포맷·전송·보안의 표준화와 상호운용성을 강화하고, 재현 가능성을 높이는 레퍼런스 파이프라인을 공개하는 한편, 고령자 사용성·수용성 평가와 지속 사용률 제고를 위한 피드백·알림 설계를 병행할 것이다.

References

- [1] A. Middleton, S. L. Fritz, and M. Lusardi, "Walking speed: The functional vital sign", *Journal of Aging and Physical Activity*, Vol. 23, No. 2, pp. 314-322, Apr. 2015. <https://doi.org/10.1123/10.1123/japa.2013-0236>.
- [2] S. Studenski, S. Perera, K. Patel, C. Rosano, K. Faulkner, M. Inzitari, J. Brach, J. Chandler, P. Cawthon, E. B. Connor, M. Nevitt, M. Visser, S. Kritchevsky, S. Badinelli, T. Harris, A. B. Newman, J. Cauley, L. Ferrucci, and J. Guralnik, "Gait speed and survival in older adults", *Journal of the American Medical Association*, Vol. 305, No. 1, pp. 50-58, Jan. 2011. <https://doi.org/10.1001/jama.2010.1923>.
- [3] S. D. Din, A. Godfrey, and L. Rochester, "Body-worn sensors for remote monitoring of Parkinson's disease motor symptoms: vision, state of the art, and challenges ahead", *Journal of Parkinson's Disease*, Vol. 11, No. S1, pp. S35-S47, 2021. <https://doi.org/10.3233/JPD-202471>.
- [4] C. S. Colón-Emeric, C. L. McDermott, D. S. Lee, and S. D. Berry, "Risk Assessment and Prevention of Falls in Older Community-Dwelling Adults: A Review", *JAMA*, Vol. 331, No. 16, pp. 1397-1406, Apr. 2024. <https://doi.org/10.1001/jama.2024.1416>.
- [5] J. L. Adams, T. Kangarloo, Y. Gong, V. Khachadourian, B. Tracey, D. Volfson, R. D. Latzman, J. Cosman, J. Edgerton, D. Anderson, A. Best, M. A. Kostrzebski, P. Auinger, P. Wilmot,

- Y. Pohlson, S. Jensen-Roberts, M. L. T. M. Müller, D. Stephenson, E. R. Dorsey, and E. Botting, "Using a smartwatch and smartphone to assess early Parkinson's disease in the WATCH-PD study over 12 months", *npj Parkinson's Disease*, Vol. 10, No. 1, pp. 112, Jun. 2024. <https://doi.org/10.1038/s41531-024-00721-2>.
- [6] S. D. Din, A. Godfrey, and L. Rochester, "Validation of an accelerometer to quantify a comprehensive battery of gait characteristics in healthy older adults and Parkinson's disease: Toward clinical and at-home use", *IEEE Journal of Biomedical and Health Informatics*, Vol. 20, No. 3, pp. 838-847, May 2016. <https://doi.org/10.1109/JBHI.2015.2419317>.
- [7] L. Donath, O. Faude, E. Lichtenstein, and G. Pagenstert, "Mobile inertial sensor based gait analysis: Validity and reliability of spatiotemporal gait characteristics in healthy seniors", *Gait & Posture*, Vol. 49, pp. 371-374, Sep. 2016. <https://doi.org/10.1016/j.gaitpost.2016.07.269>.
- [8] E. Warmerdam, J. M. Hausdorff, A. Atrsaei, Y. Zhou, A. Mirelman, K. Aminian, A. J. Espay, C. Hansen, L. J. W. Evers, A. Keller, C. Lamoth, A. Pilotto, L. Rochester, G. Schmidt, B. R. Bloem, and W. Maetzler, "Long-term unsupervised mobility assessment in movement disorders", *The Lancet Neurology*, Vol. 19, No. 5, pp. 462-470, May 2020. [https://doi.org/10.1016/S1474-4422\(19\)30397-7](https://doi.org/10.1016/S1474-4422(19)30397-7).
- [9] F. Lipsmeier, K. I. Taylor, R. B. Postuma, E. Volkova-Volkmar, T. Kilchenmann, B. Mollenhauer, A. Bamdadian, W. L. Popp, W.-Y. Cheng, Y.-P. Zhang, D. Wolf, J. Schjodt-Eriksen, A. Boulay, H. Svoboda, W. Zago, G. Pagano, and M. Lindemann, "Reliability and validity of the Roche PD Mobile Application for remote monitoring of early Parkinson's disease", *Scientific Reports*, Vol. 12, No. 1, pp. 12081, Jul. 2022. <https://doi.org/10.1038/s41598-022-15874-4>.
- [10] S. Kim, H. S. Kim, and J.-I. Yoo, "Sarcopenia classification model for musculoskeletal patients using smart insole and artificial intelligence gait analysis", *Journal of Cachexia, Sarcopenia and Muscle*, Vol. 14, No. 6, pp. 2793-2803, Dec. 2023. <https://doi.org/10.1002/jcsm.13356>.
- [11] Y. Yun and J. Sohn, "Diagnosis of sarcopenia in the elderly and development of deep learning algorithm exploiting smart devices", *Journal of the Society of Disaster Information*, Vol. 18, No. 3, pp. 433-443, Sep. 2022. <https://doi.org/10.15683/kosdi.2022.9.30.433>.
- [12] U. Rashid, D. Barbado, S. Olsen, G. Alder, J. L. L. Elvira, S. Lord, I. K. Niazi, and D. Taylor, "Validity and reliability of a smartphone app for gait and balance assessment", *Sensors*, Vol. 22, No. 1, pp. 124, Dec. 2021. <https://doi.org/10.3390/s22010124>.
- [13] Y. Hutabarat, A. C. Silva, and N. Xiong, "Recent advances in quantitative gait analysis using wearable sensors: A review", *IEEE Sensors Journal*, Vol. 21, No. 23, pp. 26470-26487, Oct. 2021. <https://doi.org/10.1109/JSEN.2021.3119658>.
- [14] T.-H. Heo, H. Yeom, and S. Lee, "Accurate step-count detection based on recognition of smartphone hold position", *Journal of KIISE*, Vol. 44, No. 4, pp. 374-382, Apr. 2017. <https://doi.org/10.5626/JOK.2017.44.4.374>.
- [15] Q. Zou, Y. Wang, Q. Wang, Y. Zhao, and Q. Li, "Deep Learning-Based Gait Recognition Using Smartphones in the Wild", *IEEE Transactions on Information Forensics and Security*, Vol. 15, pp. 3197-3212, Apr. 2020. <https://doi.org/10.1109/TIFS.2020.2985628>.
- [16] H. Jeon and D. Lee, "Bi-Directional Long Short-Term Memory-Based Gait Phase Recognition Method Robust to Directional Variations in Subject's Gait Progression Using Wearable Inertial Sensor", *Sensors*, Vol. 24, No. 4, Article 1276, Feb. 2024. <https://doi.org/10.3390/s24041276>.
- [17] S. Mekruksavanich, W. Phaphan, and A.

Jitpattanakul, "A Deep Multi-Task Learning Network for Activity Recognition and User Identification Using Smartphone Sensors", *Procedia Computer Science*, Vol. 256, pp. 1350-1357, Feb. 2025. <https://doi.org/10.1016/j.procs.2025.02.248>.

저자소개

김민석 (Min-Seok Kim)



2006년 8월 : 전남대학교
컴퓨터공학과(석사)
2022년 6월 ~ 현재 : ㈜부트캠프
대표이사
2024년 3월 ~ 현재 : 광주대학교
광·정보 통신학과 박사과정
관심분야 : 디지털헬스케어,

임베디드 S/W

안드레스 카세레스 (Lismer Andres Caceres-Najarro)



2016년 8월 : 경성대학교
전자공학과(석사)
2021년 2월 :
광주과학기술원(GIST)
전기전자컴퓨터공학과(박사)
2023년 3월 ~ 2024년 5월 :
한국에너지공학대학교 에너지 AI

공학과 연구교수

2024년 9월 ~ 현재 : 조선대학교 컴퓨터공학과 조교수
관심분야 : Smart 헬스케어, localization, tracking

김광현 (Gwang-Hyun Kim)



1989년 2월 : 광운대학교
전자계산학과(이학사)
1992년 2월 : 광운대학교
전자계산학과(석사)
1997년 2월 : 광운대학교
전자계산학과(박사)
1997년 3월 ~ 현재 : 광주대학교

AI소프트웨어학과 교수

관심분야 : 머신러닝/딥러닝, 차세대네트워크 구축