

Smart Device-Based Deep Learning Model for Sarcopenia Monitoring and Motion prediction

Younguk Yun*, Jung-woo Sohn*

*Assistant Professor, Dept. of Software, Yonsei University, Wonju, Korea

[Abstract]

This study investigates deep learning models for predicting Sarcopenia and motion, such as falls, resulting from Sarcopenia. By leveraging the widespread use of Smartphones, We propose a system that monitors Sarcopenia without the need for additional equipment. A total of 307,584 data points were collected using the built-in 9-axis of IMU sensor of a smartphone, capturing normal walking, abnormal walking, falling, running, and squatting movements. We aims to identify the optimal algorithm through training. To classify Sarcopenia, both binary classification models and multi-class classification models for movement or motion recognition were evaluated. In the binary classification model, the GRU model achieved 100% accuracy, showing the highest performance in both accuracy and speed. For the multi-class classification model, the CNN-GRU combination reached the highest accuracy of 93.72%, and the proposed model demonstrated the fastest training time at 172.16 seconds. This research identifies the optimal combination of deep learning models for motion prediction and detection, and it has potential applications in the fields of digital healthcare and real-time artificial intelligence processing systems.

▶ **Key words:** Sacopenia, Human Activity Recognition, Context Awareness, Deep-Learning, Deep Neural Network, GRU, CNN-CRU

[요 약]

본 연구는 근감소증 판별과 근감소증으로 인한 낙상 등의 동작 감지를 위한 딥러닝 모델 연구를 수행한다. 스마트폰의 높은 보급률을 활용하여 추가 구매 물품 없이 근감소증을 관찰할 수 있는 시스템을 제안하고 가능성을 확인한다. 스마트폰에 내장된 9축 IMU 센서를 활용해 정상 걸음, 비정상 걸음, 낙상, 달리기, 스쿼트 자세에 대한 데이터 총 307,584개를 수집한 후 학습을 통해 최적의 알고리즘을 확인한다. 근감소증 판별을 위해 이진 데이터 분류 모델과 움직임 또는 동작 분류 모델인 다중 분류 모델의 최적 알고리즘을 확인한다. 이진 분류 모델에서 GRU 모델이 정확도가 100%로 정확도와 속도가 가장 높았고 다중 분류 모델의 경우 CNN-GRU를 활용한 경우 93.72%로 가장 높았고 연구에서 제안하는 모델에서 학습 속도 또한 172.16초로 가장 빨랐다. 본 연구를 통해 운동 예측 또는 동작 감지와 같은 딥러닝 모델의 최적 조합을 확인했으며, 디지털 헬스케어 분야와 실시간 인공지능 처리 시스템 연구 등에 활용될 수 있을 것이다.

▶ **주제어:** 근감소증, 동작 인식, 상황인지, 딥러닝, 신경망, GRU, CNN-CRU

- First Author: Younguk Yun, Corresponding Author: Jung-woo Sohn
- *Younguk Yun (yu_yun@yonsei.ac.kr), Dept. of Software, Yonsei University
- *Jung-woo Sohn (jwsohn00@yonsei.ac.kr), Dept. of Software, Yonsei University
- Received: 2024. 10. 11, Revised: 2024. 12. 19, Accepted: 2024. 12. 19.

I. Introduction

최근 디지털 헬스케어에 대한 관심이 높아지고 있다. 이는 병원 중심의 서비스 제공에서 벗어나 일상생활에서 신체 및 건강 데이터를 수집하고 분석하여 개인 맞춤형 건강 관리를 제공하는 것을 목표로 한다. 인공지능(artificial intelligence, AI) 알고리즘의 발전으로 치료 정확도와 개인화가 가속화되고 있으며, 노후에도 지속적인 건강 관리와 진단 및 진료를 받을 수 있는 연구가 빠르게 진행되고 있다.

본 연구에서는 신체의 노화 과정 중에 발생하는 질병인 근감소증(Sarcopenia)을 조기에 진단하고, 이를 모니터링하며, 나아가 동작 예측까지 포함하는 통합적인 스마트 디바이스 기반 시스템 개발과 알고리즘 연구를 수행한다. 근감소증은 2016년 미국, 2018년 일본, 그리고 2021년 한국에서 질병으로 공식 분류되었으며, 고령화 사회로 접어드는 선진국에서는 중요한 사회적 문제로 인식되고 있다[1-4].

특히, 근감소증으로 인한 낙상과 같은 비정상적인 동작은 환자의 삶의 질과 안전에 치명적인 영향을 미칠 수 있다. 이러한 문제를 조기에 감지하고 예측하여 대응할 수 있는 시스템 개발이 필요하다. 보행 속도(Gait Speed, GS)는 '제6의 생체 징후'로 언급된 바 있으며[5], 노화와 질병에서 건강 및 기능적 역량을 평가하는 핵심 지표중에 하나이다 [6]. 근감소증의 진단 기준 중 하나는 근육 기능에 기반을 두고 있으며, 그중 보행속도는 가장 많이 평가되는 특징 중 하나이다[7]. 본 연구는 근감소증 환자의 움직임 패턴을 학습하여 움직임의 속도를 판단하는 알고리즘을 제안한다. 또한 단순히 현재의 상태를 진단하는 것을 넘어, 향후 발생할 수 있는 동작(예: 낙상)이나 비정상적인 움직임을 예측하고 이를 사전에 경고할 수 있는 예측 시스템을 구축하는 것을 목표로 한다. 이러한 동작 예측 기능은 근감소증의 악화를 방지하고, 환자의 안전성을 높이며, 디지털 헬스케어의 실질적인 효과를 극대화하는 데 기여할 수 있다.

본 연구의 목표는 근감소증 환자의 동작 데이터를 스마트폰 내장 관성 센서(inertial measurement unit, IMU)를 활용해 수집하고, 이를 딥러닝 모델에 적용하여 실시간으로 모니터링하고 예측하는 것이다. 기존 연구들은 근감소증 진단에 초점을 맞춘 경우가 많았으나, 본 연구는 모니터링과 동작 예측의 새로운 가능성을 제시한다. 특히, 근감소증 환자의 비정상적인 동작 데이터를 기반으로, 낙상과 같은 위험 동작을 사전에 예측하여 사고를 방지할 수 있는 실시간 시스템을 개발하였다. 이는 환자의 안전을 도모하는 새로운 방향성을 제시한다.

스마트폰의 높은 보급률은 추가 장비 없이 근감소증 환

자를 모니터링하고 예측할 수 있는 연구를 수행한다. 본 연구에서는 내장된 9축 IMU 센서를 활용하여 정상 걸음, 비정상 걸음, 낙상, 달리기, 스쿼트 데이터를 수집하였다. 이 데이터를 기반으로, GRU 및 CNN-GRU와 같은 딥러닝 모델을 설계하고, 이를 통해 비정상적인 동작을 분류하고 동작을 예측하였다. 본 연구는 이러한 기술적 접근을 통해 근감소증 환자 모니터링 시스템의 새로운 가능성을 제시하며, 디지털 헬스케어 및 인공지능 응용 분야에 기여할 수 있을 것이다.

II. Preliminaries

1. Related works

근감소증은 한국에서 2021년 질병으로 분류되었을 만큼 전 세계적으로 인지도가 매우 부족하며 많은 연구도 많이 이루어지지 않은 상태이다. 이에 인공지능을 활용한 운동량 또는 운동 인지(human activity recognition, HAR), 상황인지(context awareness) 등의 연구 중에서 관성센서를 활용하는 연구를 조사한다. 기존 연구에서는 Baumgartner의 New Mexico Elder Health Survey를 시작으로, 아시아 근감소증 진단그룹(AWGS)이 아시아인을 위한 진단 기준을 제시하였으며, 연구에 따르면 근감소증이 발생한 고령자의 보행속도는 0.6m/s 이하로 감소하는 특징이 있다[5-9]. 관성 센서를 활용한 기존 연구에서는 걸음 수와 보폭 거리를 활용해 속도를 계산하지만, 관성센서의 고유 진동으로 정확히 측정이 어렵고, 민감도에 따라 결과가 달라질 수 있다[10-13]. IMU를 사용해 사람의 걸음걸이를 정확도 약 92%[12], IMU 센서를 골반과 양쪽 다리에 3개를 부착한 후 다양한 모델을 사용해 가장 높은 정확도를 보인 알고리즘은 91%[13]였다. 본 논문에서는 추가 비용 없이 스마트폰에 있는 센서를 사용해 걸음걸이를 추정하는 알고리즘을 제안하고 있으며 정확도는 LSTM, GRU 모델을 사용해 90% 이상의 정확도를 보인다.

동작 인식은 사용하는 센서에 따라 크게는 두 가지로 환경 센서와 내장 센서 기반의 알고리즘으로 나누어 볼 수 있다. 관성 센서를 HAR 연구는 웨어러블 디바이스(스마트워치, 밴드 등)와 환경 센서를 활용하여 인간 활동을 분류하거나 예측하는 데 초점이 맞춰져 왔다 [10-11]. 관성 센서를 활용한 동작 인식 연구는 최근 다양한 분야에서 이루어지고 있다. 웨어러블 디바이스(예: 스마트워치)를 활용해 동작을 인식하는 연구도 있으나 추가 장비가 필요해 일반 사용자 접근성이 제한적이고[10-13] 스마트폰 기반의

IMU 데이터를 활용한 LSTM 모델을 통해 동작을 분석하였으나, 근감소증을 대상으로 한 연구는 사례를 찾아보기 어렵고 데이터 규모가 제한적이다[14].

기존 연구들이 일반적인 동작 인식에 초점을 맞춘 반면, 본 연구는 근감소증이라는 특수 질환에 초점을 맞추고 있다. 특히, 스마트폰과 같은 휴대용 디바이스에 내장된 IMU 센서를 활용하여 근감소증 환자의 움직임 데이터를 수집했다. 연구를 통해 총 307,584개의 데이터를 확보했고 근감소증과 주요 동작 특성(정상 걸음, 비정상 걸음, 낙상, 달리기, 스쿼트)을 구분할 수 있도록 설계되었다.

동작 인식을 판별하는 데 활용되는 알고리즘으로 머신러닝(machine learning, ML) 딥러닝(deep learning, DL)이 대표적이다. ML과 관련된 대표적인 알고리즘으로 Naive Bayes, k-Means clustering, Support Vector Machine(SVM), Linear Regression, k-Nearest Neighbours(k-NN), Hierarchical clustering이 있다. DL은 긴 시퀀스 데이터를 처리할 때 자주 사용되는 Long Short-Term Memory(LSTM), 이미지 처리 시 많이 활용되는 Convolutional Neural Network(CNN), 최근 많이 사용되는 GPT나 Bert와 같이 자연어 처리에 많이 활용되는 Recurrent Neural Network(RNN), LSTM의 단순화된 구조로 빠르게 학습이 되면서도 LSTM과 유사한 성능을 보이는 Gated Recurrent Unit(GRU) 등의 DL 모델이 있다. 최근에는 이를 기반으로 하는 다양한 학습 모델이 연구되고 있다. 모델 학습 시 높은 컴퓨팅 비용(computation cost)이 요구되며 많은 양의 데이터가 필요하다는 등 단점이 있지만 높은 학습 성능을 갖는 장점이 있다. 최근에는 컴퓨팅 환경이 좋아지면서 딥러닝(deep learning, DL) 활용한 사례가 많다[15-19].

본 연구에서는 딥러닝을 활용하여 스마트 디바이스 환경에서 근감소증을 진단하는 연구를 수행한다. 낮은 컴퓨팅 비용에서 유리한 시계열(time-series) 분석을 수행하고, 이를 바탕으로 딥러닝 알고리즘을 적용하여 근감소증 진단의 정확도를 분석하는 것에 목적이 있다 Fig. 1.




Fig. 1. System Description

III. The Proposed Scheme

이러한 대규모 데이터와 스마트폰의 보편성을 활용한 접근 방식은 추가 장비 없이 누구나 활용 가능한 실용적인 본 논문에서는 시스템 구현 가능성을 제시하고 단일 모델(GRU, LSTM)뿐만 아니라 복합 모델(CNN-GRU)을 통해 높은 정확도와 학습 속도를 검증하여 근감소증 진단 및 동작 예측 시스템의 실현 가능성을 보여준다.

1.1 Application Development

스마트 디바이스에 내장된 다양한 센서를 활용하여 데이터를 수집하고 분석하기 위한 테스트용 애플리케이션을 구현하였다. 이 애플리케이션은 Android OS 기반의 시스템이며 전용 통합 개발환경(integrated development environment, IDE)을 통해 개발되었다. API 버전은 12이며 데이터 수집과 연구에 사용된 스마트 디바이스는 삼성전자(Samsung Electronics)의 Galaxy Note 10 스마트폰이다.

개발된 애플리케이션은 사용자가 실험에 대한 정보를 입력할 수 있는 시작 화면과 실험을 진행하고 중지할 수 있는 기능, 그리고 main 화면으로 복귀할 수 있는 기능을 제공한다. 입력하는 정보 중에 학습을 위한 라벨(label) 정보도 입력할 수 있도록 개발되었다 Fig. 2.

데이터 수집을 위해 SQLite(Structured Query Language) 데이터베이스를 이용하여 데이터를 저장했다. 이 데이터베이스는 경량화된 관계형 데이터베이스로, 스마트 디바이스에서 사용하기에 적합하다[20]. 저장된 데이터는 학습에 필요한 9개의 데이터 필드와 라벨 외에도 측정 현황을 파악하기 위한 정보를 포함한다.

수집된 데이터 중 가속도 센서(accelerometer) 데이터는 센서가 얼마나 빠르게 움직이고 있는지를 나타내는 값으로, x, y, z 세 개의 축에 대한 데이터를 수집한다. 데이터 표에서 accelX, accelY, accelZ 값을 의미한다. 자이로 센서(gyroscope) 데이터는 센서의 회전과 방향 등의 영향을 받는 값으로, 마찬가지로 x, y, z 세 개의 축에 대한 데이터를 수집한다. 지자기 센서(magnetometer) 데이터는 자기장의 세기와 방향을 측정하는 값으로, 마찬가지로 x, y, z 세 개의 축에 대한 데이터를 수집한다. 총 9개의 축 데이터를 활용하기에 9축 센서로 표현되기도 한다. 데이터 필드명은 accelX와 같이 센서 앞 글자와 축 정보를 활용해 데이터를 저장한다. 9축 센서의 모든 데이터 중에서 운동량과 관련 있는 가속도, 자이로 센서의 정보만 인공지능 학습모델에 활용된다.



Fig. 2. Developed Application

근감소증 환자는 보폭 불균형, 느린 속도, 비틀림 증가 등의 특성을 보인다. 이는 정상 걸음과 명확히 구분되는 물리적 신호로 동작 인식이 가능하다. 정상 걸음의 경우 가속도의 변화량이 규칙적이며 반복적인 패턴을 나타낸다. 반면, 비정상 걸음에서는 가속도 값의 변화가 불규칙하고 흔들림의 빈도가 높을 수 있다. 또한 정상 걸음에서는 회전(Gyro sensor) 데이터가 안정적이며 좌우 대칭성이 유지된다. 그러나 비정상 걸음은 회전 값의 불균형이 뚜렷하게 나타나며, 비틀림이 증가할 수 있다는 점을 기반으로 연구가 진행된다.

1.2 Prediction Algorithm

본 연구에서는 딥러닝(Deep-neural network) 학습 중 대표적인 모델 몇 개를 활용하여 정확도를 분석하는 연구를 수행한다. 본 연구에서 활용된 딥러닝 학습 모델은 LSTM, CNN, RNN, GRU이다[14-19]. 이 세 개의 모델은 딥러닝 학습모델에서 대표성을 갖는 모델로 많이 알려져 있다. 먼저 LSTM은 시계열 데이터 예측에 강점을 보이는 모델로, 과거의 데이터를 기반으로 미래의 데이터를 예측하는 데 사용된다. LSTM은 순환 신경망(Recurrent Neural Network)의 일종으로, 입력 데이터의 시퀀스를 처리하는 데 적합하다. LSTM은 장기 기억(long-term memory)을 유지할 수 있어, 시계열 데이터의 예측에 효과적인 모델이다. CNN은 이미지, 영상 분야에서 특징을 추출하여 예측하는 데 강점을 보이는 모델로, 이미지나 영상을 입력으로 받아 특징을 추출하고 이를 기반으로 예측을 수행한다. CNN은 이미지의 패턴을 인식하여 분류하는 데 효과적이며, 이미지 처리 분야에서 널리 사용된다. RNN은 순환구조를 이루는 인공 신경망의 한 종류로, 자연어 처리 분야에서 강점을 보이는 모델이다. RNN은 입력 데이터의 시퀀스를 처리하는 데 적합하며, 자연어 처리, 음성 인식, 시계열 데이터 예측 등 다양한 분야에서 활용된다. 본 연구에는 위에 언급한 학습 모델 외에도 최근 HAR 연구에서 높은 정확도로 많이 사용되는 융합 모델인

CNN-LSTM 알고리즘도 활용하여 정확도 분석을 수행한다. CNN-LSTM 융합모델은 CNN과 LSTM의 장점을 결합한 모델로 이미지 처리에 많이 활용되는 CNN을 거쳐 시계열 데이터인 LSTM을 통해 예측 능력을 향상시키는 알고리즘이다. 결합 모델은 높은 정확도를 보이지만 학습 속도가 느리다는 단점이 존재한다. 본 연구에서는 2014년에 얀 르쿤(Yann LeCun) 교수와 조경현 교수 등이 처음으로 소개한 Gated Recurrent Unit(GRU) 모델을 활용하여 정확도 분석을 수행한다. GRU는 한국인인 뉴욕 대학교 조경현 교수가 제안한 순환 신경망이다. LSTM과 달리 출력 게이트가 없는 간단한 구조를 사용하고 있다. LSTM의 복잡한 구조를 간소화했기에 연산 속도가 높다. GRU는 입력 게이트(input gate), 망각 게이트(forget gate), 출력 게이트(output gate)를 사용하여 hidden state를 업데이트한다. 입력 게이트는 현재 입력과 이전 hidden state를 결합하여 새로운 hidden state를 생성하고 망각 게이트는 이전 hidden state의 일부를 망각하여 hidden state를 업데이트한다. 출력 게이트는 hidden state를 출력한다. GRU는 LSTM과 유사한 성능을 보이면서도 구조가 간단하여 딥러닝 모델의 학습 속도와 성능을 높이는 곳에 많이 사용된다 [21-23]. 위에서 제안한 LSTM, CNN, RNN을 활용한 정확도와 융합모델인 CNN-LSTM, CNN-GRU, CNN-RNN 모델을 활용한 정확 분석도 수행한다. 본 논문에서 사용된 모델의 세부 모델의 환경 변수 등은 2.3절에서 다룬다.

2.1 Experiment and Data Collection

Fig. 3. 과같이 본 연구에서는 제안 기법의 연구를 위한 데이터 수집용 애플리케이션을 활용하여 데이터 수집 실험을 진행하였다. 이 실험은 환경적인 요인을 최소화하기 위해 경사가 없는 평지에서 수행되었으며, 실험자마다 편차를 최대한 줄이고 움직임의 중심 위치로서 걷기, 낙상, 스쿼트 등 다양한 동작 데이터를 가장 신뢰성 있게 반영할 수 있기 때문에 허리 위치에 밴드를 활용하여 고정하여 데이터를 수집하였다. 데이터는 50Hz의 속도로 수집되었으며, 총 54,848개의 데이터가 수집되었다. 이는 센서 9개 축의 정보를 갖고 있으므로 54,848의 2차원 데이터를 의미한다. 움직임별로 데이터를 수집할 때 개발용 폰에서 정보입력 부분에 label 정보를 입력해 수집했으며, 총 5개의 분류로 데이터를 수집했으며 정상 걸음(normal gait), 비정상 걸음(abnormal gait), 달리기(run), 낙상(falling), 스쿼트(squat) 데이터를 수집하였다. 낙상과 스쿼트를 제외한 이동거리가 있는 데이터는 모두 동일하게 50m 이동

및 왕복 운동을 수행했다. 또한, 낙상 동작은 사람이 넘어 질 때의 움직임을 기록하였으며, 스쿼트 동작은 앉았다가 일어서는 운동 시의 데이터를 수집하였다. 이 과정에서 동작 학습을 위한 데이터 수집 시 달리기나 낙상 실험에서 속도나 자세에 대한 제한을 두지 않았다. 예를 들어, 달리기 데이터를 수집할 때 팔의 위치, 달릴 때의 자세, 또는 달리기 속도 등을 특정하지 않고, 실험자에게 단지 레이블 주지만 제공한 후 실험을 진행하였다. 예외적인 상황에서는 오히려 모델의 판단 정확도가 떨어질 가능성이 있을 수 있기에 자세나 속도의 제한을 두지 않았다. 이는 실제 상황을 고려한 실험이며 정해진 자세보다는 다양한 형태의 데이터를 수집하는 것이 실제 서비스 구현 시 더 큰 유효성을 제공할 수 있을 것이다.

실험에는 성인 남성 3명, 성인 여성 3명, 총 6명이 참여하였다. 각 실험자는 다섯 가지 동작을 수행했다. 연구를 위해 환자의 데이터를 수집해 근감소증 데이터로 활용하는 것이 가장 이상적이거나 피실험자의 걸음걸이가 정상일 때와 근감소증이 일어난 후의 데이터를 모두 분석해야 한다는 조건에 어려움이 있었고 환자를 섭외하는 과정에서 전문 기관과의 협력의 어려움과 개인정보 보호에 대한 문제가 있었다. 이에 근감소증 환자의 움직임을 모사하기 위해 느리게 걷기, 절뚝거리며 걷기, 지그재그 패턴 걷기 등 비정상적인 걸음 패턴을 다각적으로 포함하여 데이터를 수집했다. 모사된 데이터는 기존 연구에서 정의된 근감소증 환자의 보행 특성과 유사하게 설계되었으며, 이러한 실험 설계는 초기 연구 단계에서 충분히 신뢰성 있는 데이터로 활용이 가능하다[8]. 통계적으로 다양한 연령층과 성별, 실제 근감소증 환자의 데이터를 활용하여 연구를 수행하는 것은 향후 연구로 남겨둔다.

실험 데이터에서 근감소증을 판별하기 위해 활용된 데이터는 '정상 걸음'과 '비정상 걸음'이다. 정상 걸음은 실험자가 걷는 보통의 걸음을 의미합니다. 비정상 걸음은 근감소증의 환자를 모방하여 데이터 수집 실험을 수행했다.




Fig. 3. Experimental Environment

근감소증 환자는 거동이 불편하고 걸음이 느리진다는 점에 착안하여 이를 모방하여 느리게 걷기, 절뚝거리며 걷기, 터덜터덜 걷기, 지그재그(zigzag) 패턴으로 걷기, 비틀거리며 걷기 등 비정상적인 걸음으로 이동하면서 데이터를 수집했다. 여기에서 지그재그 걸음은 좌우 약 2m 내 이동 제한을 두었다. 위에서 언급한 비정상 걸음은 근감소증환자를 고려한 비정상적인 걸음 실험이기에 비정상 걸음 간의 특징점을 구분할만한 뚜렷한 실험은 아니기에 '비정상 걸음'이라는 하나의 분류로만 데이터를 수집하였고 활용했다.

HAR 연구를 위해 사용된 데이터는 정상 걸음과 비정상 걸음에 달리기, 낙상, 스쿼트를 추가한 5가지 데이터이다.

따라서 알고리즘 분석 연구는 정상 걸음과 비정상 걸음을 나누는 이진 분류(Binary Classification)와 여러 운동을 분류할 수 있는 다중 분류(Multi Classification) 학습 모델 연구로 나뉜다.

2.2 Algorithm Performance Evaluation

딥러닝 학습을 위한 하드웨어 세부 성능은 CPU: AMD RYGEN5 4650G, RAM:32G, GPU: NVIDIA RTX 4060, 이며 소프트웨어 버전은 Tensorflow2.14.0, CUDA 11.8, cuDNN 8.6, Python 3.8이다. 각 실험에서 수집된 약 54,000개의 데이터는 Fig. 4. 와 같이 가속도 센서와 자이로 센서의 총 6개 축에 대한 데이터이며 시계열 데이터에서 특징점(feature)을 더욱 부각하기 위해 이미지를 만드는 것과 같이 2차원 데이터로 전처리를 수행했다. 원본 데이터(raw data)는 50Hz로 수집이 되었고 약 2.5초에 해당하는 데이터를 1개 프레임(frame)으로 처리했다. 다음 프레임은 이전 프레임 데이터 중에서 뒤에 데이터에 대하여 50% 겹쳐서 프레임 처리를 진행했다. 이는 Sliding window[24] 알고리즘을 사용하여 특징점을 더 잘 찾는 것을 목표로 한다. Fig.5은 sine wave sliding window를 사용하여 프레임을 구분한 그림이다. 본 연구에도 Fig.5 와 같이 데이터 프레임을 나눠 구했다. 또한 Fig. 6.는 이렇게 나눈 그래프를 시각화 한 예이다. 이렇게 1차원 데이터를 2차원으로 전처리하면 CNN과 같은 이미지 학습모델에도 활용 가능하다. Fig. 6.은 정상 걸음과 비정상 걸음에 대한 데이터를 2차원으로 보여주고 있다. 그림에서 정상 걸음의 경우 가속도 센서 X축의 peak 값이 700이 넘는 경우는 15회 이상이고 비정상인 경우는 1회로 나타난다. 이처럼 특징점을 더 잘 찾아 AI 학습 모델 정확도를 높일 수 있을 것이다. Fig. 7. 은 CNN-LSTM 융합 모델에 대한 그림이다. 와 같이 출력되는 값을 다시 모델의 입력 값으로 넣어 융합 모델을 구현할 수 있다.

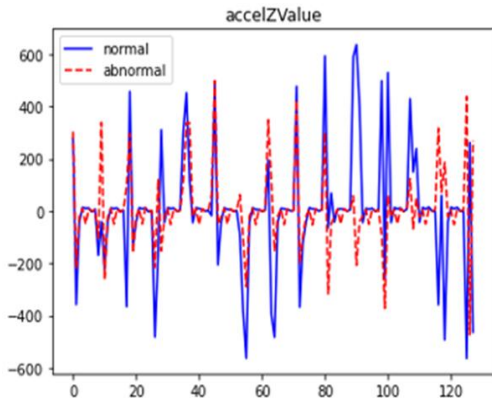


Fig. 4. Collected Accelerometer Data

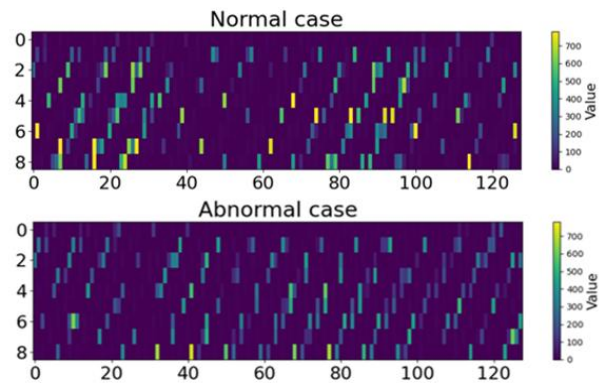


Fig. 6. Sliding Window data for Normal and Abnormal Gait




Fig. 5. Sliding Window




Fig. 7. CNN-LSTM algorithm

Tensorflow의 parameter(param)는 연구 동향을 파악하여 일반적으로 많이 사용되는 입력값을 선택했으며 모두 같게 부여되었다. 사용된 param은 다음과 같다. 모든 알고리즘에서 같게 사용된 param은 epoch(반복): 100, batch size: 64, Dropout: 0.5, dense: 100, activation function: ReLu와 Softmax, optimizer: Adam, learning rate: 0.1 이며 CNN에서 batch size(step): 4, filter size(length), 64이다. RNN에서는 batch size: 100, time step: 4, features:9 이다.

실험 결과는 Table.1. Table. 2. 와 Fig. 8 Fig. 9과 같다. 여기에서 파란색('x' 마크)는 학습정확도, 초록색(마름모)는 테스트 데이터 정확도, 황색(실선)은 학습 손실, 빨간색(동그라미)는 테스트 데이터 손실을 의미한다. 예측한 값과 실제 값 간의 차이를 측정하는 지표를 손실(Loss)이라고 하고 테스트 데이터의 지표가 더 중요하다고 볼 수 있다. Table. 1.과 2. 에서 테스트 데이터의 정확도와 손실 값이다. 손실 값의 단위는 없다. 본 연구에서 제공된 그래프는 단순히 정확도와 손실을 시각적으로 표현하는 데 그치지 않고, 학습 속도와 모델의 수렴도를 분석하여 Edge 디바이스에서의 실시간 활용 가능성을 평가하기 위한 데이터로 활용될 수 있다.

정상 걸음과 비정상 걸음을 구분하는 이진 분류의 결과

GRU 모델을 단독으로 사용하는 경우 정확도가 1(100%)로 가장 높은 것으로 보인다. 또한, 모델의 학습 속도 또한 7.12초로 가장 빨리 이뤄지는 것을 알 수 있다. 두 번째로 높은 성능을 보여준 LSTM과 비슷한 유사한 정확도, 속도를 갖고 있으나 약 50번의 반복 수행 만에 정확도가 1에 수렴하고 있는 것을 볼 수 있다. CNN 기반의 융합모델을 사용하는 경우 예상과 다르게 정확도 비교적 낮게 추정되는 것을 볼 수 있는데 과적합으로 인한 손실이 높았던 것으로 판단된다. 정상 걸음, 비정상 걸음, 달리기, 낙상, 스킵트 구분 결과는 CNN 단독 학습모델은 성능 저하가 뚜렷하여 실험에서 배제되었다. LSTM의 경우 정확도는 90% 이상이지만 학습 속도는 정확도가 가장 높은 GRU 모델에 비해 속도는 약 3배 차이가 나는 것을 알 수 있다. 다중 모델의 경우 CNN 기반의 학습 모델이 단독 모델보다 정확도나 속도 측면에서 우세함을 보였고 이진 분류와 같이 GRU를 사용한 모델에서 비교적 높은 지표를 얻었다. 지표로는 단독으로 사용한 모델이 CNN-GRU 모델보다 좋은 것으로 나왔으나 평균적으로 볼 때 안정적으로 학습이 되는 것을 확인할 수 있다. GRU는 LSTM 대비 구조가 단순하여 학습 속도가 빠르고, 시계열 데이터를 효율적으로 처리하는 데 강점을 보이는데 실험 결과를 통해 이러한 특징을 확인할 수 있었고 복합 모델에서는 CNN-GRU가 비

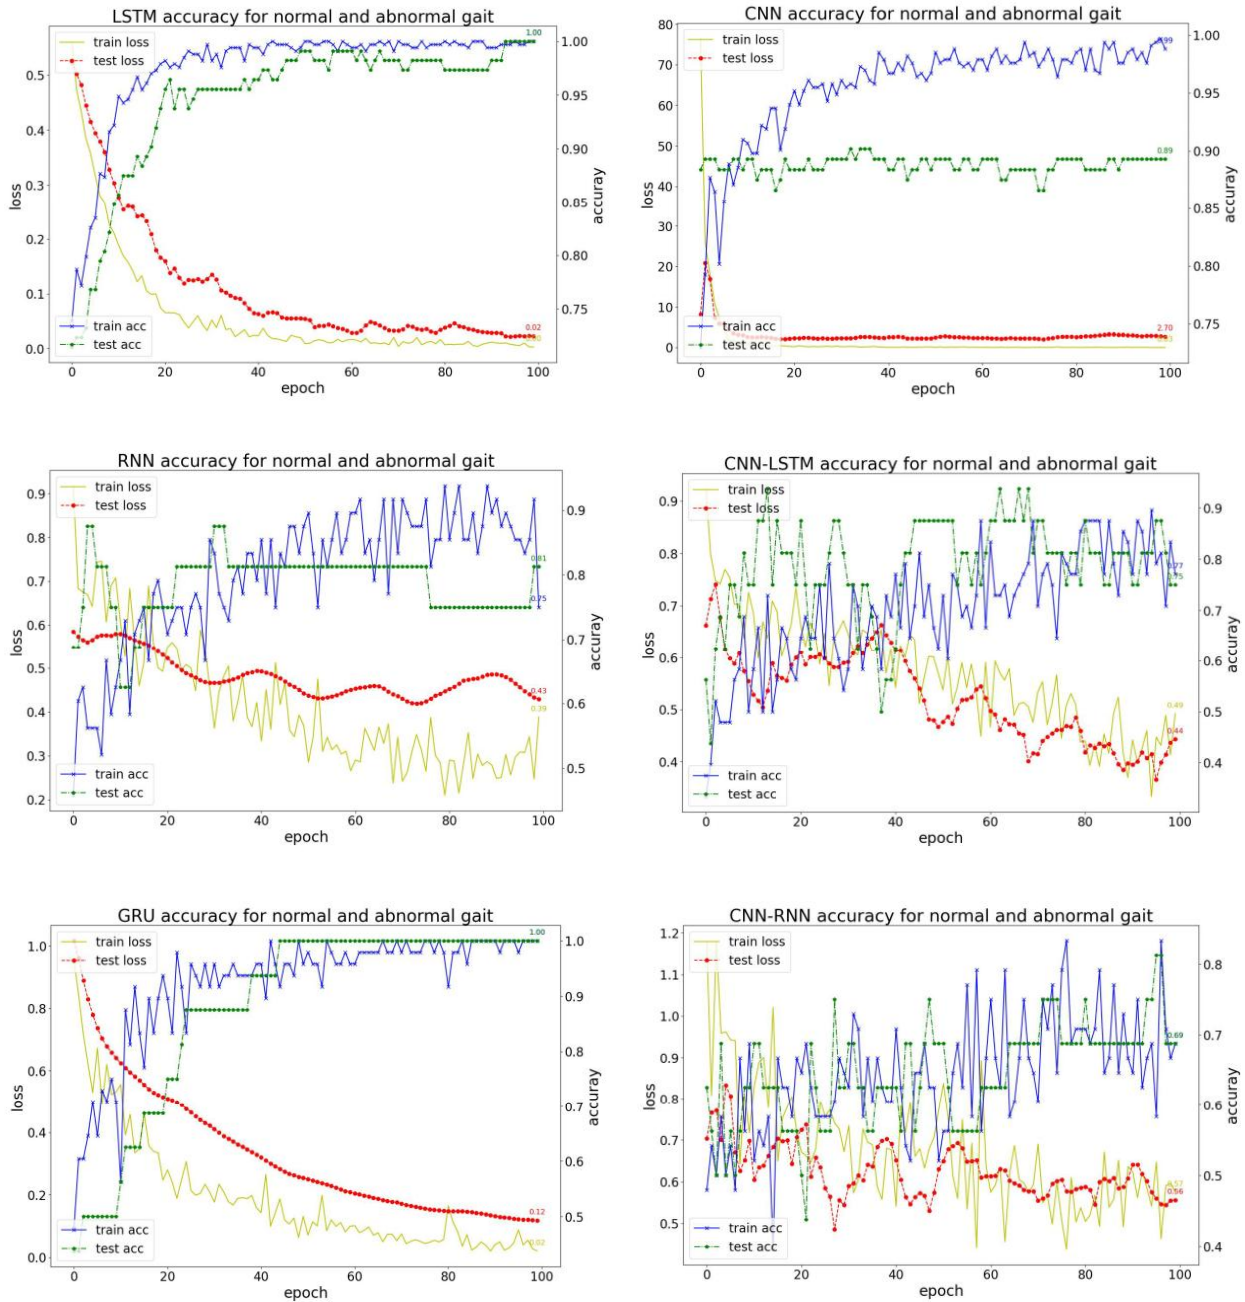


Fig. 8 Learning Accuracy for Normal and Abnormal Gait
 (Top Left: LSTM, Top Right: CNN, Middle Left: RNN, Middle Right: CNN-LSTM, Bottom Left: GRU, Bottom Right: CNN-RNN)

교적 좋은 성능을 보였는데 데이터의 시각적 패턴을 분석하고, 이를 통해 주요 특징을 추출하는 모델인 CNN과 GRU의 특징인 과거 시점의 정보를 망각 게이트와 업데이트 게이트를 통해 최적화함으로써 불필요한 정보 누적을 방지하고 학습 효율을 높였다고 볼 수 있다. 이를 통해 학습 속도와 정확도 모두에서 복합 모델이 단순 모델보다 우수한 결과를 보였다. 아울러 단순 모델인 GRU 단독 모델도 복합 모델과 같이 좋은 성능을 보였는데 본 연구를 통

해 수집된 데이터는 CNN으로 처리하기 전에 Fig. 6.과 같이 이미 간단하고 잘 정의된 특징을 가진 것으로 보였고 CNN의 추가적인 특징 추출 과정이 오히려 불필요한 계산과 모델 복잡성을 초래된 것으로 보인다.

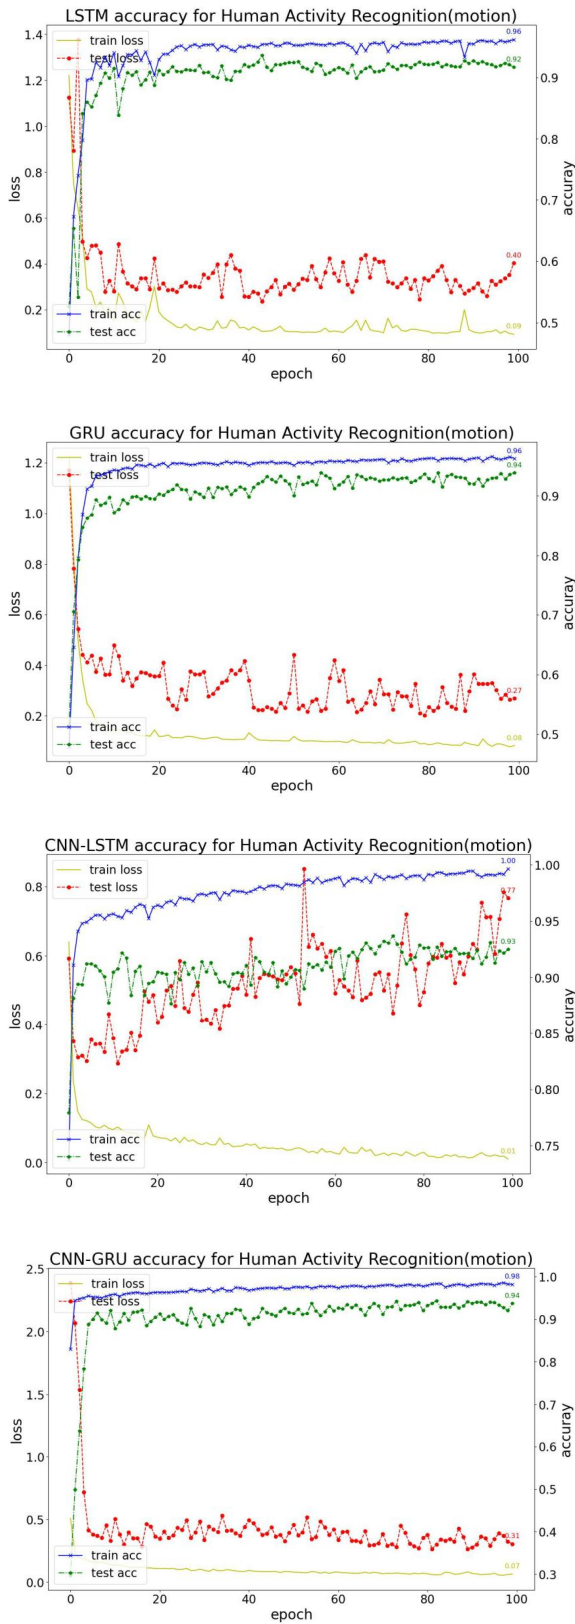


Fig. 9. Learning Accuracy for Human Activity Recognition

Table 1. Accuracy and Learning time comparison by Deep-learning model for gait

Deep Learning Model	Accuracy(%)	Loss	Learning time (second)
LSTM	93.75	0.1425	8.19
RNN	81.25	0.4287	16.03
CNN	89.29	2.7021	10.57
GRU	100.00	0.1181	7.12
CNN-LSTM	75.00	0.4432	8.15
CNN-RNN	68.75	0.5564	6.25
CNN-GRU	87.50	0.4322	6.71

Table 2. Accuracy and Learning time comparison by Deep-learning model for HAR(motion)

Deep Learning Model	Accuracy(%)	Loss	Learning time (second)
LSTM	92.75	0.4026	467.51
RNN	67.63	1.0599	1237.16
GRU	93.82	0.2691	178.45
CNN-LSTM	92.50	0.7669	191.66
CNN-RNN	90.05	0.6797	141.86
CNN-GRU	93.72	0.3054	172.16

IV. Conclusions

본 연구는 스마트 디바이스에 내장된 센서를 활용하여 사람의 동작과 운동을 감지하거나 예측할 수 있는 시스템 알고리즘을 연구하였다. GRU와 CNN-GRU 모델이 이진 분류 및 다중 분류에서 높은 정확도를 보임을 확인하였고 이진 분류에서는 GRU 모델이 100%의 정확도를 보였으며, 다중 분류에서는 CNN-GRU가 93.72%의 정확도를 기록하였다. 특히, 동작 분류에 사용되는 다양한 딥러닝 모델의 정확도와 학습 속도를 비교 분석하였다. CNN-LSTM, CNN-GRU 모델 조합을 통해 높은 정확도를 달성했으며 이진 분류의 경우 복잡한 모델은 오히려 성능이 감소하는 것을 확인했다. GRU 모델은 LSTM에 비해 구조가 단순하며, 학습 속도에 영향을 미치는 param 수가 적어 학습 속도가 더 빠른 것으로 분석되었다. 본 연구에서 제공된 그래프는 단순히 정확도와 손실을 시각적으로 표현하는 데 그치지 않고, 학습 속도와 모델의 수렴도를 분석하여 Edge 디바이스에서의 실시간 활용 가능성을 평가하기 위한 중요한 자료로 활용될 수 있으며 GRU와 CNN-GRU 모델은 각각의 구조적 특성 덕분에 제한된 하드웨어 환경에서도 효율적으로 작동할 수 있다. GRU는 단순 구조로 인해 계산 복잡도가 낮으며, CNN-GRU는 복합 모델임에도 안정적인 학습 속도를 유지하며 높은 정확도를 달성하였다. 이를 통해

Edge 디바이스에서의 실시간 동작 인식 및 근감소증 모니터링 시스템으로 확장 가능성을 보였다. 본 연구는 단순 모델과 복합 모델을 통해 성능 개선이 가능함을 보였다. 향후 다양한 모델 param을 조정하여 성능 및 속도를 개선할 수 있을 것으로 기대한다. 또한, 다양한 위치(손, 주머니, 가방 등)에서 데이터를 수집하고 비교 분석하여 모델의 일반화 가능성을 높일 수 있다.

본 연구는 디지털헬스케어 분야뿐 아니라 데이터의 실시간 처리가 중요한 다양한 인공지능 연구 분야에도 적용될 수 있을 것이다.

ACKNOWLEDGEMENT

"This research was supported by the MIST(Ministry of Science, ICT), Korea, under the National Program for Excellence in SW), supervised by the IITP(Institute of Information & communications Technology Planing & Evaluation) in 2023"(2019-0-01219)

REFERENCES

- [1] Evans, W.J. "What is sarcopenia?" *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, Vol. 50, pp. 5-8, 1995. DOI: https://doi.org/10.1093/gerona/50A.Special_Issue.5
- [2] Marty, E., Liu, Y., Samuel, A., Or, O., Lane, J. "A review of sarcopenia: Enhancing awareness of an increasingly prevalent disease." *Journal of Brain Bone*, Vol. 105, pp. 276-286, 2017. DOI: <https://doi.org/10.1016/j.bone.2017.09.008>
- [3] Yuki, A., Ando, F., Otsuka, R., Shimokata, H. "Sarcopenia based on the Asian Working Group for Sarcopenia criteria and all-cause mortality risk in older Japanese adults." *Geriatrics & Gerontology International*, Vol. 17, No. 10, pp. 1642-1647, 2017. DOI: <https://doi.org/10.1111/ggi.13187>
- [4] Kim, M., Kim, H., Park, S., Cho, I., Yu, W. "A study on the analysis of physical function in adults with sarcopenia." *Journal of The Korean Society of Integrative Medicine*, Vol. 8, No. 2, pp. 199-209, 2020. DOI: <https://doi.org/10.15268/ksim.2020.8.2.199>
- [5] Fritz, S., Lusardi, M. "Walking speed: the sixth vital sign." *Journal of Geriatric Physical Therapy*, Vol. 32, pp. 2-5, 2009. DOI: <http://dx.doi.org/10.1519/00139143-200932020-00002>
- [6] Cruz-Jimenez, M. "Normal changes in gait and mobility problems in the elderly." *Physical Medicine and Rehabilitation Clinics of North America*, Vol. 28, pp. 713-725, 2017. DOI: <https://doi.org/10.1016/j.pmr.2017.06.005>
- [7] Cruz-Jentoft, A.J., Bahat, G., Bauer, J., Boirie, Y., Bruyère, O., Cederholm, T., et al. "Sarcopenia: revised European consensus on definition and diagnosis." *Age and Ageing*, Vol. 48, pp. 16-31, 2019. DOI: <https://doi.org/10.1093/ageing/afz046>
- [8] Sanchez-Rodriguez, D., Marco, E., Miralles, R., Guillen-Sola, A., Vazquez-Ibar, O., Escalada, F., Muniesa, J.M. "Does gait speed contribute to sarcopenia case-finding in a postacute rehabilitation setting?" *Archives of Gerontology and Geriatrics*, Vol. 61, No. 2, pp. 176-181, 2015. DOI: <https://doi.org/10.1016/j.archger.2015.06.015>
- [9] Perez-Lasierra, Jose Luis, et al. "Sarcopenia screening based on the assessment of gait with inertial measurement units: a systematic review." *BMC geriatrics* Vol. 24, No. 1 p863, 2024. DOI: <https://doi.org/10.1186/s12877-024-05475-3>
- [10] Lee, J., Park, K.E., Kim, Y. "A study on indoor positioning based on pedestrian dead reckoning using inertial measurement unit." *Journal of the Society of Disaster Information*, Vol. 17, No. 3, pp. 521-534, 2021. DOI: <https://doi.org/10.15683/kosdi.2021.9.30.521>
- [11] Liu, Y., Nie, L., Liu, L., Rosenblum, D.S. "From action to activity: Sensor-based activity recognition." *Neurocomputing*, Vol. 181, pp. 108-115, 2016. DOI: <https://doi.org/10.1016/j.neucom.2015.06.118>
- [12] Alharthi, A. S., Yunas, S. U., Ozanyan, K. B. "Deep learning for monitoring of human gait: A review." *IEEE Sensors Journal*, Vol. 19, No. 21, pp. 9575-9591, 2019. DOI: <https://doi.org/10.1109/jsen.2019.2928777>
- [13] Arshad, M. Z., Awais, M., Khan, H. U., Akram, U., Hussain, A., Majid, M. "Gait-based frailty assessment using image representation of IMU signals and deep CNN." *2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*, IEEE, pp. 1-4, 2021. DOI: <https://doi.org/10.1109/embc46164.2021.9630976>
- [14] Stisen, A., Blunck, H., Bhattacharya, S., Prentow, T.S., Kjærgaard, M.B., Dey, A., Sonne, T., Jensen, M.M. "Smart devices are different: Assessing and mitigating mobile sensing heterogeneities for activity recognition." *Proceedings of the 13th ACM Conference on Embedded Networked Sensor Systems*, Seoul, South Korea, pp. 127-140, 2015. DOI: <https://doi.org/10.1145/2809695.2809707>
- [15] Kanjo, E., Younis, E.M.G., Ang, C.S. "Deep learning analysis of mobile physiological, environmental and location sensor data for emotion detection." *Information Fusion*, Vol. 49, pp. 46-56, 2019. DOI: <https://doi.org/10.1016/j.inffus.2018.09.001>
- [16] Bishop, C.M. "Pattern Recognition and Machine Learning", Springer, pp. 100-120, 2006.
- [17] Liu, Y., Nie, L., Liu, L., Rosenblum, D.S. "From action to activity:


- Sensor-based activity recognition." *Neurocomputing*, Vol. 181, pp. 108-115, 2016. DOI: <https://doi.org/10.1016/j.neucom.2014.06.091>
- [18] Abdallah, Z.S., Gaber, M.M., Srinivasan, B., Krishnaswamy, S. "Adaptive mobile activity recognition system with evolving data streams." *Neurocomputing*, Vol. 150, pp. 304-317, 2015. DOI: <https://doi.org/10.1109/JBHI.2018.2809383>
- [19] Shickel, B., Tighe, P.J., Bihorac, A., Rashidi, P. "Deep EHR: A survey of recent advances in deep learning techniques for electronic health record (EHR) analysis." *IEEE Journal of Biomedical and Health Informatics*, Vol. 22, No. 5, pp.1589-1604, 2018. DOI: <https://doi.org/10.14778/2824032.2824046>
- [20] OH, Gihwan, et al. "SQLite optimization with phase change memory for mobile applications," *Proceedings of the VLDB Endowment*, Vol. 8, No. 12 pp. 1454-1465, 2015. DOI: <https://doi.org/10.48550/arXiv.2305.17473>
- [21] Shiri, Farhad Morteza pour, et al. "A comprehensive overview and comparative analysis on deep learning models: CNN, RNN, LSTM, GRU." *arXiv preprint arXiv:2305.17473* (2023). DOI: <https://doi.org/10.7717/peerj-cs.1052>
- [22] Siraj, Md Sadman, Ahad, M. A. R. "A hybrid deep learning framework using CNN and GRU-based RNN for recognition of pairwise similar activities." *2020 Joint 9th International Conference on Informatics, Electronics & Vision (ICIEV) and 2020 4th International Conference on Imaging, Vision & Pattern Recognition (icIVPR)*, IEEE, pp. 1-6, 2020. DOI: <https://doi.org/10.1109/icievicivpr48672.2020.9306630>
- [23] Dua, N., Kumar, S., Kumar, R., Gupta, A., Kaur, R., "Inception-inspired CNN-GRU hybrid network for human activity recognition." *Multimedia Tools and Applications*, Vol. 82, No. 4, pp. 5369-5403, 2023. DOI: <https://doi.org/10.1007/s11042-021-11885-x>
- [24] Jaén-Vargas, M., Morantes, G., Suarez, C., Rodriguez, N. D., & Labrador, M. "Effects of sliding window variation in the performance of acceleration-based human activity recognition using deep learning models." *PeerJ Computer Science*, Vol. 8, e1052, 2022. DOI: <https://doi.org/10.7717/peerj-cs.1052>

Authors



Younguk Yun received B.S., M.S. and Ph.D. degrees in Electronic Engineering from Kwangwoon University, Korea, in 2014, 2020, respectively. Dr. Yun joined the faculty of the Software at Yonsei University in 2021.

He is currently an Assistant Professor at the Department of Software, Yonsei University. He is interested in Indoor positioning, Healthcare and Autonomous driving with AI signal processing of RADAR, camera, IMU and Various IoT sensors.



Jung-woo Sohn received B.S. and Ph.D. degrees in Aerospace Engineering and Information Sciences and Technology from Seoul National University, Korea in 1998 and The Pennsylvania State University, USA in

2013, respectively. Dr. Sohn joined the faculty of the Department of Software at Yonsei University in 2021. He is currently an Assistant Professor in the Department of Software, Yonsei University. He is interested in market system design, trading agent design, and agent-based simulations.