

스마트 디바이스를 활용한 노약자 근감소증 진단과 딥러닝 알고리즘

Diagnosis of Sarcopenia in the Elderly and Development of Deep Learning Algorithm Exploiting Smart Devices

윤영욱^{1*} · 손정우²Younguk Yun^{1*}, Jung-woo Sohn²¹Assistant Professor, Department of Software, Yonsei University, Wonju, Republic of Korea²Assistant Professor, Department of Software, Yonsei University, Wonju, Republic of Korea

*Corresponding author: Younguk Yun, yu_yun@yonsei.ac.kr

ABSTRACT

Purpose: In this paper, we propose a study of deep learning algorithms that estimate and predict sarcopenia by exploiting the high penetration rate of smart devices. **Method:** To utilize deep learning techniques, experimental data were collected by using the inertial sensor embedded in the smart device. We implemented a smart device application for data collection. The data are collected by labeling normal and abnormal gait and five states of running, falling and squat posture. **Result:** The accuracy was analyzed by comparative analysis of LSTM, CNN, and RNN models, and binary classification accuracy of 99.87% and multiple classification accuracy of 92.30% were obtained using the CNN-LSTM fusion algorithm. **Conclusion:** A study was conducted using a smart sensing device, focusing on the fact that gait abnormalities occur for people with sarcopenia. It is expected that this study can contribute to strengthening the safety issues caused by sarcopenia.

Keywords: Sarcopenia, Deep-learning, Smart-device, IoT, Walking-pattern, IMU, Data-analysis

요약

연구목적: 본 논문에서는 스마트 디바이스의 높은 보급률을 활용하여 근감소증을 추정 및 예측하는 딥러닝 알고리즘을 제안과 연구를 수행한다. **연구방법:** 딥러닝 학습을 위해 스마트 디바이스에 내장된 관성센서를 활용하여 실험 데이터를 수집하였다. 데이터를 수집하는 테스트용 어플리케이션 구현하여 '정상'과 '비정상' 걸음과 '달리기', '낙상', '스쿼트' 자세의 5 가지 상태를 구분하여 데이터를 수집하였다. **연구결과:** LSTM, CNN, RNN model 사용 시 예측 정확도를 분석했고 CNN-LSTM 융합형 모델을 활용하여 이진분류 정확도 99.87%, 다중 분류 92.30%의 정확도를 보였다. **결론:** 근감소증이 있는 사람의 경우 걸음걸이의 이상이 생긴다는 점에 착안하여 스마트 디바이스를 활용한 연구를 진행하였다. 본 연구를 활용하여 근감소증으로 인해 생기는 재난안전을 강화 할 수 있을 것이다.

핵심용어: 근감소증, 딥러닝, 스마트디바이스, IoT, 예측, 보행패턴, IMU, 데이터 분석

Received | 25 February, 2022

Revised | 12 August, 2022

Accepted | 26 August, 2022

OPEN ACCESS



This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/4.0>) which permits unrestricted noncommercial use, distribution, and reproduction in anymedium, provided the original work is properly cited.

서론

노령화로 인해 발생하게 되는 신체기능 저하와 근력 감소는 더 이상 노화 작용에 대한 자연스러운 현상이 아닌 근감소증(Sarcopenia)이라는 질병으로 분류됨에 따라 공공의료에서 국민 건강 증진을 목적으로 관리되어야 할 대상이 되고 있다. 근감소증이란 노화가 진행되면서 골격의 근량이 감소하면서 신체 기능이 떨어지는 것을 말한다(Evans, 1995). 미국에서는 2016년, 일본에서 2018년, 한국에서는 2021년 질병으로 분류되었고, 고령화 사회로 접어드는 선진국에서는 더욱 간과할 수 없는 사회적 문제로 분류하는 추세다. 한국에서도 평균 수명 연장 및 인구 구성의 불균형에 의해서 고령사회로 급속하게 진행되는 상황을 고려해볼 때 연령 증가에 따른 근감소증을 분석하고 방지하기 위한 적극적인 노력이 필요하다(Marty et al., 2017; Cao et al., 2016; Yuki et al., 2017; Kim et al., 2020). 노령화로 인한 근감소증은 근 손실률이 50%에 달하는데 근 손실로 인해 움직임이 둔화하는 특징이 있다.

근감소증의 진단(diagnosis)에는 여러 가지 기법이 이용되는데 크게 사지 근육량의 평가, 근력의 평가, 신체수행능력의 평가로 분류할 수 있다(Won, 2020). 이 중 신체 수행 능력 평가 방법(보행 속도의 측정, 5회 의자에서 일어서기 소요 시간)이 측정 방법이 간단하고 근육량 측정을 위해 자기공명장치(Magnetic Resonance Imaging, MRI)와 같은 전문 측정 기기의 사용이 필요 없기 때문에 우선으로 사용되고 있다. 이와 같이 근감소증의 진단을 위해서는 직접 환자의 근육량을 측정하거나 평가하는 방법이 가장 정확하더라도 과정이 환자에게 매우 불편하고 어려움을 줄 수 있다. 이에 직접 근육량을 평가하지 않고 근감소증을 판별하기 할 수 있는 비접촉식 근감소증 판별 연구가 필요한 상황이다.

근감소증 연구는 한국에서 2021년 질병으로 분류되었을 만큼 전 세계적으로 질병으로서 인지도가 매우 부족한 상태이며 많은 연구를 찾아보기 힘들다. 신체 수행 능력 평가는 Baumgartner가 1998년 New Mexico Elder Health Survey(NMEHS) 연구 결과를 토대로 진단 기준을 처음으로 제시한 이후 2014년에 아시아인을 대상으로 아시아 근감소증 진단그룹(Asian Working Group for Sarcopenia, AWGS)의 좀 더 구체적인 아시아 진단기준이 제시되어 사용되고 있다(Chen et al., 2014; Hong et al., 2012). AWGS 등의 진단기준에 따르면 건강한 고령자의 경우 보행속도는 1.0m/s 정도이며 근감소증이 발생한 고령자의 경우 보행속도가 0.6m/s 이하의 걸음 속도를 갖는 특징을 볼 수 있다(Sánchez-Rodríguez et al., 2015). 몇몇 연구들은 근감소증이 발생되면 걸음속도가 느려진다는 특징을 활용하여 연구를 진행하고 있으며(Ko et al., 2021; Kim et al., 2020) 관성센서(inertial measurement unit, IMU)를 활용해서 구한 이동속도가 위에서 언급한 걸음속도 이내에 해당하거나 별개의 통계적 데이터 처리 기법을 활용해 구한 이동 속도가 기준 속도 이내에 해당하면 근감소증을 판단할 수 있다.

관성센서를 통해 속도 값을 구하고 정상인과 근감소증을 구분하는 데이터 값을 사용하는 데는 여러 가지 문제가 있을 수 있다. 우선, 기존 연구는 걸음 수(step)와 보폭 거리를 활용하여 속도를 구한다(Lee et al., 2021). 여기서 걸음 수를 판단하는 알고리즘을 통해 정확한 걸음 수를 측정하기가 어렵다. 관성센서는 고유의 진동이 있기 때문에 센서의 민감도를 낮추면 걸음을 디딜 때 충격이 여러 번 가해져 실제보다 많이 걸음 수가 측정되고 민감도를 높이면 반대로 실제 걸음 수보다 적게 판정이 일어난다. 한명의 사용자에게 최적화를 시키기 위해 센서 보정(sensor calibration)을 수행하면 상황이 좋아지긴 하지만 센서의 한계로 정밀한 보정이 어렵고 모든 사용자에게 적용할 수 있는 만족할만한 보정 값을 찾기가 쉽지 않다. 일례로 스마트 워치나 step 측정 애플리케이션을 사용할 때 측정된 걸음 수가 서로 다른 것이 이런 이유에 기인한다. 이뿐만 아니라 보폭 값은 통계적인 보폭 값을 사용하고 있는데 이 또한 모든 사람에게 적용할 수 있는 대표 값을 찾기가 어렵다. 이렇게 측정되는 걸음 수와 보폭 값이 정확하지 않기 때문에 속도 또한 정확한 값을 추정하기가 어렵다. 이는 당연히 근감소증 판단 정확도에

도 영향을 줄 수 있다. 본 연구는 근감소증으로 인해 걸음 속도가 감소하는 점에 주목하는 한편 step, 보폭 등 속도에 영향을 받지 않는 형태의 근감소증 판별 연구를 수행하고자 한다.

또한, 본 연구에서는 최근의 높은 스마트 디바이스(smart-device) 보급률을 활용하여 추가적인 장치, 또는 추가 구매하는 장치 없이 쉽게 근감소증을 판별할 수 있는 내장 센서 기반의 활동 인지(human activity recognition, HAR) 연구를 수행하였다. HAR 알고리즘(algorithm) 대부분은 정상인의 운동량 측정과 관련된 연구에 초점이 맞춰져 있었다. 또한, HAR 알고리즘은 사용하는 센서에 따라 크게 두 가지로 환경 센서(Liu et al., 2016; Zeng et al., 2014)와 내장 센서(Stisen et al., 2015; Kanjo et al., 2019) 기반의 알고리즘으로 나누어 볼 수 있다. 환경 센서 기반 알고리즘은 비디오카메라와 같이 특정 위치에 고정되어 측정된 데이터를 활용한 형태이고 내장 센서 기반 알고리즘은 스마트폰, 스마트 워치, 웨어러블 디바이스 등과 같이 착용하거나 옷에 내장되어 움직임을 감지하는 알고리즘이다. 환경 센서 기반의 알고리즘은 사생활 침해, 유지보수의 어려움 등의 문제점이 있다. 반면, 내장 센서 기반의 알고리즘은 stand-alone 형태로 연구를 수행할 수 있기 때문에 환경 센서보다 데이터를 수집하고 유지보수하는데 장점이 있다. 본 연구에서는 스마트폰에 내장된 IMU 센서를 활용한다. 일반적으로 스마트 디바이스에 내장된 관성 센서는 가속도계(가속도 측정), 자이로스코프(각속도 측정), 마그네틱 센서(지자기 강도 측정)로 각 센서 당 3차원의 정보를 표현할 수 있도록 3축을 표현할 수 있다. 9개의 축 데이터를 전부 수집하기 위해 테스트용 애플리케이션 개발을 수행했다.

HAR에 활용되는 인공지능(artificial intelligence, AI) 알고리즘은 머신러닝(machine learning)과 딥러닝(deep learning, DL)으로 나눌 수 있는데 ML의 경우 주어진 훈련 데이터 세트(training data set)에서 패턴을 식별하고 추론하는 알고리즘으로 특징추출, 벡터화, 세분화, 정규화 또는 투사 등을 포함한다. 대표적인 알고리즘으로 Naive Bayes, k-Means clustering, Support Vector Machine(SVM), Linear Regression, Random Forests, k-Nearest Neighbours(k-NN), Hierarchical clustering 등이 이에 해당한다(Liu et al., 2016; Bishop, 2006; Domingos, 2012). 한편 최근 몇 년 동안 DL 알고리즘은 뛰어난 성능으로 많은 분야에서 활용되고 있다(Liu et al., 2016). DL은 모델 해석이 쉽지 않고 학습 시 많은 양의 데이터가 필요하며 높은 컴퓨팅 비용이 발생하는 등 단점이 존재하지만 데이터를 분류해서 전달해주는 작업이 생략될 수 있고 높은 학습 성능을 갖는 장점이 있다(Abdallah, et al., 2015; Shickel et al., 2018). 본 연구에서는 DL 알고리즘의 심층적인 모델 분석은 진행하지 않고 스마트 디바이스 환경을 고려한 낮은 컴퓨팅 비용에서 유리한 시계열(time-series) 분석을 수행하고 DL 알고리즘을 적용하여 정확도 분석 연구를 수행한다. 근감소증 유무 판별을 위해 보행 패턴을 기반으로 정상과 비정상 걸음을 판별하는 예측 모형을 제공하는 것을 목적으로 연구를 수행한다. 추가로 이진 분류와 여러 자세 및 활동에서 수집된 데이터를 분류하는 다중 분류 연구를 수행한다.

연구 내용

Fig. 1은 시스템 개요에 대한 설명이다. 개발된 스마트 디바이스 애플리케이션을 활용하여 다양한 자세와 움직임 데이터를 수집하고 수집된 데이터는 DL 알고리즘의 학습 데이터로 사용된다. 최종적으로 학습과 분류, 평가를 수행하여 알고리즘 간의 정확도 분석을 진행하였다. 결과값을 통해 최적화 예측 모델을 제안한다.

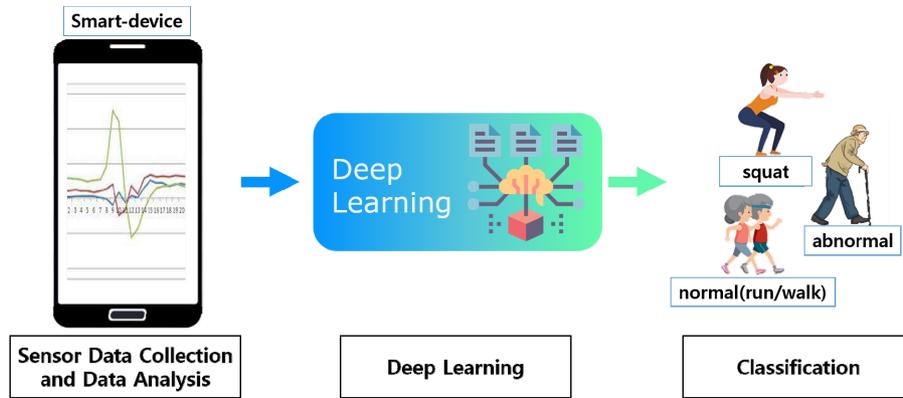


Fig. 1. System description

어플리케이션 개발

스마트 디바이스에 내장 센서를 활용하기 위해 테스트용 애플리케이션을 구현하였다. 또한, 데이터를 저장하기 위해 스마트 디바이스 Database(DB)로 사용되는 SQLite를 구현하였다. 구현된 애플리케이션은 Android Studio를 통해 구현하였으며 application programming interface, API version은 12이며 연구에 사용된 스마트 디바이스는 Galaxy Note 5 스마트폰이다. Fig. 2.는 개발된 애플리케이션을 보여준다. Fig. 2의 왼쪽 사진은 시작 화면인데 해당하는 실험에 대한 정보를 입력할 수 있다. 이 정보는 DL 알고리즘의 라벨(label) 정보로 활용된다. Fig. 2의 오른쪽 사진은 실험, 중지, main 화면 복귀 기능을 구현했다. Fig. 3은 수집된 데이터 일부를 보여준다. 수집된 학습에 필요한 9개의 데이터 필드와 label 외에도 측정 현황을 파악하기 위한 정보를 수집했다. accelX는 가속도 센서와 센서의 세 개의 축 중에서 x 축에 해당하는 데이터를 의미한다. accelY, accelZ는 각 y, z 축을 의미한다. 가속도 센서는 센서가 얼마나 빠르게 움직이고 있는지를 알려준다. 이외에 gyroX, magX 필드에서 gyro, mag는 각각 자이로 센서와 지자기 센서를 의미하고 센서의 회전과 방향 등의 영향을 받는 센서이다.

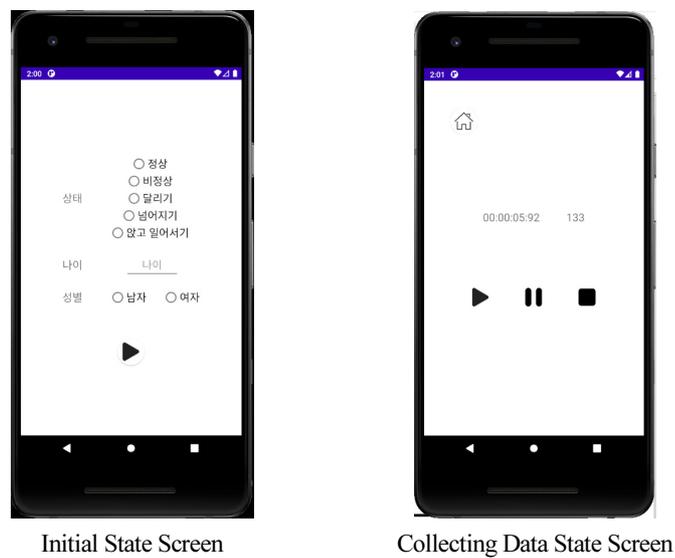


Fig. 2. Developed Application

Data										Label		
time	accelX	accelY	accelZ	gyroX	gyroY	gyroZ	magX	magY	magZ	gender	age	label
11:12	1	2	0	-128	-65	288	-15	276	-39	man	29	1
11:13	3	9	0	86	-33	59	-66	157	14	man	29	1
11:14	4	7	3	29	13	14	-48	-86	19	man	29	1

Fig. 3. Collected data by exploiting smart-device

근감소증 예측 알고리즘

근감소증 예측 연구를 위해 행동이나 움직임 패턴을 연구하는 HAR 연구에서 정확도가 높은 딥러닝 알고리즘을 채택하여 본 연구에 적용하고 정확도 연구를 수행했다. 본 연구에서 활용된 딥러닝 알고리즘은 Long Short-Term Memory(LSTM), Convolutional Neural Network(CNN), CNN-LSTM 융합모델, Recurrent Neural Network(RNN) 모델이다. LSTM은 시계열 데이터 예측에 강점을 보이는 모델, CNN은 이미지, 영상 분야에서 특징을 추출하여 예측하는 데 강점을 보이는 모델, RNN은 순환구조를 이루는 인공 신경망의 한 종류로 자연어 처리 분야에서 강점을 보이는 모델이다. Fig. 4는 CNN과 LSTM의 장점이 결합된 CNN-LSTM 모델로 최근 HAR 연구에서 활용되고 있다(Neverova et al., 2016; Wang et al., 2016).

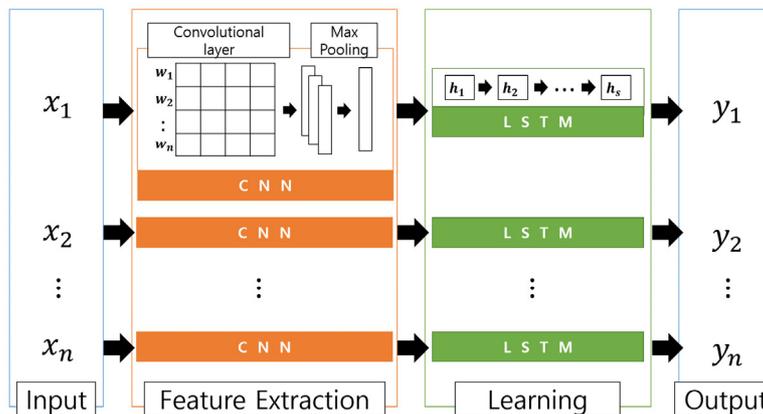


Fig. 4. CNN-LSTM model for HAR

실험 및 성능 평가

Fig. 5와 같이 제안 기법의 연구 및 성능 평가를 위해 개발된 애플리케이션을 활용하여 데이터 수집 실험을 진행하였다. 실험은 환경적인 요인을 줄이기 위해 경사가 없는 평지에서 수행이 되었고 Fig. 5의 Device Position 사진과 같이 실험자마다 편차를 최대한 줄이기 위해 밴드를 활용하여 허리 위치에 고정하여 데이터를 수집하였다. 50Hz로 수집된 데이터의 총수는 54,848개로 하나의 데이터는 센서 9개 축의 정보를 갖고 있으므로 $54,848 \times 9$ 의 2차원 데이터를 의미한다. 움직임별로 데이터를 labeling 하여 수집했고 수집된 데이터는 Table 1과 같다. normal gait(정상 걸음)은 정상인이 걷는 보통의 걸음을 의미

하고 abnormal gait(비정상 걸음)은 거동이 불편한 상태의 걸음을 모방하여 절뚝거리거나 터덜터덜 걷는 동작, 지그재그(zigzag)형 걸음, 비틀거리는 걸음 등 비정상적인 걸음을 의미한다. 지그재그 걸음은 좌우 약 2m내 이도 제한을 두었다. Run은 달리기를 의미하며 위 세 실험은 50m 거리를 왕복하는 실험을 수행했다. 또한, Falling은 낙상 시 움직임, Squat는 앉고 일어서는 스쿼트 운동 시 움직임 데이터를 수집했다. 여기서, 동작 학습 과정을 수행할 때 달리기 시 속도 제한 또는 낙상 실험 시 속도나 자세를 규정해 데이터를 수집하지 않았다. 예를 들어 달리기 실험데이터를 모은다고 할 때 팔의 위치, 달릴 때 모습, 속도 등을 규정하여 데이터를 모으지 않고 실험자에게 label의 주제만 알려주고 실험을 진행시켰다. 이유는 규정된 자세나 속도로 시험 데이터를 수집하면 규정된 자세나 모습에서는 높은 정확도를 보여줄 수 있지만 예외적인 상황에는 오히려 판단 정확도를 하락시킬 수 있는 요인이 될 수 있기 때문이다. 즉, 규정된 모습보다 다양한 형태의 데이터를 모으는 것이 실제 서비스를 구현하는데 이점을 줄 수 있다.

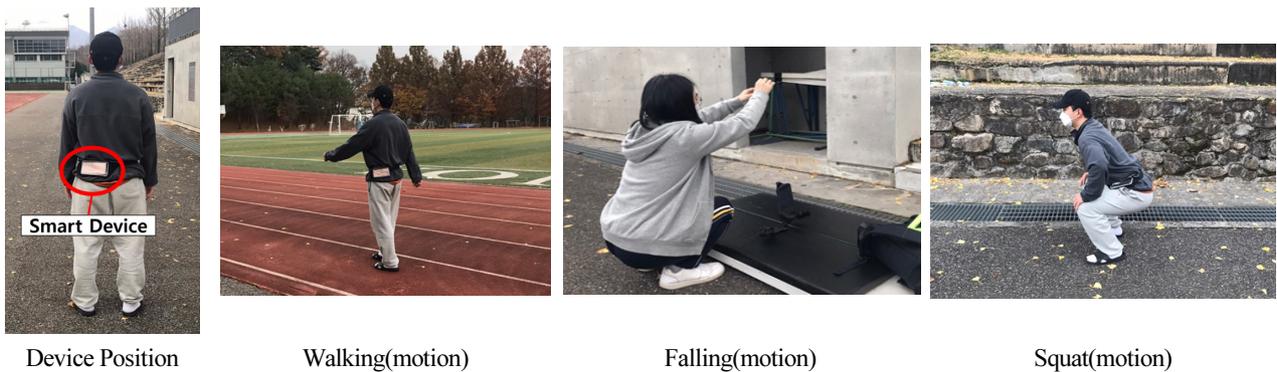


Fig. 5. Experimental environment

Table 1. Collected data handle

Label	Normal Gait	Abnormal Gait	Run(motion)	Falling(motion)	Squat(motion)	Total
Number of Data	12,864	21,312	6,016	8,064	6,592	54,848

실험 대상군은 성인 남성 2명, 성인 여성 2명 총 4명이 실험에 참여하였다. 각 개인들의 다섯 가지 실험 데이터는 모두 학습용 데이터로 함께 사용되었다. 한 사람의 데이터만 활용하여 데이터 분류를 잘하는 것보다 다양한 사람의 데이터를 활용하여 학습하는 것이 더 넓은 데이터 군집화(clustering)를 이뤄 줄 것으로 기대되기 때문이다. Fig. 6은 데이터 군집화의 개념도이다. 한 사람의 데이터만 활용하여 학습한다면 일진 부분에서만 데이터가 모이는 편협한 데이터 학습이 될 수 있다. 이러한 부분에 있어서 많은 사람과 다양한 패턴의 학습 데이터를 사용하는 것이 데이터 학습 시 중요하다고 볼 수 있다. 이렇듯 실험 대상군의 데이터를 모두 학습 데이터로 활용하는 것이 데이터 분석 결과에 영향을 미칠 수 있으며 다양한 데이터를 학습하여 넓은 군집화를 이루는 것이 학습 시 긍정적 요소로 작용할 수 있다.

요컨대, 위에서 언급한 바와 같이 통계적으로 다양한 연령층과 많은 사람의 데이터를 활용하여 학습과 성능 분석을 하는 것이 가장 바람직하지만 본 연구는 스마트 디바이스를 활용한 기술과 딥러닝 기술을 활용하여 근감소증과 노약자를 관리할 수 있는 일차적 연구로서의 기법 개발과 알고리즘 제안에 초점을 맞추고 있다.

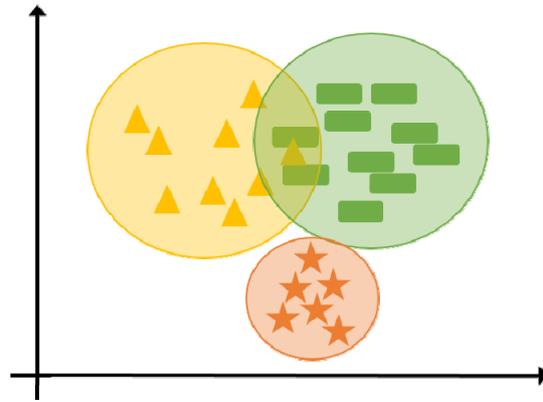


Fig. 6. Data clustering

데이터 분석 실험 개요

다양한 조건에서 수집된 데이터를 활용하여 두 가지 형태로 데이터 분석을 진행했다. 첫 번째는 근감소증 여부를 판별하는 이진 분류 모델과 정상, 비정상, 달리기, 낙상, 스킵트 동작 데이터 예측을 목표로 하는 다중 행동 분류 모델로 데이터 분석을 진행하였다. 이진 분류 모델링에는 Table 1의 normal gait 데이터와 abnormal gait 데이터가 사용되었고 다중 분류 모델링에는 Table 1의 모든 데이터가 모두 사용되었다. 데이터는 학습(train)과 테스트(test) 데이터 셋을 7:3으로 나누어 데이터 분석을 수행했다. 학습 데이터는 딥러닝 모델이 해당 동작을 학습하는 데이터이며 테스트는 학습된 데이터가 잘 예측이 되었는지 확인하는 데이터로 구분할 수 있다.

실험 결과 및 성능 평가

딥러닝 연구를 위한 플랫폼은 Tensorflow v2.0에서 진행되었다. 모델에 사용되는 프레임은 128×9 형태로 학습과 테스트가 진행되도록 설정하였고, 학습이 잘 될 수 있도록 오버래핑(overlapping)을 50%로 설정했다. 오버래핑 값에서 feature로 mean, max, minium, energy, entropy, mean-frequency, skewness, kurtosis 값이 사용되었다(Zeng et al., 2014; Stisen et al., 2015; Kanjo et al., 2019; Bishop, 2006).

본 연구에서 활용된 딥러닝 모델은 CNN, RNN, CNN-LSTM이며 데이터 분석을 위한 parameter는 다음과 같다. epoch는 100, batch size는 64, dense는 100, dropout은 0.5, activation function은 ReLu, Adam optimizer를 사용했고 CPU는 Ryzen 2500x, GPU는 GTX970이 사용되었다. 학습 속도는 최저 RNN 모델을 사용한 경우 약 50초, 최대 CNN-LSTM 모델을 사용한 경우 약 140초가 걸렸다. 학습 모형별 정확도는 Table 2와 같으며 이진 분류 모델의 경우 근감소증을 판별하는 알고리즘으로 볼 수 있는데 CNN은 99.12%, RNN은 98.92%, CNN-LSTM은 99.87%로 세 모델의 정확도가 99% 이상이며 CNN-LSTM이 약간 우세한 결과를 보였다. 다중 분류의 경우 CNN은 79.36%, RNN은 68.52%, CNN-LSTM은 92.30%로 역시 CNN-LSTM 모델에서 가장 높은 정확도 결과가 도출되었다. 여기에서 정확도는 데이터 프레임 하나의 정확도를 의미한다. 즉, 하나의 프레임을 통해 얻은 결과와 label 데이터를 비교하여 예측과 결과가 일치한 경우를 True라고 할 때, 전체 프레임에서 True라고 예측한 비율을 의미한다(Davis et al., 2006; Jun ker et al., 1999). 덧붙여 이것은 전체 프레임을 잘 예측

한 프레임의 수로 나눈 값으로 이해할 수 있다. 데이터 프레임은 앞서 설명한 바와 같이 20×9개의 데이터로 1초 동안 측정에 해당하는 데이터이다. 비교적 짧은 시간 수집된 데이터를 활용하여 예측하기 때문에 시스템의 실시간성도 높아질 수 있다.

정상 걸음과 비정상 걸음을 분류하는 이진 분류모델에서는 실험자의 직접적인 속도를 파악할 수 없지만 정상적인 걸음에 대비해서 움직임이 둔화하는 비정상 걸음의 경우 생기는 주파수의 변화, amplitude, mean, angle 값 등의 다양한 각도로 feature 값을 잘 학습하여 인해 높은 결과를 잘 도출했을 것이라 판단된다. 이 이진 분류 모델은 근감소증을 판별하는 분류 모델로 활용될 수 있는데 정상적인 걸음을 하던 사용자가 근감소증이 발병하게 되면 걸음 속도 저하로 인해 비정상 걸음으로 판별될 수 있고 이 정보를 활용해 근감소증 판별을 할 수 있다. 실제 사용자의 근감소증을 판별하기 위해서는 걸음걸이의 정상 여부와 동작 검출까지 이뤄져야 판단하기 용이할 것이다. 이때 활용될 수 있는 모델이 다중 분류 모델이다. Fig. 7는 학습 데이터를 나타낸다. 왼쪽은 9개의 학습 데이터 중 하나의 파형 데이터를 보여주고 있고 오른쪽은 데이터 한 프레임(frame)을 다음 프레임에서 50% 겹친 상태로 새로운 데이터를 생성한다. Fig. 7의 오른쪽 그림에서 색상의 강도가 신호 세기로 볼 수 있는데 비정상 걸음에 대비하여 신호강도가 낮은 점이 특징이다. 이는 걸음걸이 속도와 비례한다고 볼 수 있는데 이러한 특징으로 근감소증을 예측할 수 있을 것이다. 다중 분류의 경우 CNN-LSTM 모델을 사용했을 때 예측 정확도가 높았는데 근감소증 예측뿐 아니라 다양한 움직임에 대한 추정도 가능할 것으로 판단된다.

Table 2. Classification accuracy according to deep-learning models (unit: %)

model	Binary Classification			Multi Classification		
	CNN	RNN	CNN-LSTM	CNN	RNN	CNN-LSTM
Accuracy	99.12	98.92	99.87	79.63	68.52	92.30

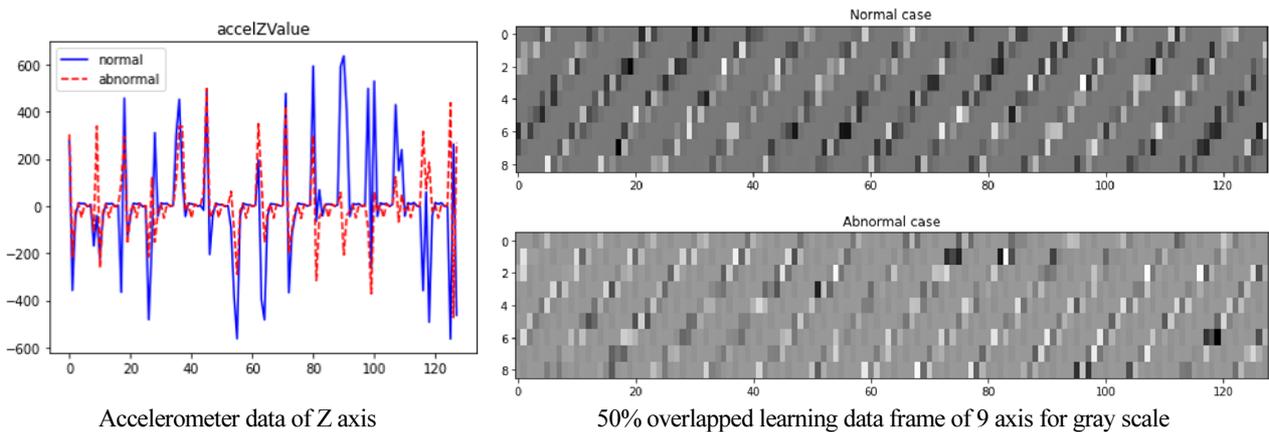


Fig. 7. Training data set

결론 및 향후 연구

본 연구는 고령자를 대상으로 근감소증 여부를 추가 기기 없이 일반적으로 많이 보급된 스마트 디바이스를 이용해 예측할 수 있는 시스템을 제안하였다. 이전의 비접촉식 근감소증 판단 알고리즘 연구들은 근감소증이 발병한 경우 걸음이 느려진다

는 특성을 활용하여 사용자의 이동 속도만 고려했는데 이러한 연구들은 이동 속도를 정확하게 구하지 못하면 실제로 활용되기 어렵다는 문제점을 갖고 있었다. 본 연구는 걸음 속도의 변화가 있다면 움직임에서도 다양한 feature 값들이 변할 것이라는 전제로 이진 분류를 진행했다. 또한, 다중 동작 분류는 속도만으로는 근감소증을 판별하기 어려운 경우 자세나 동작 데이터를 활용하여 근감소증 판단 정확도를 더 높이는 데 도움을 줄 수 있는 데이터로 활용될 수 있을 뿐만 아니라 특별히 관리가 필요한 사용자의 경우 관리자, 감독관이 의사결정을 내리는 데 도움이 되는 데이터로써 활용이 될 수 있다.

이 연구를 위해 Android 기반의 데이터 수집이 가능한 애플리케이션을 개발하였다. 근감소증이 발생하는 경우 가장 큰 특징으로 볼 수 있는 걸음걸이 속도를 변화에 초점을 맞춰 근감소증을 예측하는 모델을 제안했고 가장 높은 정확도는 CNN-LSTM 융합 모델 경우 99.87%의 높은 정확도를 나타냈다. 추가 연구로서 다양한 움직임을 예측하는 실험도 진행했는데 이 경우 역시 CNN-LSTM 융합 모델 사용 시 92.30% 정확도를 보였다.

Fig. 8는 다중 분류 시 CNN-LSTM 융합 모델에서 학습에 따른 정확도를 보여주고 있다. 학습이 진행될수록 안정적으로 정확도가 높아지는 것을 목표로 하고 있으나 그래프의 많은 변동을 확인할 수 있는데 학습 시 오버피팅(over-fitting)의 결과로 볼 수 있다. 추후 연구로는 모델링 parameter 조정을 통한 정확도 향상을 위해 다양한 연령층과 더 많은 사람의 데이터를 활용하여 학습과 성능 분석연구를 수행하고자 한다.

사용자가 정상적인 상태일 때 사용자의 걸음걸이를 사전에 학습시키거나 본 연구에서보다 더 많은 표본 데이터를 활용한다면 실시간으로 근감소증 예측해 고령자의 재난 안전사고 예방을 강화할 수 있고 움직임을 실시간으로 판별하는 서비스 등의 다양한 헬스케어 분야에서 활용이 가능할 것으로 판단된다.

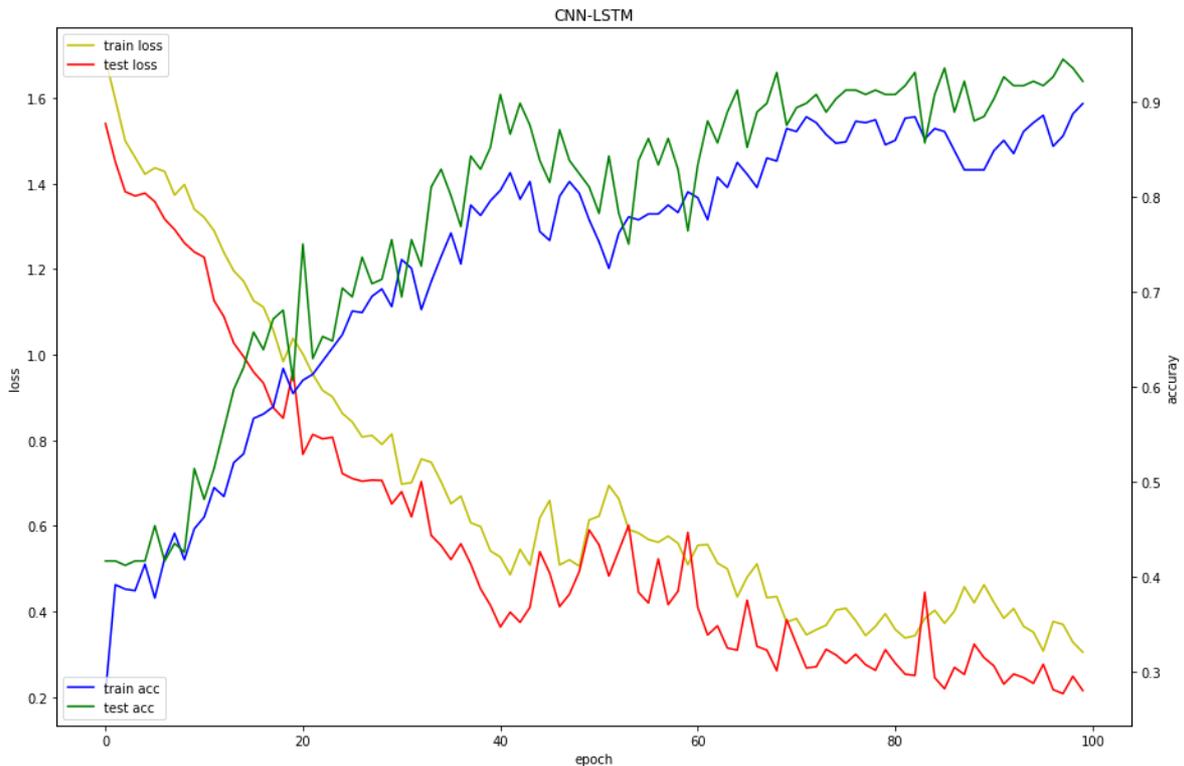


Fig. 8. Accuracy rate by learning of iteration(epoch)

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 2022”(2019-0-01219)

References

- [1] Abdallah, Z.S., Gaber, M.M., Srinivasan, B., Krishnaswamy, S. (2015). “Adaptive mobile activity recognition system with evolving data streams.” *Neurocomputing*, Vol. 150, pp. 304-317.
- [2] Bishop, C.M. (2006). *Pattern Recognition and Machine Learning*. Springer, New York, US.
- [3] Cao, L., Morley, J.E. (2016). “Sarcopenia is recognized as an independent condition by an international classification of disease, tenth revision, clinical modification (ICD-10-CM) code.” *Journal of the American Medical Directors Association*, Vol. 17, No. 8, pp. 675-677.
- [4] Chen, L.K., Liu, L.K., Woo, J., Assantachai, P., Auyeung, T.W., ShahrulBahyah, K., Chou, M.Y., Chen, L.Y., Hsu, P.S., Krairit, O., Lee, S.W., Lee, W.J., Lee, Y., Liang, C.K., Limpawattana, P., Lin, C.S., Peng, L.N., Satake, S., Suzuki, T., Won, C.W., Wu, C.H., Wu, S.N., Zhang, T., Zeng, P., Akishita, M., Arai, H. (2014) “Sarcopenia in Asia: Consensus report of the Asian Working Group for Sarcopenia.” *Journal of American Medical Directors Association* Vol. 15, pp. 95-101.
- [5] Davis, J., Goadrich, M. (2006). “The relationship between Precision-Recall and ROC curves.” *Proceedings of the 23rd International Conference on Machine Learning*, Pittsburgh, Pennsylvania, US, pp. 233-240.
- [6] Domingos, P. (2012). “A few useful things to know about machine learning.” *Communications of the ACM*, Vol. 55, No. 10, pp.78-87.
- [7] Evans, W.J. (1995). “What is sarcopenia?” *The Journals of Gerontology Series A: Biological Sciences and Medical Sciences*, Vol. 50, pp. 5-8.
- [8] Hong, S., Choi, W.H. (2012). “Clinical and Physiopathological Mechanism of Sarcopenia.” *The Korean Journal of Medicine* Vol. 83, No. 4, pp. 444-454.
- [9] Junker, M., Hoch, R., Dengel, A. (1999). “On the evaluation of document analysis components by recall, precision, and accuracy.” *Proceedings of the Fifth International Conference on Document Analysis and Recognition. ICDAR'99*, Bangalore, India, Cat. pp. 713-716.
- [10] Kanjo, E., Younis, E.M.G., Ang, C.S. (2019). “Deep learning analysis of mobile physiological, environmental and location sensor data for emotion detection.” *Information Fusion*, Vol. 49, pp. 46-56.
- [11] Kim, K.W., Byun, S.J., Lee, H.J., Han, J.W. (2020). *Method for Prediction Frailty Using Triple Axis Motion Meter, Prediction Frailty System using Triple Axis Motion Meter and Wearable Prediction Frailty Device*, KR. Patent No. 10-2107379, Korea.
- [12] Kim, M., Kim, H., Park, S., Cho, I., Yu, W. (2020). “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.
- [13] Ko, J.B., Kim, K.B., Shin, Y.S., Han, H., Han, S.K., Jung, D.Y., Hong, J.S. (2021). “Predicting sarcopenia of female elderly from physical activity performance measurement using machine learning classifiers.” *Clinical Interventions in Aging*, Vol. 16, p. 1723.
- [14] Lee, J., Park, K.E., Kim, Y. (2021). “IA 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.
- [15] Liu, Y., Nie, L., Liu, L., Rosenblum, D.S. (2016). “From action to activity: Sensor-based activity recognition.” *Journal of Neurocomputing*, Vol. 181, pp. 108-115.
- [16] Marty, E., Liu, Y., Samuel, A., Or, O., Lane, J. (2017). “A review of sarcopenia: Enhancing awareness of an increasingly prevalent disease.” *Journal of Brain Bone*, Vol. 105, pp. 276-286.
- [17] Neverova, N., Wolf, C., Lacey, G., Fridman, L., Chandra, D., Barbello, B., Taylor, G. (2016). “Learning human identity from motion patterns.” *IEEE Access*, Vol. 4, pp. 1810-1820.
- [18] Sanchez-Rodriguez, D., Marco, E., Miralles, R., Guillen-Sola, A., Vazquez-Ibar, O., Escalada, F., Muniesa, J.M. (2015). “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.
- [19] Shickel, B., Tighe, P.J., Bihorac, A., Rashidi, P. (2018). “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.
- [20] Stisen, A., Blunck, H., Bhattacharya, S., Prentow, T.S., Kjærgaard, M.B., Dey, A., Sonne, T., Jensen, M.M. (2015). “Smart devices are different: Assessing and mitigating mobile sensing heterogeneities for activity recognition.” In *Proceedings of the 13th ACM Conference on Embedded Networked Sensors Systems*, Seoul, South Korea, pp. 127-140.
- [21] Wang, J., Yu, L.C., Lai, K.R., Zhang, X. (2016). “Dimensional sentiment analysis using a regional CNN-LSTM model.” *Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics*, Berlin, Germany, Vol. 2, pp. 225-230.
- [22] Won, C.W. (2020). “Diagnosis of sarcopenia in primary health care.” *Journal of Korean Medical Association*. Vol. 63, No. 10, pp. 633-641.
- [23] Yuki, A., Ando, F., Otsuka, R., Shimokata, H. (2017). “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.
- [24] Zeng, M., Nguyen, L.T., Yu, B., Mengshoel, O.J., Zhu, J., Wu, P., Zhang, J. (2014). “Convolutional neural networks for human activity recognition using mobile sensors.” In *6th international conference on mobile computing, application and services*, Austin, Texas, US, pp. 197-205.