

# 컴팩트 범용 잔차 구조(CURA)를 이용한 보행 신호 기반 골격근 비율 추정

서재범\*, 김민석\*\*, 안드레스 카세레스\*\*\*

## Skeletal Muscle Ratio Estimation from Gait Signals using a Compact Universal Residual Architecture (CURA)

Jae-Bum Seo\*, Min-Seok Kim\*\*, and Lismar Andres Caceres-Najarro\*\*\*

이 성과는 중소벤처기업부의 재원으로 중소기업기술정보진흥원의 지원을 받아 수행된 연구임 [RS-2025-02311567]  
This work was supported by the Technology Development Program [RS-2025-02311567] funded by the Ministry of  
SMEs and Startups (MSS, Korea)

### 요약

본 연구는 스마트폰 기반 보행 신호로부터 골격근 비율을 추정하기 위한 경량 딥러닝 프레임워크를 제안한다. 36명의 고령자를 대상으로 수집된 132개의 보행 세션을 활용하여 고차원 보행 특징을 추출하고, 이를 온디바이스 환경에서의 효율적 추론을 위해 설계된 잔차 신경망인 CURA(Compact Universal Residual Architecture)에 적용한다. 제안된 방법은 164.7K개의 파라미터로  $R^2$  92.78%와 MAE 1.01를 달성하였다. 신호 왜곡 환경에서의 동작을 평가하기 위해 입력 데이터에 가우시안 노이즈를 주입하였다. 그 결과, 제안된 모델은 비교 대상 기법 대비 안정적인 예측 성능을 유지하며, 최대 노이즈 수준에서도  $R^2$  77.06%를 달성하였다. 이러한 결과는 보행 특징이 생체역학적으로 관련된 정보를 포착할 수 있음을 시사하며, 경량 온디바이스 기반 골격근 추정의 가능성을 뒷받침한다.

### Abstract

This study presents a lightweight deep learning framework for estimating skeletal muscle ratio from smartphone-based gait signals. Using 132 gait sessions from 36 elderly participants, high-dimensional gait features are extracted and processed using Compact Universal Residual Architecture (CURA), a residual network designed for efficient on-device inference. The proposed approach achieves an  $R^2$  of 92.78% and an MAE of 1.01 with only 164.7K parameters. To examine behavior under signal distortion, Gaussian noise is injected into the input data. The model maintains stable predictive performance compared to baseline methods, achieving an  $R^2$  of 77.06% at the highest noise level. These findings provide exploratory evidence that gait features capture biomechanically relevant information, supporting lightweight, on-device skeletal muscle estimation.

### Keywords

lightweight deep learning, feature-based gait analysis, skeletal muscle ratio estimation, health monitoring

\* 조선대학교 컴퓨터공학과  
- ORCID: <https://orcid.org/0009-0005-5418-9659>  
\*\* 동강대학교 연구교수  
- ORCID: <https://orcid.org/0009-0007-3969-415X>  
\*\*\* 조선대학교 컴퓨터공학과 조교수(교신저자)  
- ORCID: <https://orcid.org/0000-0002-2784-0953>

· Received: Mar. 03, 2026, Revised: Jun. 13, 2026, Accepted: Jun. 16, 2026  
· Corresponding Author: Lismar Andres Caceres-Najarro  
Chosun University, Dept. of Computer Engineering  
Tel.: +82-62-230-7473, Email: [andrescn@chosun.ac.kr](mailto:andrescn@chosun.ac.kr)

## I. 서 론

보행 분석은 인간의 움직임을 이해하고 건강 상태를 평가하는 데 핵심적인 역할을 한다[1]. 보행이나 자세와 같은 일상 동작은 근육과 골격의 정교한 상호작용으로 이루어지며, 이를 정량적으로 추정함으로써 신체 내부의 부하 분포와 운동 메커니즘을 분석할 수 있다. 기존의 근전도나 역 역학 기반 측정 방식은 고가의 장비와 복잡한 절차를 요구하지만, 최근에는 관성 센서 데이터와 머신러닝 알고리즘을 결합하여 임상 현장에서 보다 효율적이고 비침습적으로 보행 특성을 분석하려는 시도가 주목받고 있다[2]. 특히, 보행 데이터를 기반으로 골격근 상태를 실시간 추정하면 근감소증(Sarcopenia), 파킨슨병 등 골격근계 질환의 조기 진단과 개인 맞춤형 재활 설계가 가능함이 선행 연구를 통해 제시된 바 있다[3]. 또한 웨어러블 센서와 결합하면 일상 환경에서도 골격근 기능을 지속적으로 모니터링할 수 있어, 고령화 사회에서의 건강 관리와 낙상 예방을 위한 실시간 모니터링 도구로서의 효용성이 강조되고 있다[2].

골격근 예측은 그동안 주로 정밀한 생체역학 장비와 복잡한 계산 과정에 의존해왔기 때문에 매우 고비용의 연구·진단 분야로 여겨져 왔다. 기존 접근법은 일반적으로 광학 모션 캡처 시스템, 표면 근전도, 그리고 역 역학 분석을 결합하여 근육의 힘, 관절 토크, 내부 하중을 계산하는 방식을 사용하였다[4].

근감소증 환자들은 근육량의 감소 속도와 신체 기능의 변화를 지속적으로 추적해야 하므로, 정기적인 골격근량 측정이 필수적이다. 그러나 이러한 측정은 일반적으로 이중에너지 X선 흡수계측, 근전도, 컴퓨터 단층 촬영/자기공명 영상 등의 정밀 장비를 사용해야 하며, 이는 높은 검사 비용과 전문 인력의 개입을 필요로 한다[5]. 따라서 병원 중심의 정기 평가에는 현실적인 제약이 따르며, 환자와 의료 시스템 모두에 경제적·시간적 부담이 발생한다.

전통적인 고비용 접근법 외에도, 다양한 형태의 데이터 기반 골격근 예측 모델이 제안되어 왔다. 대표적으로, 보행·활동 기반 예측형 모델은 웨어러블 센서(IMU, 압력 센서)나 스마트폰 내장 가속도계를

이용해 보행 패턴으로부터 골격근 상태를 추정하는 방식으로, 실시간 분석과 일상생활 적용이 가능하다는 장점이 있다[2][6].

생체·신체 지표 기반 모델은 신장, 체중, 근육량, 임상 검사 수치 등 인체 계측 정보나 생리학적 변수를 활용해 근력이나 관절 하중을 예측하는 방식으로, 의료 데이터 기반의 정적 추정에 적합하다[7].

또한 영상·이미지 기반 정량화 모델은 CT, MRI, 초음파 영상 등에서 심층학습을 통해 골격근 단면적 및 지방 분포 등을 정량화하여, 신체 내부의 근육 상태를 고해상도로 분석한다[8]. 그러나 이러한 방식은 고비용의 장비가 필요하다는 한계가 있다.

마지막으로, 최근에는 이러한 서로 다른 정보원을 결합한 복합 임상·모델 융합형 연구가 진행되고 있으며, 보행 데이터, 생체지표, 영상 정보를 통합함으로써 골격근 예측의 정확도와 임상 활용성을 동시에 높이는 방향으로 발전하고 있다[6][9].

본 연구는 범용 스마트폰 내장 센서로부터 추출된 보행 특징에 특징 공학을 적용한 후, 골격근 비율을 정량적으로 추정하기 위한 CURA(Compact Universal Residual Architecture)[10] 구조를 활용한다. 특히, 물리적 의미를 내포한 특징 공학 기법과 CURA 신경망 구조를 결합하여, 연산 자원이 제한된 온 디바이스 환경에서 회귀 추정 파이프라인의 동작 가능성을 탐색적으로 검증하는 데 목적이 있다. 나아가, 실제 측정 환경에서 발생할 수 있는 신호 왜곡 상황을 가정하여 가우시안 노이즈를 단계적으로 주입하고 모델의 반응을 분석함으로써, 제안하는 방법론이 보행 기반 골격근 추정에 활용될 수 있는 기술적 개연성을 확인하고자 한다.

## II. 관련 연구

다양한 선행 연구에서는 신체 활동 데이터와 생체 신호를 활용하여 근감소증 및 골격근 상태를 추정하려는 시도가 이루어져 왔다. 임상 환경에서는 일반적으로 컴퓨터 단층촬영, 자기공명 영상, 초음파 영상과 같은 영상 기반 측정 기법을 활용하여 골격근 관련 지표를 평가하며, 최근에는 딥러닝 기반 분석 기법이 결합되어 활용되고 있다[11]-[15].

이러한 방법들은 높은 정확도를 제공하지만, 고가의 장비와 전문 인력을 필요로 하기 때문에 일상 환경에서의 지속적인 모니터링에는 한계가 있다.

이러한 한계를 극복하기 위해, 최근에는 웨어러블 기기나 스마트폰 센서를 기반으로 한 비침습적이고 접근성이 높은 방법들이 제안되고 있다. 특히 보행 분석은 일상적인 움직임 속에서 근육 기능과 신체 역학 간의 상호작용을 반영할 수 있다는 점에서 유망한 접근 방식으로 주목받고 있다.

그러나 기존의 보행 또는 활동 데이터 기반 연구들은 대부분 근감소증의 유무를 판별하는 이진 분류 문제에 초점을 맞추고 있다. 예를 들어, M. Kim et al.[16]은 스마트폰 애플리케이션을 통해 파킨슨병 환자의 보행 패턴을 수집하고 근감소증을 0.949의 정확도로 예측하였다.

또한 M. Seok et al.[17]은 일상 신체 활동 데이터를 활용하여 딥러닝 모델이 근감소증을 81 - 90%의 정확도로 분류할 수 있음을 보였다. 이러한 연구들은 높은 성능을 보였으나, 이산적인 분류 결과에 의존하기 때문에 근육량의 미세한 변화를 연속적인 값으로 반영하는 데에는 한계가 있다.

M. Rezapour et al.[18]은 흉부 부착형 관성 측정 장치로부터 추출한 보행 변수를 활용하고 XGBoost 모델을 적용하여 하지 골절 환자의 합병증을 예측하였으며, 86%의 정확도를 달성하였다. 해당 연구는 보행 역학 정보가 생리적 상태와 밀접하게 연관되어 있음을 시사하며, 보행 기반 정량 추정의 가능성을 보여준다. 그러나 골격근 비율과 같은 연속적인 목표 변수를 직접적으로 추정하지는 않는다.

한편, 단순한 생리적 지표를 활용한 비침습적 선별 방법들도 제안되고 있다. M. S. Kim et al.[19]은 연령, BMI, 악력과 같은 기초 신체 지표를 기반으로 한 예측 모델을 제안하였으며, N. Li et al.[20]은 손 악력 시 전완부 근전도 신호를 분석하여 조기 선별 가능성을 제시하였다. 이러한 접근 방식은 측정의 접근성을 향상시키지만, 국소적인 신체 지표나 정적 정보에 의존하기 때문에 일상 보행 중 나타나는 전신 수준의 보행 역학을 충분히 반영하지 못하는 한계가 있다.

이에 비해, 본 연구는 다음과 같은 차별점을 갖

는다. 첫째, 기존의 이진 분류 중심 접근과 달리, 골격근 비율을 연속적인 값으로 추정하는 회귀 문제로 정식화하여 근육량 변화의 미세한 변화를 지속적으로 모니터링할 수 있도록 한다. 둘째, 스마트폰 내장 센서를 활용한 보행 신호를 이용함으로써 별도의 전문 장비 없이도 실용적이고 접근성 높은 데이터 수집이 가능하다. 셋째, 보행 특성을 반영한 특징 공학 기반 표현을 설계하고 이를 경량 신경망 구조인 CURA에 적용하여 온 디바이스 환경에서도 효율적인 성능을 달성한다. 마지막으로, 시뮬레이션된 노이즈 환경에서의 강건성 평가를 수행하여 실제 환경에서의 적용 가능성을 검증하였다.

### III. 설계 및 구현

본 연구에서는 인바디 체성분 데이터를 기반으로 피실험자의 골격근 비율을 산출하였다. 식 (1)은 골격근 비율(SMR, %)을 산출하기 위한 식이다.

$$SMR(\%) = \left( \frac{W_{SMM}}{W_{Body}} \right) \times 100 \quad (1)$$

$W_{SMM}$ 은 골격근량(kg),  $W_{Body}$ 는 측정된 체중(kg)을 의미한다. 즉, 식 (1)은 개인의 전체 체중에서 골격근량이 차지하는 비율을 백분율로 나타낸 것이다.

#### 3.1 데이터셋

본 연구의 데이터셋은 지역 커뮤니티센터를 방문한 60세 이상 고령자 36명을 대상으로 구축되었다.

연구 참여자로부터 기본 인구통계 및 신체 정보가 수집되었다. 주요 항목에는 성별, 생년월일, 신장, 체중, 다리 길이 등이 포함되며, 최근 6개월 이내 골절 및 낙상 경험과 같은 건강 이력 또한 조사되었다.

체성분 정보는 전문 생체전기 임피던스 분석 장비를 사용하여 측정하였다. 측정 항목은 체수분, 단백질, 무기질, 체지방량, 제지방량, 총 체중, 체질량 지수, 체지방률 등을 포함하며, 본 연구에서 가장 핵심적인 종속변수는 체중 대비 골격근 비율(%)이

다. 골격근 비율은 생체전기 임피던스 분석 장비로 측정된 식(1)에서 산출하였다. 본 절에서는 측정된 골격근량의 기술 통계를 함께 제시한다. 측정된 골격근량은 평균 22.0±4.1kg, 최소 - 최대 범위는 17.9 ~ 32.2 kg였으며, 이에 기반해 산출된 골격근량의 평균은 21.0± 5.8%로 확인되었다. 체성분 데이터는 근감소증과 보행 특성의 연관성을 분석하기 위한 주요 레이블로 사용되었다.

보행 데이터는 스마트폰 내장 센서(3축 가속도계, 3축 자이로스코프, 지자기 센서)를 이용해 수집되었다. 측정 방법은 일정한 보행 경로에서 수행되었으며, 센서 데이터를 통해 고령자 보행 특성을 반영하는 보행 속도, 보폭, 안정성, 보행 리듬 등의 정보를 포함하는 시계열 데이터가 확보되었다.

### 3.2 특징 선택

본 연구에서 사용한 입력 변수는 스마트폰 센서로부터 직접 측정된 원시 변수(SM, Smartphone-based Measurement variables)와, 원시 변수를 이용해 산출한 특징 공학 변수(FE, Feature Engineering variables)로 구성하였다. 표 1은 최종 분석에 사용된 주요 특징군과 물리적 의미를 요약한 것이다. 다음은 FE에 관한 설명이다.

표 1. 스마트폰 기반 측정 변수 및 특징 공학 변수  
Table 1. Smartphone-based measurement variables and feature-engineered variables

No.	Feature Name	Group	Description
1	acc_n (acc_nx, acc_ny, acc_nz)	FE	Normalized acc. (Gait-invariant)
2	mag_n (mag_nx, mag_ny, mag_nz)	FE	Normalized mag.
3	gyro_n (gyro_nz)	FE	Normalized gyro-z
4	gyro_sqrt (gyrox_sqrt, gyroy_sqrt, gyroz_sqrt)	FE	Sqrt-scaling for outlier reduction
5	acc_sqrt (accx_sqrt, accy_sqrt, accz_sqrt)	FE	Sqrt-scaling for signal stability
6	acc_sq (accx_sq, accy_sq, accz_sq)	FE	square-transformation
7	gyro_sq (gyrox_sq, gyroy_sq, gyroz_sq)	FE	square-transformation
8	mag_magnitude, gyro_magnitude	FE	Extreme Short

9	log_magnitude (log_mag_magnitude, log_gyro_magnitude)	FE	Log-scale for distribution normality
10	ratio (mag_to_acc, gyro_to_acc)	FE	Sensor ratios
11	variation (acc_cv, mag_cv)	FE	Dispersion metrics
12	energy (mag_energy, gyro_energy)	FE	Total energy
13	entropy (acc_entropy)	FE	entropy using acc data x,y,z
14	orientation (tilt, acc_azimuth, roll)	FE	Spatial orientation
15	acc (accx, accy, accz)	SM	Raw 3-axis acceleration
16	mag (magx, magy, magz)	SM	Raw 3-axis magnetic field
17	gyro (gyroz)	SM	Raw z-axis angular velocity
18	rotation_gyro (rotation_mx, rotation_mz, rotation_my)	SM	Gyro-based rotation matrix
19	rotation_acc (rotation_ax, rotation_ay, rotation_az)	SM	Acc-based rotation matrix
20	rotation_rate (rotation_hz, rotation_hy, rotation_hx)	SM	Rate of change in rotation
21	linear_acc (linear_accx, linear_accy, linear_accz)	SM	Gravity-removed acceleration
22	azimuth (azimuth)	SM	Compass-based heading

센서가 측정하는 절대적인 크기 값이나 개인마다 다른 보행 강도의 영향을 줄이기 위해, 가속도와 자기장 신호를 방향 정보만 남기는 방식으로 변환하였다. 이를 위해 각 센서의 3축(x·y·z) 세 축 값을 하나의 벡터로 보고, 그 벡터가 가진 전체 크기로 나누어 정규화하였다.

결과로 크기의 영향이 사라지고, 센서가 어느 방향을 가리키는지만 남게 된다. 이 과정을 통해 생성된 특징이 acc\_nx, acc\_ny, acc\_nz와 mag\_nx, mag\_ny, mag\_nz, gyro\_nz이며, 모두 센서의 방향성만을 나타내는 단위벡터 형태이다.

이러한 방향 기반 특징은 측정 환경이나 보행 강도 차이에 영향을 덜 받기 때문에, 보행 패턴 분석에서 보다 안정적인 입력으로 활용할 수 있다.

각 축의 신호 값을 제곱근 형태로 변환하여 gyro\_sqrt, gyroy\_sqrt, gyroz\_sqrt, accx\_sqrt, accy\_sqrt,

accz\_sqrt 변수를 생성하였다. 이는 신호의 크기를 완만하게 축소하여 극단값의 영향을 줄이고, 분포의 스케일을 안정화하기 위한 전처리 과정이다. 각속도와 가속도 센서를 사용하였다.

다음은 accx\_sq, accy\_sq, accz\_sq, gyro\_x\_sq, gyro\_y\_sq, gyro\_z\_sq의 설명이다. 이는 각 축 값의 제곱은 신호 에너지에 가까운 의미를 갖기 때문에, 특정 축의 진동 크기가 큰 구간을 강조하는 역할을 한다. 또한 음수 값을 양수로 변환하여, 절댓값 기반의 크기 변화를 부드럽게 반영한다. 센서로는 가속도와 각속도 센서를 사용하였다.

mag\_magnitude, gyro\_magnitude 두 변수는 센서의 3축 값을 이용해 벡터의 전체 크기를 계산한 특징이다. 각 축 값을 제공한 뒤 모두 더하고, 그 합에 제곱근을 취하는 방식으로 산출한다. 즉, 다음과 같이 센서 신호의 전체 강도를 하나의 값으로 요약한 것이다. 여기서는 지자기 센서와 각속도 센서의 3축 신호를 사용하였다.

이와 더불어, 개별 센서의 절댓값뿐만 아니라 서로 다른 센서 데이터 간의 상관관계를 추출하기 위해 가속도 대비 각속도 및 지자기의 크기 비율(Ratio)을 정의하였다. 이는 움직임의 강도 변화에 따른 회전 및 방향성 성분의 상대적 비중을 파악하기 위함이다.

앞서 설명한 mag\_magnitude, gyro\_magnitude는 원시 값의 분포가 치우치거나 이상치에 민감할 수 있어 log\_mag\_magnitude, log\_gyro\_magnitude 역시 추가하였다. 본 연구에서는 이를 log1p 변환을 적용하여 로그 스케일로 안정화하였다. 이를 통해 극단적으로 큰 값의 영향을 줄이고 전체 분포를 정규화하여, 모델이 보다 안정적으로 학습이 가능하도록 해당 특징을 생성하였다.

앞서 설명한 mag\_magnitude, gyro\_magnitude를 이용해 gyro\_to\_acc와 mag\_to\_acc를 만들었다.

$$\text{gyro\_to\_acc} = \frac{\text{gyro\_magnitude}}{\text{acc\_magnitude} + 1e^{-6}} \quad (2)$$

$$\text{mag\_to\_acc} = \frac{\text{mag\_magnitude}}{\text{acc\_magnitude} + 1e^{-6}} \quad (3)$$

식은 (2)(3)과 같으며, 지자기 센서와 각속도 센서

를 기반으로 움직임 대비 회전 및 자기장 변화의 상대적 크기를 정량적으로 표현하고자 하였다. 또한 분모에  $1e^{-6}$ 의 작은 상수를 더한 이유는, 일부 구간에서 가속도 크기가 극단적으로 작아지는 경우 0으로 나누는 문제를 방지하기 위함이다.

각 센서에 대해 변동계수를 계산하여 acc\_cv, mag\_cv 특징을 생성하였다. 이 값들은 보행 동안 해당 신호가 얼마나 균일하거나, 혹은 얼마나 진동·흔들림이 심하게 발생하는지를 나타내며, 보행 패턴의 불안정성 또는 움직임 강도의 차이를 반영하는 유용한 입력으로 활용하였다. 센서는 가속도와 지자기를 사용하였다.

단순한 통계적 변동성 외에, 실제 보행 시 발생하는 물리적 활동 강도를 파악하고자 각 센서 신호의 에너지(energy)를 추출하였다.

센서 신호의 변동 크기를 직관적으로 반영하기 위해 각 센서의 3축 성분 값을 활용하여 다음과 같이 에너지 계산하였다. 각 센서별 에너지 지표인 mag\_energy, gyro\_energy는 다음과 같이 정의된다.

$$\text{mag\_energy} = \text{mag}_x^2 + \text{mag}_y^2 + \text{mag}_z^2 \quad (4)$$

$$\text{gyro\_energy} = \text{gyro}_x^2 + \text{gyro}_y^2 + \text{gyro}_z^2 \quad (5)$$

식 (4),(5)는 각각 지자기, 각속도의 3축 방향 성분 값을 의미한다. 이러한 에너지 지표는 센서 신호의 변화량을 직관적으로 나타내는 특징이 있다.

에너지 지표가 활동의 강도를 반영한다면, 보행 신호의 구조적 복잡성을 파악하기 위해서는 신호의 통계적 무작위성을 측정할 수 있는 지표가 수반되어야 한다. 이에 본 연구에서는 보행 신호의 불확실성과 동적 변이를 정량화하기 위해, 3축 가속도 신호의 에너지 분포에 기초한 정보 엔트로피를 다음과 같이 산출하였다.

$$H(x) = - \sum_{i=1}^n p_i \cdot \log(p_i + 1e^{-6}) \quad (6)$$

이때 식 (6)의  $p_i$ 는 각 시점에서 3축 가속도 신호의 전체 크기 대비 각 축 성분이 차지하는 상대적 비중을 의미하며, 다음과 같이 정의된다.

$$p_i = \frac{|x_i|}{\sum_{j=1}^n |x_j| + 1e^{-6}} \quad (7)$$

결과적으로 식 (7)은 특정 시점에서 가속도 벡터가 어느 한 축으로 집중되는지, 혹은 여러 축에 걸쳐 불규칙하게 분산되는지를 측정함으로써 보행 자세의 동적 복잡성을 포착하는 지표로 활용된다.  $1e^{-6}$ 의 작은 상수를 더한 이유는, 일부 구간에서 가속도 크기가 극단적으로 작아지는 경우 0으로 나누는 문제를 방지하기 위함이다. 특히 보행 신호가 일정한 패턴을 벗어나 무질서해질수록 엔트로피 값이 증가하므로, 이를 통해 보행의 안정성과 질적 변화를 효과적으로 분석할 수 있다.

또한, 보행 중 신체의 동적 움직임뿐만 아니라 공간상에서의 자세 변화를 정량화하기 위해 가속도 센서 기반의 방위 정보를 산출하였다. 이는 중력 성분을 포함한 원시 가속도계 신호의 축 간 비율을 분석함으로써 보행 시 발생하는 전후방 기울기, 좌우 회전 및 경사도를 다각도에서 포착하는 지표가 된다.

보행 시 센서의 전방 기울기를 근사적으로 추정하기 위해, 3축 가속도 센서 성분을 기반으로 기울기 지표(Tilt)를 정의하였다. 전방 기울기 지표  $\theta_{tilt}$ 는 전후 방향 가속도 성분  $accx$ 와, 이에 직교하는 평면에서의 기준 크기  $\sqrt{accy^2 + accz^2}$ 를 이용하여 다음과 같이 계산된다.

$$\theta_{tilt} = \arctan2(accx, \sqrt{accy^2 + accz^2}) \quad (8)$$

식 (8)은  $\arctan2(\cdot, \cdot)$ 는 두 변수에 대한 역탄젠트 함수로, 각도의 사분면 정보를 보존하여 반환하는 함수이다. 이 정의는 전방 성분과 직교 평면 성분 간의 비율을 각도로 변환한 것으로, 센서 신호의 절대 크기에 대한 영향을 줄이면서 순수한 기울기 방향 정보를 효과적으로 반영한다. 예를 들어,  $accx$ 가 기준 크기에 비해 매우 작은 경우  $\theta_{tilt}$ 는  $0^\circ$ 에 가까워져 기울기가 거의 없는 상태를 의미한다. 반대로  $accx$ 가 기준 크기와 유사한 수준일 경우,  $\theta_{tilt}$ 는 약  $45^\circ$ 로 증가하여 비교적 큰 전방 기울기를 나타낸다.

보행 중 센서가 가리키는 좌우 방향각(Acc azimuth)을 계산하기 위해, 앞뒤와 좌우 가속도의 비율을 이용하여 각도를 산출하였다.

$$acc - azimuth = \deg(\arctan2(accy, accx)) \quad (9)$$

식 (9)에서  $\deg(\cdot)$ 는 라디안 단위를 도 단위로 변환하는 함수를 의미한다. 이 식은 각각  $accx$ ,  $accy$  좌표로 간주하고, 이 두 값이 이루는 기울기를 역탄젠트로 변환하여 좌우 회전 방향을 각도로 표현하는 방식이다.

식 (10)은 보행 중 스마트폰 센서의 좌우 기울기(Roll)를 산출하기 위한 식이다.

$$roll = \deg(\arctan2(accy, accz + 1e^{-6})) \quad (10)$$

여기서  $accy$ 와  $accz$ 는 각각 가속도 센서의 좌우축 및 상하축 성분을 의미한다.

SM 항목은 스마트폰 내장 센서로부터 추출된 원시 형태의 특징군을 의미한다. 상세한 산출 과정보다는 이를 활용한 골격근 비율 추정 모델의 동작 타당성을 탐색적으로 검증하는 것이 본 연구의 주된 목적인바, 개별 변수의 수리적 정의 대신 모델의 입력 변수로서 갖는 물리적 의미를 중심으로 요약하여 제시한다.

### 3.3 랜덤포레스트 기반 중요도 평가

랜덤포레스트 기반 골격근 비율 학습을 통해 기여도가 높은 상위 특징들을 분석한 결과, 단순 센서 원시 값보다는 특정 공학을 거친 변수들이 모델의 예측 성능에 핵심적인 역할을 하는 것으로 나타났다. 아래의 표 2에서 0.005 이하의 값은 분석에 유의미함이 없을 것이라 판단해 제외하였다.

자기장-가속도 비율(mag\_to\_acc)의 결정적 역할 가장 높은 중요도(0.242)를 기록한 mag\_to\_acc는 가속도(움직임의 강도) 대비 자기장 변화의 상대적 크기를 나타낸다.

이는 고령자의 보행 시 발생하는 동적인 움직임과 신체 방향 유지 능력이 골격근량과 밀접한 상관

관계가 있음을 시사한다. 특히 근육량이 적은 대상자일수록 보행 시 불필요한 흔들림이나 불규칙한 자기장 변화가 가속도 신호와 결합되어 나타나는 특성이 모델에 반영된 것으로 풀이된다.

accx\_sqrt, accx\_sq, accx\_sqrt, accx\_sq 변수가 나란히 상위권에 위치했다. 이는 단순히 걷는 속도뿐만 아니라, 발을 내디딜 때 발생하는 충격의 미세한 분포와 추진력의 강도가 골격근 상태를 결정짓는 중요한 지표임을 의미한다.

roll, acc\_cv, acc\_azimuth 좌우 기울기를 나타내는 roll(0.077)과 보행의 불규칙성을 의미하는 변동계수 acc\_cv(0.031)가 유의미한 순위를 차지했다. 골격근량이 적은 고령자에게서 흔히 나타나는 '보행 시 좌우 흔들림'과 불규칙한 보행 리듬이 스마트폰 내장 센서를 통해 효과적으로 포착되었음을 보여준다.

표 2. 랜덤포레스트 모델의 변수 중요도 분석 결과  
Table 2. Feature importance analysis results for random forest model

Rank	feature_name	import
1	mag_to_acc	0.24
2	magz	0.16
3	accx_sqrt	0.09
4	accx_sq	0.08
5	roll	0.07
6	acc_cv	0.03
7	rotation_my	0.02
8	acc_entropy	0.02
9	acc_azimuth	0.02
10	rotation_ax	0.01
11	rotation_hy	0.01
12	rotation_az	0.01
13	mag_nx	0.01
14	magx	0.01
15	acc_ny	0.008
16	rotation_hx	0.008
17	mag_cv	0.008
18	mag_magnitude	0.008
19	rotation_ay	0.007

결과적으로 본 연구에서 제안한 특징 공학 기법은 단순 스마트폰 내장 센서의 신호를 고령자의 보행 특성을 반영하는 고차원적 지표로 성공적으로 변환하였다.

본 변수 중요도 평가 실험은 특징 공학을 통해 생성된 변수들의 생체역학적 기여도를 탐색적으로 파악하기 위한 목적으로 수행되었다. 이후 진행된 CURA 구조의 학습 및 성능 평가 단계에서는 정보 손실을 방지하고 딥러닝 모델의 고차원 특징 학습 능력을 극대화하기 위해, 특징 공학을 거친 전체 변수 집합을 입력 벡터로 활용하였다.

## IV. 실험

본 장에서는 보행 센서 데이터를 활용하여 제안한 CURA 구조 기반 회귀 모델의 골격근 비율 예측 성능을 평가하고, 추가적으로 실제 환경에서 발생할 수 있는 센서 노이즈에 대한 모델의 강건성을 검증하였다. 이를 위해 CURA 구조를 이용한 학습 과정과 노이즈 주입 기반 안정성 실험을 순차적으로 수행하였으며, 각 단계별 결과를 아래에 기술한다. 또한 본 실험은 R2의 경우 % 값을, MAE, MSE의 경우 실제 값을 기술하였다.

### 4.1 CURA를 이용한 골격근 비율 회귀 학습

본 연구에서는 제안한 CURA 기반 회귀 모델을 활용하여 보행 데이터로부터 골격근 비율을 예측하였다. 모델의 신뢰성과 일반화 성능을 확보하기 위해 모든 모델에 5-겹 교차 검증을 수행하였으며, 이를 통해 특정 데이터 분할에 따른 편향을 최소화하였다.

CURA 구조의 하이퍼 파라미터 설정에서 은닉층 차원은 129로 고정하였으며, 모델의 복잡도에 따른 성능 변화를 분석하기 위해 Depth를 각각 1, 2, 3으로 설정하여 비교 실험을 진행하였다.

본 연구에서는 제안 방법론의 타당성을 객관적으로 검증하기 위해 LSTM과 고전적 기계학습 모델인 XGBoost를 비교 군으로 설정하였다.

우선 XGboost의 설정이다. XGboost의 경우 그리드 서치를 이용하여 설정값이 결정되었고, 결과 colsample\_bytree: 0.7, gamma: 10.0, learning\_rate: 0.01, max\_depth: 2, max\_leaves: 4, min\_child\_weight: 50, n\_estimators: 1200, reg\_alpha: 0.0, reg\_lambda: 100, subsample: 0.7으로 세팅이 되었다.

LSTM 모델은 데이터의 입력 형태에 따라 최적화된 구성을 채택하였다. 우선, 원시 데이터(RAW) 학습을 위한 모델은 입력 차원에 맞춰 3000개의 입력과 17차원의 은닉층과 3개의 레이어로 구성하여 총 210K의 파라미터를 확보하였다.

LSTM, CURA 두 모델 모두 AdamW 옵티마이저를 사용하였으며, 학습률은 0.001, 가중치 감쇠는 0.0001을 적용하여 규제 효과를 도모하였다. 또한 각 Fold 별로 검증 오차를 실시간 모니터링하여 15회 이상 성능이 정체될 경우 조기 종료를 수행하였다.

고전적 기계학습 모델인 XGBoost는 신경망 구조와 달리 명시적인 학습 파라미터 수 추정이 불가능하므로 해당 항목을 N/A로 표기하였고 신경망의 경우는 파이토치 라이브러리를 활용하여 파라미터를 산출하였다.

아래는 표 3은 제안하는 CURA 구조 기반 회귀 모델과 LSTM 구조 기반 회귀 모델, 그리드 서치로 최적화된 XGBoost의 골격근 비율 예측 성능을 비교한 결과이다.

표 3의 결과에서 CURA는 특징 공학 기반 입력 벡터와 결합될 때 모델 규모 증가에 따라 예측 성능이 향상되는 경향을 보였다. CURA-164.7K는 R<sup>2</sup> 92.78%, MAE 1.01을 기록하여 XGBoost와 유사한 수준의 설명력을 보이면서도 더 낮은 MAE를 나타냈다. XGBoost는 R<sup>2</sup>기준으로 가장 높은 값을 보였으나, MAE는 CURA-164.7K보다 높았다. 따라서 본 결과는 제안한 CURA가 특징 벡터 기반 회귀 문제에서 정확도와 경량성 사이의 균형을 가질 수 있음을 보여준다.

표 3. 5-겹 세션 단위 교차검증 기반 골격근 비율 예측 성능 비교

Table 3. Performance comparison for skeletal muscle ratio prediction using 5-fold session-level cross-validation

Type	Model	Param	MAE	R <sup>2</sup> (%)±SD(%)
Feat.	CURA	30.5K	2.52	74.55%±0.68%
		97.6K	1.40	90.63%±0.47%
		164.7K	1.01	92.78%±1.41%
	XGboost[21]	N/A	1.80	93.15%±0.02%
RAW	LSTM	210K	4.37	38.38%±1.95%

본 연구의 실험 결과는 복잡한 시계열 신호로부터 유효한 정보를 도출함에 있어 제안하는 특징 공학 기법이 갖는 중요성을 보였다. 원시 데이터(RAW)를 직접 입력으로 사용한 경우, LSTM의 경우 R<sup>2</sup> 스코어가 각각 38.38% 수준에 머물렀으며, MAE 역시 4.37로 매우 높게 나타났다. 이는 특징 공학 없이 심층 신경망 구조만으로는 신호 내재적인 복잡한 비선형적 연결고리를 포착하기에 한계가 있음을 시사한다.

이에 본 연구에서는 보행 데이터와 골격근 비율 간의 기술적 개연성을 보다 심층적으로 파악하고자, 신호 오염 상황에 따른 모델의 반응성을 관찰하는 추가 실험을 진행하였다. 이는 제안된 구조가 단순히 학습 데이터 내의 수치적 상관관계를 추종하는 것을 넘어, 입력 신호의 왜곡 상황에서도 골격근 상태를 유추할 수 있는 본질적인 생체역학적 패턴을 일관되게 포착하고 있는지 탐색하기 위함이다.

이를 위해 검증 데이터에 평균이 0인 가우시안 노이즈( $\sigma$ )를 인위적으로 주입하여 실제 환경에서 발생 가능한 신호 왜곡을 모의하였으며,  $\sigma$ 를 0.01, 0.05, 0.10의 세 단계로 강화하며 모델의 출력값 변화 추이를 분석하였다. 단, 앞선 실험에서 보행 데이터의 복잡성으로 인해 유의미한 학습 수준에 도달하지 못한 LSTM 모델은 노이즈 주입을 통한 반응성 분석의 실익이 낮다고 판단하여 본 실험 대상에서 제외하였다.

#### 4.2 노이즈 강건성 평가

본 연구에서는 보행 기반 골격근 비율 예측 모델의 안정성을 확인하기 위해 입력 변수에 대한 노이즈 강건성 평가를 수행하였다. 검증 데이터셋에 평균 0의 가우시안 노이즈를 주입하였으며, 표준편차  $\sigma$ 를 0.01, 0.05, 0.10으로 단계적으로 증가시켰다. 이는 실제 스마트폰 센서 환경에서 발생할 수 있는 약한 진동, 측정 오차, 착용 위치 변화에 따른 입력 변동을 모의하기 위한 설정이다.

각 노이즈 수준에서 모델의 예측값을 산출한 후 MAE, RMSE, R<sup>2</sup>를 기반으로 성능을 평가하였다. 그 결과,  $\sigma$ 가 증가함에 따라 일부 성능 저하가 나타났

으나 전반적으로 모델의 예측 정확도는 안정적 수준을 유지하였으며, 이는 CURA 구조가 가진 입력 안정화 효과와 게이팅·잔차 결합 구조의 영향으로 해석할 수 있다. 이러한 분석은 제안한 모델과 특징 조합이 현실 환경의 센서 노이즈에도 비교적 강건하게 대응할 수 있음을 시사한다.

표 4에 나타난 노이즈 수준별 성능 분석 결과, 입력  $\sigma$ 가 증가함에 따라 전반적인 예측 정밀도는 낮아지는 경향을 보였다. 노이즈가 적은 환경( $\sigma=0.01$ )에서 CURA 모델들은 파라미터 규모에 따라 1.24 ~ 2.74 범위의 MAE와 최대 90.79% (164.7k 기준)의  $R^2$ 를 기록하였으나, 트리 기반의 XGBoost는 동일 조건에서  $R^2$ 가 20.28%에 머물렀다.

표 4. 입력 노이즈 수준에 따른 골격근 비율 예측 성능 변화

Table 4. Impact of input noise levels on skeletal muscle ratio prediction performance

Model	Param	$\sigma$	MAE	RMSE	$R^2(\%)$
CURA	30.5K	0.01	2.74	4.43	72.54%
	30.5K	0.05	2.96	4.63	70.01%
	30.5K	0.10	3.48	5.19	62.34%
	97.6K	0.01	1.46	2.62	90.35%
	97.6K	0.05	1.75	3.14	86.20%
	97.6K	0.10	2.32	4.21	75.15%
	164.7K	0.01	1.24	2.56	90.79%
	164.7K	0.05	1.42	3.02	87.22%
	164.7K	0.10	1.86	4.05	77.06%
XGboost[21]	NA	0.01	4.03	7.55	20.28%
	NA	0.05	4.69	8.49	0.30%
	NA	0.10	5.20	9.07	-14.93%

노이즈가 중간 강도( $\sigma=0.05$ )로 높아질 때 XGBoost는 성능이 급격히 저하된 반면, 신경망 기반의 CURA 모델들은 70.01~87.22%대의  $R^2$ 를 유지하였다. 특히 가장 강한 노이즈( $\sigma=0.10$ ) 환경에서도 CURA-164.7k 모델은 77.06%의  $R^2$ 와 MAE 1.86을 기록하며 상대적으로 완만한 성능 감소 폭을 보였다.

높은 노이즈 수준( $\sigma=0.10$ )에서 XGBoost 모델의  $R^2$ 가 음수(-14.93%)로 급격히 하락하며 모델이 완전히 붕괴된 것은, 트리 기반 모델의 구조적 특성에 기인한다. XGBoost와 같은 결정 트리 모델은 입력 특징의 미세한 변동에도 민감하게 반응하여 불연속적이고 날카로운 결정 경계를 형성하는 경향이 있

다. 이로 인해 신호 왜곡이 임계치를 넘어서는 환경에서는 노이즈를 유의미한 신호로 오인하여 예측의 일관성을 완전히 상실하게 된다.

## V. 토의 및 토론

본 연구는 특징 공학과 경량화된 CURA 구조를 결합하여 스마트폰 기반 보행 신호로부터 골격근 비율을 추정하는 접근의 타당성을 탐색적으로 분석하였다.

### 5.1 보행 신호 기반 골격근량 추정의 타당성

실험 결과, 스마트폰 기반 보행 신호로부터 골격근 비율을 추정하는 것이 가능함을 확인하였다. 제안된 CURA 구조는 비교적 적은 수의 파라미터를 유지하면서도 모델 용량이 증가함에 따라 예측 성능이 일관되게 향상되는 경향을 보였으며, 이는 정확도와 계산 효율성 간의 효과적인 균형을 나타낸다. 이러한 결과는 보행 기반 특징이 골격근 구성과 관련된 잠재적인 생체역학적 정보를 반영하고 있음을 시사한다.

가공되지 않은 원시 데이터 기반의 딥러닝 모델인 LSTM과의 비교를 통해 특징 표현의 역할을 더욱 명확히 확인하였다. LSTM 모델은 원시 데이터로부터 의미 있는 패턴을 추출하는 데 한계를 보인 반면, 특징 기반의 CURA 모델은 안정적이고 정확한 예측을 달성하였다. 이러한 결과는 보행 신호에 내재된 구조적 정보를 추출하는 데 있어 적절하게 설계된 특징 공학의 중요성을 보여주며, 제안된 접근 방식의 타당성을 뒷받침한다.

### 5.2 신호 왜곡 환경에서의 모델 반응성 분석

가우시안 노이즈 주입을 통한 평가 결과, 제안된 CURA 구조는 신호 왜곡이 증가함에도 불구하고 비교적 안정적인 성능을 유지하는 것으로 나타났다. 노이즈 수준이 높아짐에 따라 예측 정확도는 점진적으로 저하되었으나, 모델은 일정 수준의 예측 성능을 유지하였으며, 이는 입력 섭동에 대한 안정적인 동작 특성을 시사한다. 반면, XGBoost 모델은 동

일한 조건에서 성능이 급격히 하락하여 노이즈에 더 민감하게 반응하는 경향을 보였다.

이러한 결과는 CURA가 노이즈에 민감한 신호 특성에 의존하기보다, 골격근 비율과 관련된 구조적 패턴을 포착하고 있음을 보여준다. 또한 왜곡된 환경에서도 예측 성능이 유지되는 경향은 모델이 보행 신호에 내재된 일관된 생체역학적 구조를 활용하고 있음을 시사한다.

### 5.3 방법론적 고려사항 및 향후 개선 계획

본 연구에서 사용된 세션 단위 검증은 스마트폰 기반 특징 표현으로부터 골격근 관련 정보가 추출될 수 있는지를 평가한다. 이러한 설정은 제한된 데이터를 효율적으로 활용할 수 있게 하며, 보행 신호와 골격근 비율 간 관계의 학습 가능성을 확인하는데 기여한다.

평가를 보다 강화하기 위해, 향후 연구에서는 데이터셋 확장과 함께 1인 제외 교차 검증(LOSO)과 같은 피험자 독립적 검증 방식을 도입할 예정이다. 특히, 연령, 신체 조건, 보행 특성이 보다 다양한 피험자를 포함하도록 데이터셋을 확장할 계획이다. 또한 실제 사용 환경을 반영하기 위해 통제되지 않은 조건에서의 데이터 수집도 고려할 것이다.

아울러, 기기 간 변동성과 종단적 측정을 포함한 이질적인 환경에서 모델의 안정성과 일관성을 분석할 예정이다. 이러한 확장 연구는 제안된 프레임워크에 대한 보다 종합적인 평가를 가능하게 하며, 실제 환경에서의 적용 가능성을 뒷받침할 것이다.

### 5.4 임상적 관점에서의 해석

본 연구는 기존의 체성분 측정 방법을 대체하기 위해 설계된 것이 아니다. 대신, 스마트폰 기반 보행 신호가 골격근 비율과 관련된 특성을 반영할 수 있음을 보였다. 이러한 결과는 널리 활용 가능한 관성 센서 데이터를 근육 관련 평가를 위한 간접적이고 접근성 높은 지표로 활용할 수 있는 가능성을 시사한다.

향후 더 크고 다양한 집단을 대상으로 한 추가 검증이 이루어진다면, 제안된 접근 방식은 모바일

헬스케어 환경에서 일상적인 스크리닝 및 골격근 변화의 종단적 모니터링을 위한 보완적 도구로 활용될 수 있다. 이러한 맥락에서 본 방법은 단독 진단 도구라기보다는, 지원적이며 확장 가능한 평가 도구로서 활용되는 것이 적절하다.

## VI. 결 론

본 연구는 특징 공학과 경량 CURA 구조를 결합하여 스마트폰 기반 보행 신호로부터 골격근 비율을 추정하는 것의 타당성을 조사하였다. 제안된 프레임워크는 소형화된 모델 크기에도 높은 예측 성능을 달성하였으며, 이는 정확도와 계산 효율성 사이의 효과적인 균형을 보여준다. 이러한 결과는 보행 기반 특징들이 골격근 구성과 관련된 유의미한 생체역학적 정보를 내포하고 있음을 시사한다.

신호 왜곡 환경에서의 분석 결과, 본 모델은 입력 데이터의 품질이 저하되어도 안정적인 예측 거동을 유지하였으며, 이는 실제 센싱 환경에서의 적용 가능성을 나타낸다. 또한, 원시 데이터 기반의 LSTM과의 비교를 통해 보행 데이터에서 구조적으로 유의미한 정보를 추출하는 데 있어 특징 표현의 중요성을 확인하였다.

결론적으로, 본 연구는 통제된 조건 하에 스마트폰 기반 보행 신호가 골격근 관련 특성을 추정하는데 활용될 수 있다는 탐색적 근거를 제시하며, 경량화된 온디바이스 헬스 모니터링 방식의 타당성을 뒷받침한다. 향후 연구에서는 더욱 다양하고 실제적인 환경에서의 추가 검증에 집중할 계획이다.

## References

- [1] R. Baker, "The history of gait analysis before the advent of modern computers", *Gait & Posture*, Vol. 26, No. 3, pp. 331-342, Sep. 2007. <https://doi.org/10.1016/j.gaitpost.2006.10.014>.
- [2] M. A. Hossen and P. E. Abas, "Machine Learning for Human Activity Recognition: State-of-the-Art Techniques and Emerging Trends", *Journal of Imaging*, Vol. 11, No. 3, pp. 1-56, Mar. 2025.

- <https://doi.org/10.3390/jimaging11030091>.
- [3] A. Mirelman, P. Bonato, R. Camicioli, T. D. Ellis, N. Giladi, J. L. Hamilton, C. J. Hass, J. M. Hausdorff, E. Pelosin, and Q. J. Almeida, "Gait impairments in Parkinson's disease", *The Lancet Neurology*, Vol. 18, No. 7, pp. 697-708, Jul. 2019. [https://doi.org/10.1016/S1474-4422\(19\)30044-4](https://doi.org/10.1016/S1474-4422(19)30044-4).
- [4] S. L. Delp, F. C. Anderson, A. S. Arnold, P. Loan, A. Habib, C. T. John, E. Guendelman, and D. G. Thelen, "OpenSim: Open-Source Software to Create and Analyze Dynamic Simulations of Movement", *IEEE Transactions on Biomedical Engineering*, Vol. 54, No. 11, pp. 1940-1950, Nov. 2007. <https://doi.org/10.1109/TBME.2007.901024>.
- [5] L. K. Chen, J. Woo, P. Chunhua, L. K. Arai, M. Akishita, and C. K. Lin, "Asian Working Group for Sarcopenia: 2019 consensus update on sarcopenia diagnosis and treatment", *Journal of the American Medical Directors Association*, Vol. 21, No. 3, pp. 300-307, Mar. 2020. <https://doi.org/10.1016/j.jamda.2019.12.012>.
- [6] K. Fujita, T. Hiyama, K. Wada, T. Aihara, Y. Matsumura, T. Hamatsuka, Y. Yoshinaka, M. Kimura, and M. Kuzuya, "Machine learning-based muscle mass estimation using gait parameters in community-dwelling older adults: A cross-sectional study", *Archives of Gerontology and Geriatrics*, Vol. 103, No. 104793, pp. 1-7, Nov. 2022. <https://doi.org/10.1016/j.archger.2022.104793>.
- [7] R. C. Lee, Z. Wang, M. S. Heo, R. Ross, J. Wang, and S. B. Heymsfield, "Total-body skeletal muscle mass: development and cross-validation of anthropometric prediction models", *The American Journal of Clinical Nutrition*, Vol. 72, No. 3, pp. 796-803, Sep. 2000. <https://doi.org/10.1093/ajcn/72.3.796>.
- [8] I. Irmakci, S. Al-Amri, and U. Bagci, "Deep learning for musculoskeletal image analysis", *Proc. of the 53rd Asilomar Conference on Signals, Systems, and Computers*, pp. 1481-1485, Nov. 2019. <https://doi.org/10.1109/IEEECONF44664.2019.9048671>.
- [9] R. Kreher, et al., "Multilabel segmentation and analysis of skeletal muscle and adipose tissue in routine abdominal CT scans", *Computers in Biology and Medicine*, Vol. 182, pp. 1-7, Mar. 2025. <https://doi.org/10.1016/j.combiomed.2024.109622>.
- [10] J. B. Seo, M. Salman, and L. A. Caceres-Najarro, "CURA: Size Isn't All You Need – A Compact Underlying Architecture for On-Device Intelligence", *IEEE Transactions on Consumer Electronics*, Early Access, pp. 1-11, Jun. 2026. <https://doi.org/10.1109/TCE.2026.3703044>.
- [11] M. Onishi, T. Iseki, S. Tsuji, and Y. Momoki, "Usefulness of a newly developed ultrasonic system to estimate skeletal muscle mass and muscle strength in community-dwelling older adults", *Scientific Reports*, Vol. 15, No. 1, pp. 1-10, Jul. 2025. <https://doi.org/10.1038/s41598-025-09430-z>.
- [12] S. Schluessel, B. Mueller, M. Drey, and K. J. Glass, "3D deep learning-based muscle volume quantification from thoracic CT as a surrogate for DXA-derived appendicular muscle mass in older adults", *Aging Clinical and Experimental Research*, Vol. 37, No. 1, pp. 1-11, Oct. 2025. <https://doi.org/10.1007/s40520-025-03206-1>.
- [13] W. H. Hsu, et al., "Explainable machine learning model for predicting skeletal muscle loss during surgery and adjuvant chemotherapy in ovarian cancer", *Journal of Cachexia, Sarcopenia and Muscle*, Vol. 14, No. 5, pp. 2044-2053, Oct. 2023. <https://doi.org/10.1002/jcsm.13282>.
- [14] J. Y. Lim, Y. M. Kim, H. S. Lee, and J. Kang, "Skeletal muscle gauge prediction by a machine learning model in patients with colorectal cancer", *Nutrition*, Vol. 115, No. 1, Art No. 112146, Nov. 2023. <https://doi.org/10.1016/j.nut.2023.112146>.
- [15] D. Olshvang, C. Harris, R. Chellappa, and P. Santhanam, "Predictive modeling of lean body mass, appendicular lean mass, and appendicular skeletal muscle mass using machine learning

techniques: A comprehensive analysis utilizing NHANES data and the Look AHEAD study", PLOS One, Vol. 19, No. 9, pp. 1-18, Sep. 2024. <https://doi.org/10.1371/journal.pone.0309830>.

[16] M. Kim, D. Kim, H. Kang, S. Park, S. Kim, and J. I. Yoo, "A machine learning model for prediction of sarcopenia in patients with Parkinson's Disease", PLOS One, Vol. 19, No. 1, pp. 1-12, Jan. 2024. <https://doi.org/10.1371/journal.pone.0296282>.

[17] M. Seok and W. Kim, "Sarcopenia Prediction for Elderly People Using Machine Learning: A Case Study on Physical Activity", Healthcare, Vol. 11, No. 9, pp. 1-24, May. 2023. <https://doi.org/10.3390/healthcare11091334>.

[18] M. Rezapour, R. B. Seymour, S. H. Sims, M. A. Karunakar, N. Habet, and M. N. Gurcan, "Employing machine learning to enhance fracture recovery insights through gait analysis", Journal of Orthopaedic Research, Vol. 42, No. 8, pp. 1748-1761, Aug. 2024. <https://doi.org/10.1002/jor.25837>.

[19] H. S. Kim, C. H. Chung, and J. W. Lee, "A Novel Sarcopenia Screening Approach Using an Osteoporosis-Inspired T-Score Method", Yonsei Medical Journal, Vol. 66, No. 10, pp. 647-656, Oct. 2025. <https://doi.org/10.3349/ymj.2024.0537>.

[20] N. Li, J. Ou, H. He, J. He, L. Zhang, Z. Peng, J. Zhong, and N. Jiang, "Exploration of a machine learning approach for diagnosing sarcopenia among Chinese community-dwelling older adults using sEMG-based data", Journal of NeuroEngineering and Rehabilitation, Vol. 21, No. 1, pp. 1-13, May 2024. <https://doi.org/10.1186/s12984-024-01369-y>.

[21] T. Chen and C. Guestrin, "XGBoost: A Scalable Tree Boosting System", Proc. of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco California USA, pp. 785-794, Aug. 2016. <https://doi.org/10.1145/2939672.2939785>.

### 저자소개

서재범 (Jae-Bum Seo)



2026년 3월 : 조선대학교  
컴퓨터공학과(학사)  
관심분야 : 머신러닝, 딥러닝  
아키텍처 설계

김민석 (Min-Seok Kim)



2006년 8월 : 전남대학교  
컴퓨터공학과(석사)  
2022년 6월 ~ 현재 : (주)부트캠프  
대표이사  
2025년 2월 ~ 현재 : 동강대학교  
산학협력단 연구교수  
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  
학과 연구교수

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