

IMU 데이터를 활용한 덤벨컬 동작분석 인공지능 모델 개발

김효린*, 김선아*, 한주혁*, 조용석*

Development of an Artificial Intelligence Model for Dumbbell Curl Motion Analysis Using IMU Data

Hyolin Kim*, Sun-A Kim*, Ju-Hyuck Han*, YongSeok Cho*

요약

현대인들의 건강의 중요성에 대한 인식이 점차 높아지면서 운동에 대한 관심이 증가하고 있다. 최근 코로나19 이후, 집에서 혼자 운동하는 이른바 홈트레이닝에 대한 수요가 증가하고 있다. 본 연구의 목적은 집에서 운동 중 피드백을 제공하므로 부상의 위험을 줄이는 것이다. 그러나 시장에 나온 제품들은 피드백을 제공하지 않거나 트레이너가 라이브 스트리밍에서 피드백을 제공한다. 또한 영상을 통해 피드백을 받더라도 미세한 움직임에 대한 피드백을 얻을 수 없다. 본 논문은 이러한 문제를 해결하기 위해 IMU 센서 데이터를 활용하여 덤벨컬 운동의 동작분석 인공지능 모델을 연구하였다. SVM, RNN, LSTM, ConvLSTM 모델들을 비교, 분석하고 Confusion Matrix, Roc Curve와 AUC를 이용하여 최적의 덤벨컬 운동에 대한 동작인식 인공지능 모델을 제시하였다. 본 연구를 통해, 집에서 개인 트레이너 없이 동작인식 인공지능 모델을 활용하여 부상의 위험을 줄이면서 안전하게 운동할 수 있다는 것을 확인하였다.

키워드 : 덤벨컬, 동작분석, IMU 센서, 홈트레이닝, 인공지능

Key Words : Dumbbell Curl, Motion Analysis, IMU Sensor, Home Training, Artificial Intelligence

ABSTRACT

With the increasing awareness of the importance of health among modern people, interest in exercise is increasing. Recently, after COVID-19, the demand for so-called home training, where you exercise alone at home, is increasing. The purpose of this study is to reduce the risk of injury by providing feedback during exercise at home. However, products on the market do not provide feedback, or trainers provide feedback on live streams. Also, even if you receive feedback through the video, you cannot get feedback on small movements. To solve this problem, we studied the motion analysis AI model of dumbbell curl exercise using IMU sensor data. We compared and analyzed SVM, RNN, LSTM, and ConvLSTM models, and presented a motion recognition artificial intelligence model for optimal dumbbell curl exercise using Confusion Matrix, Roc Curve, and AUC.

* First Author : Emro, dlsk4587@naver.com, 정회원

° Corresponding Author : Konyang University Department of Medical Information Engineering, yscho@konyang.ac.kr, 정회원

* Konyang University Department of Medical Information Engineering, hliu11@naver.com; dnfwlq203@gmail.com, 학생회원

논문번호 : 202203-044-C-RN, Received May 02, 2022; Revised May 30, 2022; Accepted May 30, 2022

1. 서 론

최근 COVID-19 이후 개인 건강에 대한 관심이 커지면서 건강 유지를 위한 충분한 신체활동의 필요성이 대두되면서 홈트레이닝의 관심도 증가하였으며, 국내외 많은 기업들도 홈트레이닝 시장에 진출하고 있다. 국내의 경우 삼성, LG, KT, SK 등 대기업부터 많은 중소기업들까지 홈트레이닝 서비스를 하고 있으며, 국외의 경우는 미국의 애플, 구글, 나이키 등 글로벌 기업에서부터 펠로톤(Peloton), 룰루레몬(Lululemon) 등 홈트레이닝 전문기업까지 홈트레이닝 시장이 빠르게 성장하고 있다. 미국 시장조사업체 그랜드뷰리서치(GRAND VIEW RESEARCH)에 따르면 전세계 피트니스앱 시장규모만 보더라도 전 세계 피트니스앱 시장 규모는 2021년 11억 달러 규모에서 2030년까지 연평균 17.6%의 성장률(CAGR)로 확대될 전망이다^[1-3].

홈트레이닝은 잘못된 자세나 운동으로 인한 부상을 방지하고, 운동의 효과를 극대화하기 위해서는 정확한 자세를 유지하며 수행하는 것이 중요하다. 따라서 최근에는 영상 콘텐츠를 보여주는 것을 넘어서 사용자의 자세나 움직이는 동작을 분석해서 자세를 교정하게 하거나 올바른 운동을 제시하는 개인 맞춤형 헬스 서비스를 제공하고 있는 제품들이 출시되고 있다.

스마트 홈트레이닝의 특성상 녹화된 영상이나 라이브 스트리밍 콘텐츠의 경우 화면을 통해서만 사용자의 자세를 확인할 수 있어 올바른 자세를 하고 있는지를 정확하게 파악할 수 없어서 운동의 효과가 감소될 수도 있고, 잘못된 자세가 반복되다 보면 관절에 부담을 주어 최악의 경우 부상을 입을 수 있다.

그리고 전문가의 설명이 포함된 스마트 홈트레이닝 동영상 콘텐츠를 시청하더라도 동작에 대한 피드백이 주어지지 않기 때문에 부정확한 자세로 인해 부상에 위험에 노출되기 쉽다. 따라서 스마트 홈트레이닝에서 운동 동작분석에 대한 피드백의 필요성이 매우 중요하게 요구되고 있다^[4-6].

또한 최근 발전하는 통신 기술 및 인공지능 기술들을 활용한 영상 스트리밍을 기반으로 하는 다양한 홈트레이닝 시스템이 시장에 발표되고 있다. 현재 피트니스 시장에 나온 대표적인 제품 중 하나인 Lululemon의 The Mirror는 스크린을 거울처럼 만들어 트레이너 및 사용자의 이미지가 표시되며, 사용자의 운동을 모니터링하여 트레이너가 피드백을 제공한다. 또한 요가, 스트레칭, 복싱 등의 다양한 라이브 수업을 제공하여 사용자가 원하는 수업을 선택하여 들

을 수 있다^[7]. 하지만 스크린이 거울이기 때문에 사용자의 동작과 트레이너의 동작이 겹쳐보여 트레이너의 자세를 보면서 동시에 거울에 비친 자신의 자세를 보기가 힘들다고 한다.

삼성 홈피트니스는 영상 스트리밍을 기반으로 수강자와 트레이너와의 실시간 영상 소통이 가능하며 다양한 운동을 할 수 있다^[8]. 하지만 이들의 경우는 피드백을 제공하는 트레이너가 영상만을 보고 자세를 판단하기 때문에 미세하게 잘못된 자세에 대한 피드백은 원활하지 않을 수 있으며, 정확한 자세 피드백을 제공하는데는 어려움이 있을 것으로 보인다.

이와 같이 운동 가이드 영상을 제공하거나 개인 트레이너가 실시간으로 영상을 보고 피드백을 해주는 홈트레이닝 서버는 한계를 가지고 있다. 운동 가이드 영상만을 보고 따라할 경우 자신의 동작이 정확한지 판단을 내리기 어렵고, 트레이너가 실시간 영상을 통해 피드백을 할 경우 작은 움직임에 대한 피드백이 불가능하다는 단점이 존재한다. 따라서 본 연구에서는 이러한 한계에 대한 대안으로 홈트레이닝 동작을 분석해서 피드백을 해주는 시스템을 제시하고자 한다.

홈트레이닝 동작분석 시스템의 경우 크게 영상을 기반으로 한 비접촉식 방식과 IMU(Inertial Measurement Unit)를 이용한 접촉식 방식으로 분류할 수 있다. IMU 센서는 주로 속도, 방향 및 중력을 측정하는 장치에 사용된다. 이전에 IMU 센서는 가속도 센서와 자이로스코프 센서로 나뉘었지만 후에 자기 센서도 추가되었다^[9].

IMU 센서는 주로 가상/증강현실, 스포츠 동작, 재활치료 등 동작 인식에 많이 활용되고 있으며, 최근의 센서제작 기술의 발달로 소형화, 저전력화가 구현되면서 착용 가능한 의류나 신발 등 활용 분야가 확대되고 있다. 특히, 의류나 신발에 웨어러블 디바이스 형태로 착용하여 사용될 경우는 ADL(Activities of daily living) 데이터 등 주로 큰 동작들을 인식하는데 활용된다.

이와 같이 사용자의 신체에 직접 부착하는 IMU 센서를 이용한 방식은 움직임에 대한 정확한 데이터를 수집할 수 있다는 장점을 가지고 있지만 장비의 구비 여부와 장비를 장착해야 한다는 단점을 가지고 있다. 반면에 카메라를 사용해서 영상을 이용하는 비접촉식 방식은 직접 센서를 부착하지 않아 자연스러운 동작 인식을 할 수 있다는 장점이 있지만 행동반경과 거리에 따른 제약으로 인해 정확한 동작을 인식하는데는 한계가 있다. 특히 딥러닝 기반 인공지능 기술을 이용한 3D 컨볼루션 신경망 모델은 학습과 추론에 많은

시간이 소요된다는 이유로 실시간성이 부족하기 때문에 실시간 동작분석에 적용하기에는 어려움이 있다¹¹⁾.

영상 데이터 기반의 동작분석 인공지능 모델은 관상면과 시상면에서 정확성을 보이며, 측정 동작과 운동면의 화면 일치도가 높을 경우 피드백의 정확도가 높아지지만 움직임이 작은 동작은 몸통 사지가 중복되는 문제, 수평면의 동작 또한 촬영 각도 및 높이의 문제로 정확도가 낮게 나온다¹¹⁾.

이러한 문제점을 해결하기 위해 본 논문은 영상처리가 아닌 IMU 센서를 사용하여 동작 분류를 시행하였다. IMU 기반의 동작분석은 센서를 통한 움직임의 직접적인 변화를 수집할 수 있어, 영상 기반 인식 기술보다 높은 감지 능력과 정확성으로 데이터의 특징이 두드러진다. 따라서 본 연구에서는 IMU 센서를 활용하여 큰 동작뿐만 아니라 미세한 동작의 차이를 구별할 수 있는 인공지능 모델을 설계하였다. 즉, 근력운동의 대표적인 운동인 덤벨컬 운동의 정확한 자세를 분류할 수 있도록 IMU 센서를 사용한 동작분석을 수행하는 인공지능 모델을 연구하였다.

II. 데이터 수집 및 전처리

본 논문에서는 그림 1, 2와 같이 스마트폰을 팔목에 부착한 상태에서 덤벨컬 운동을 하면서 이때 발생하는 IMU 센서 데이터를 수집하였다. 정확한 덤벨컬 동작을 구별하기 위해 4가지 자세를 정의한 후, 동작별로 10초 동안 5회 운동을 반복하면서 움직임에 대한 가속도와 자이로센서 데이터를 Sensor Logger Application을 통해 수집하였고, 딥러닝 학습을 위해 csv 파일로 저장하였다. 이때 IMU 센서 데이터의 Sampling Rate는 30Hz이다.

덤벨컬 동작 데이터는 총 4가지 운동 자세로 덤벨

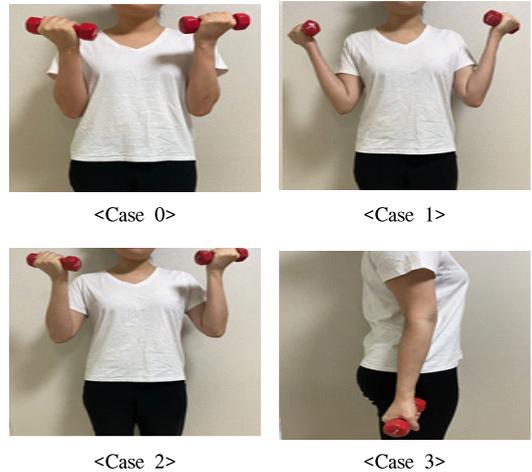


그림 3. Case 0~3 자세
Fig. 3. Posture of Case 0~3

컬 운동의 바른 자세(Case 0)와 올바르지 않은 자세(Case 1~3)로 구성되며, 올바르지 않은 자세는 덤벨컬 운동에서 흔히 발생하는 동작으로 운동 효과를 감소시키거나 관절에 부담을 주어 부상이 발생할 수 있는 자세를 대표적으로 선정하였다. 그림 3은 Case 0~3의 운동 자세 사진이다. 여기서 Case 1은 덤벨을 들어 올리는 동작에서 손목이 정상 어깨 범위를 벗어난 경우로, 손목회전을 하면서 완요관절과 노뼈머리가 손상될 수 있는 자세이다¹²⁾. Case 2는 팔꿈치를 옆구리에 고정시키지 않고 움직임이 생기는 경우로, 팔꿈치가 고정되지 않은 상태에서 운동하게 되면 상체가 흔들려서 정확한 자세를 유지할 수 없으며 치팅(cheating)을 유발하게 되어 부상을 유발할 수 있는 자세이다. 또한, Case 3은 팔을 완전히 펴며 운동하는 경우로, 팔의 완전한 이완으로 이두근에 열상이 발생할 수 있으며 빠른 운동 효과를 보기 위해 행하는 경우가 많아 잦은 부상을 유발할 수 있는 자세이다^{13,14)}.

이와 같은 운동을 통해 수집된 데이터는 각 Case 별로 200개의 데이터이고, 각각의 데이터는 10초 동안 5회 운동을 한 값으로 시간으로는 각 Case 별로 200개 x 10초 = 2,000초, 운동 횟수로는 200개 x 5회 = 1,000회 운동을 기록한 것이다. 또한, 학습 및 테스트 데이터를 증가시키기 위해 수집된 데이터를 Data Augmentation 방법의 하나인 표준편차 유도방식으로 정규분포에 따른 Noise를 추가하는 방법을 사용하였다. 즉, 수집된 가속도, 자이로센서 데이터에 정규분포 범위 내 랜덤 값을 각각 더해 새로운 데이터를 만들었다. 이 과정을 통해 각 Case 별로 1,800개 데이터를



그림 1. 피험자 실험 모습
Fig. 1. Subject's Experiment



그림 2. 실험에 사용한 스마트폰 고정 밴드
Fig. 2. The Smartphone Fixing Band Used in the Experiment

추가로 생성하였다. 최종적으로 본 연구에서 사용된 데이터는 Case 별로 직접 운동을 통해 수집된 데이터 200개, 추가로 생성한 데이터 1,800개 총 2,000개로 4개 Case에 전체 데이터는 총 8,000개이다. 이 중에서 Train Set은 7,200개, Test Set은 800개로 나누었으며 Test 과정에서 데이터 편향이 발생하지 않도록 Case 별 200개의 데이터를 통합하여 Test Set을 구성하였다. 그리고 수집된 데이터를 기반으로 가속도와 자이로 센서의 출력 파형의 패턴을 분석하였는데 그림 4~7은 각 Case 별 6축 데이터를 그래프로 시각화한 것이다.

그림 4는 바른 자세인 Case 0의 경우로 덤벨컬 운동의 특성상 손목에 부착한 스마트폰이 앞뒤로 움직이기 때문에 가속도 Y, Z축과 자이로 X축은 일정한 주기를 보이는 것을 확인할 수 있다. 그러나 가속도 X축과 자이로 Y, Z축에서는 움직임의 변화가 거의 보이지 않는데, 이는 바른 자세의 덤벨컬 운동은 가속도 Y, Z축과 자이로 X축만을 이용한다는 것을 알 수 있다. 또한, 가속도 X축과 자이로 Y, Z축에서 미세한 움직임은 운동을 하면서 생기는 근육의 잔 떨림으로 사료된다.

그림 5는 덤벨을 들어 올릴 때 손목이 어깨를 벗어나는 Case 1의 경우로 Case 0과 비교했을 때 가속도 X축과 자이로 Y, Z축에 차이가 발생하는데 그 이유는 팔목이 일직선이 아닌 사선으로 움직이므로 스마트폰을 부착한 팔목의 각도가 정상범위에서 벗어나기 때문에 나타난 현상이다. 또한 가속도 Y, Z축, 자이로 X축과 비교했을 때 떨림이 두드러지는 것을 확인할 수 있는데 이는 잘못된 자세에서 나오는 근육에 미치

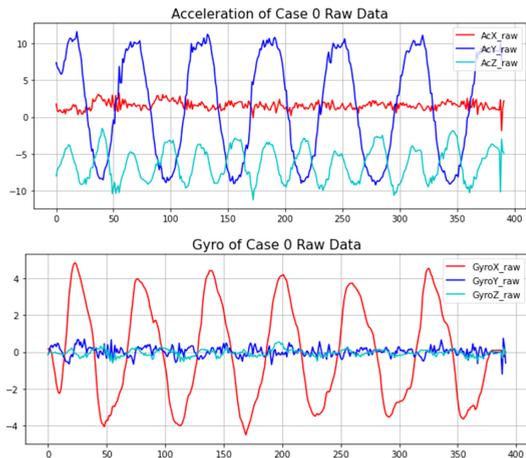


그림 4. Case 0 데이터 그래프
Fig. 4. Case 0 Data Graph

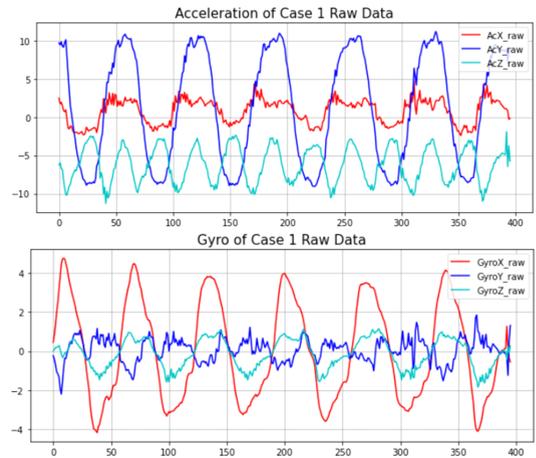


그림 5. Case 1 데이터 그래프
Fig 5. Case 1 Data Graph

는 부담이 떨림으로 나타나는 것이라고 판단된다.

그림 6은 삼두근이 몸통에 붙지 않는 Case 2의 경우로 Case 0와 비교했을 때 가속도 Y, Z축과 자이로 X, Y축에서 일정한 주기가 나타나는데 이 동작은 팔꿈치가 고정되지 않아 손목의 힘이 분산되어 센서가 좌우로 흔들리다 보니 가속도 Z축과 자이로 Y축에 차이가 발생하는 것이다. 특히 가장 두드러진 값은 가속도 X이다. 가속도 X를 보면 파장의 중심이 되는 부분이 0보다 작은 -5으로, 다른 Case들이 대개 0의 값을 갖는 것에 비해 유일한 파장의 범위인 것을 확인할 수 있다. 이 부분을 기반으로 가속도 X의 파장 기준이 0이하의 값으로 나타난다면 덤벨컬 운동시 팔꿈치를 고정하지 않는 잘못된 운동을 하고 있다 판단 할 수 있다.

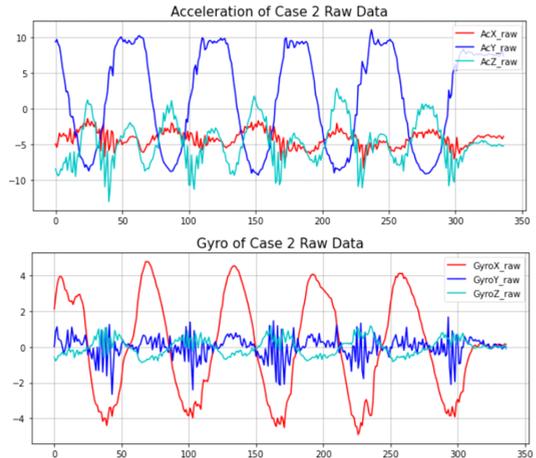


그림 6. Case 2 데이터 그래프
Fig. 6. Case 2 Data Graph

마지막으로 그림 7은 덤벨 운동의 이완 시에 팔을 완전히 펴면서 움직이는 Case 3의 경우로 Case 0과 비교했을 때 가속도 X, Z축과 자이로 X, Y축에서 두드러진 차이를 확인할 수 있다. 이 동작은 팔을 펴는 과정에서 이두근에 무리가 발생해서 근육에 떨림이 생기고 이 때문에 센서가 좌우로 흔들려 가속도 X, Z축과 자이로 Y축에서 변화가 발생한다. 특히 가장 두드러진 값은 가속도 Z와 자이로 X이다. 가속도 Z를 보면 파장의 범위가 5 ~ -10으로, 다른 Case들이 대개 0 ~ -10의 값을 갖는 것에 비해 유일한 파장의 범위인 것을 확인할 수 있다. 자이로 X는 파장의 마루 부분에서 잔 떨림이 많이 발생한다는 것을 확인할 수 있다. 이 두 부분을 기반으로 가속도 Z의 파장의 범위가 다르거나 자이로 X의 마루에서의 잔 떨림을 기준으로 덤벨컬 운동 시 팔을 완전히 펴는 동작으로 예측할 수 있을 것이다.

Case0~3의 데이터 그래프를 분석한 결과, 바른 자세와 올바르지 않은 자세의 명확한 차이뿐만 아니라 각 Case마다 특징이 두드러지는 부분을 확인할 수 있었다. 따라서 이러한 데이터를 가지고 인공지능 모델을 학습 및 분류 시킨다면 뛰어난 분류성을 보일 것으로 기대된다.

본 논문에서는 Peak-Detector로 수집된 데이터를 일정한 주기로 잘라내는 전처리 과정을 수행하였다. 또한, 수집된 데이터는 특성 유지를 위해 별도의 필터링을 거치지 않았다.

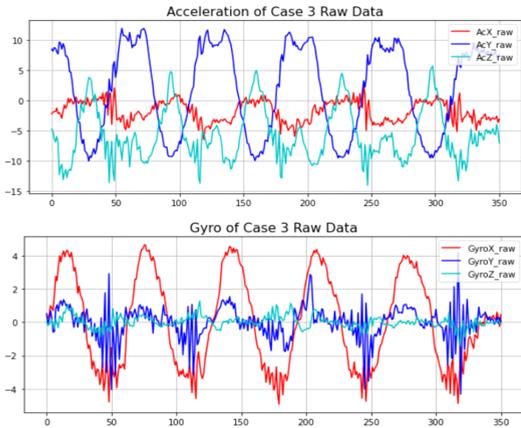


그림 7. Case 3 데이터 그래프
Fig. 7. Case 3 Data Graph

III. 인공지능 모델

본 논문에서는 덤벨컬 운동에 대한 미세한 자세 분

류를 위하여 적용 가능한 여러 인공지능 모델을 비교 검증하였으며, 이 과정에서 사용된 모델은 SVM(Support Vector Machine), LSTM(Long-Short Term Memory), RNN (Recurrent Neural Networks), ConvLSTM 모델로 시계열 데이터에 대한 인공지능 모델을 설계할 때 많이 사용되는 모델이다. 모델들의 정확한 비교를 위하여 구조를 제외하고 모델 성능에 영향을 끼칠 수 있는 여러 변수들을 유사하게 설정하였으며, 모델의 복잡도, Loss Function, Optimizer, Train Data Set, Test Data Set도 동일하게 적용하였다. SVM을 제외하고 본 논문에서 다룬 인공지능 모델의 초기화 방법은 모두 Random Normalization을 사용했으며, Optimizer는 Adam을 사용했다. 또한, Loss Function은 Categorical Cross Entropy이고 Epoch은 100회로 고정하였다.

SVM은 머신러닝 및 통계 전반에 걸쳐 광범위한 애플리케이션을 갖춘 강력한 패턴 인식 도구로 두 클래스 사이의 여백을 최대화하는 다차원 기능 공간에서 초평면을 찾는 기계 학습 알고리즘이다. SVM의 주요 장점은 Kernel 트릭을 사용하여 고차원 공간으로 변환해 분리할 수 없는 비선형 데이터를 분리한다는 것이다¹⁵⁻¹⁸.

그림 8은 본 논문에서 사용한 SVM 모델 구조로 이 모델은 입력 데이터의 3차원 구성이 어렵다. 따라서 기존의 데이터 수(7,200), 데이터 길이(250), 채널(6) 구조에서 데이터 수, 데이터 길이 × 채널로 구성된 7,200×1,500 형태의 학습 데이터로 변형하였다.

SVM의 Kernel은 Polynomial을 사용하였고, C와 Gamma의 값은 모델을 구성하면서 가장 최적값을 찾아서 결정하였는데 C의 값은 0.01, Gamma의 값은 0.001로 설정하였다. Polynomial Kernel은 데이터를 더 높은 차원으로 변형하여 나타냄으로써 초평면의 결정 경계를 얻을 수 있어 활용하였다.

RNN(Recurrent Neural Network)은 언어 모델링, 음성 인식을 포함한 중요한 작업에서 최첨단 성능을

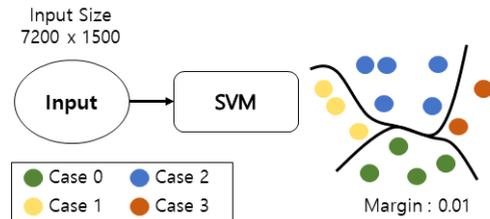


그림 8. SVM 모델 구조
Fig. 8. SVM Model Construction

갖는 신경 시퀀스(Sequence) 모델로 시퀀스에서 가까운 데이터 포인트 간의 상관관계를 구현하는 순차적 데이터를 처리하는 방법이다. 입력 벡터는 한 번에 하나씩 RNN에 입력되고, 고정된 수의 입력 벡터를 사용하는 대신 시간 프레임까지 사용 가능한 모든 입력 정보를 사용하여 예측할 수 있다. RNN이 캡처하는 양은 해당 구조와 훈련 알고리즘에 따라 다르다¹⁹⁻²¹.

그림 9는 본 논문에서 사용한 RNN 모델 구조로 이 모델은 시간 의존적 입력 시퀀스를 다루기 위해 설계되어 연속 학습에 대한 데이터 처리에 사용된다. 학습 데이터는 시계열 데이터로 연속 학습 처리에 탁월한 모델인 RNN을 사용하였다. RNN 모델은 데이터 수(7,200), 데이터 길이(250), 채널(6)의 구조를 입력 형태로 하는데, 이는 채널별로 시계열 데이터 처리를 위한 연속된 데이터 처리의 강점을 위함이다. 또한, 인공지능 모델의 학습 효율을 위한 배치 사이즈는 4로 설정하여, 하나의 배치 동안에 1,800개의 데이터가 학습된다.

모델은 7,200×250×6의 크기를 가진 학습 데이터를 입력받은 후, 첫 번째 RNN 구조에서 128개의 Hidden Layer를 입력받고, 두 번째 RNN 모델에 입력하기 전 데이터 크기를 7,200×5×250으로 변환하였다. 그리고 입력 데이터 형태를 변환하기 위해 Reshape Layer를 사용하는데 변환한 데이터를 25개의 Hidden Layer를 갖는 RNN 구조에 입력한 후, FC(Fully-Connected) 층을 거쳐 학습 결과를 출력하였다.

LSTM은 기존의 RNN의 단점을 보완하여 설계한 신경망의 구조로 직전 데이터뿐만 아니라 좀 더 거시적으로 과거 데이터를 고려하여 미래의 데이터를 예측하기 위해 개발되었다^{22,23,24}.

그림 10은 본 논문에서 사용한 LSTM 모델 구조로 우선 데이터를 분류하기 쉬운 형태인 7200×250×6의 크기를 가진 학습 데이터를 입력받는다. 이는 가속도 X, Y, Z와 자이로 X, Y, Z의 6개의 채널을 가진 데이터를 LSTM의 시계열 데이터 특징을 추출할 수 있는 구조로 데이터를 입력하기 위해 가공한 모형이다.

입력받은 데이터는 5개의 LSTM Cell을 거쳐 구성

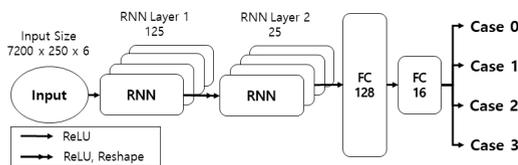


그림 9. RNN 모델 구조
Fig. 9. RNN Model Construction

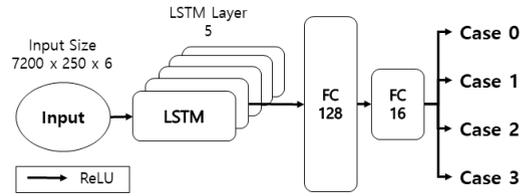


그림 10. LSTM 모델 구조
Fig. 10. LSTM Model Construction

된 모델로 각 Cell 마다 4개의 상호작용을 하는 Layer가 들어있다. 이 Cell은 Forget gate layer, Input gate layer, Output gate layer로 나뉜다.

Forget gate layer :

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{1}$$

Input gate layer :

$$\begin{aligned} i_t &= \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t &= \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \end{aligned} \tag{2}$$

Cell state update :

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \tag{3}$$

Output gate layer :

$$\begin{aligned} o_t &= \sigma(W_o [h_{t-1}, x_t] + b_o) \\ h_t &= o_t * \tanh(C_t) \end{aligned} \tag{4}$$

3가지 gate를 거쳐 업데이트가 끝나고, 업데이트가 끝난 데이터는 Cell State를 통해 정보가 전달된다.

본 논문의 데이터는 표준화와 정규화를 진행하여 라벨이 [0,1], [1,0]의 형태이기 때문에 다중 분류 함수로 쓰이는 Categorical_crossentropy를 이용하여 학습을 진행하였고, 최적화를 위해서 사용한 Adam은 매개변수의 크기가 Rescaling에 부동적인 장점을 가지고 있어 사용하였다²⁵. 학습 후 전달된 data size 128개의 정보는 FC(Fully-Connected)를 거쳐 data size 16으로 출력된다. 마지막으로 이 출력이 또다시 FC 층을 거쳐 Case 0~3중 하나의 학습 결과를 출력한다.

ConvLSTM은 CNN(Convolutional Neural Network)을 활용하여 결합된 입력 정보의 형상 추출을 LSTM을 사용하여 예측하는 것을 지원한다. ConvLSTM은 시각적 시간 배치 예측 문제와 문학적

표사의 활용을 위해 만들어졌다. CNN 모델을 이용하여 정보 그림 및 정보의 산출물을 LSTM으로 전달하고 LSTM에서는 그에 대한 정보를 시간 단계로 표시한다. 이를 하나의 layer라고 하며, 이 layer가 끝나면 유사한 layer를 다시 적용하여 여러 번 반복하여 내용을 인식하고 묘사하는데 이상적인 결과를 얻을 수 있다²⁶⁻²⁹.

그림 11은 본 논문에서 사용한 ConvLSTM 모델 구조로 이 모델은 데이터 형태를 이미지 Shape으로 구성해야 하므로 학습 데이터의 크기는 7200×25×10×6이다. 이는 CNN 형태의 계산방식을 위한 데이터 구조의 변경이며, 변경된 데이터는 데이터 길이(250)에서 데이터 길이(25), 데이터 길이 반복(10)으로 구성된다. 또한, 이러한 방식은 CNN의 Window 계산이 전체 데이터 길이(250)에서 데이터 길이(25)씩 국지적으로 이루어진다고 볼 수 있다.

첫 번째 Convolution 2D 층은 16개의 필터를 가지며 입력 Shape 크기는 25×10×6이고, 두 번째 Convolution 2D 층은 32개의 필터를 가지며 두 층 모두 활성화 함수인 ReLU(Rectified Linear Unit)를 사용하며 Kernel Size는 3×3이다.

다음 층에서는 Pool Size가 2인 Max Pooling을 한 후 학습 데이터의 크기를 7200×60×32로 Reshape 해준다. 변환한 데이터는 위 LSTM과 똑같은 구조를 가진 모델에 입력되며 마지막으로 FC층을 거쳐 학습 결과를 출력한다.

ConvLSTM은 기존의 LSTM과 달리 3차원 벡터로 연산되며 일반 행렬곱 대신 합성곱으로 이루어져 시간적, 공간적 특성을 모두 학습하므로 다른 모델에 비해 성능이 우수하다.

본 논문에서는 4개의 구조로 모델을 구성하여 딤벨컬 운동의 자세 분류 성능을 비교하였다. 인공지능 모델은 4가지 모델(SVM, LSTM, RNN, ConvLSTM)의 성능을 비교하여 가장 성능이 우수한 모델을 채용하였다.

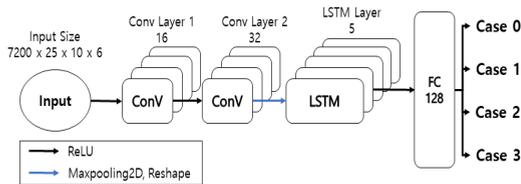


그림 11. ConvLSTM 모델 구조
Fig. 11. ConvLSTM Model Construction

IV. 실험결과 및 분석

위에서 제시한 4가지 모델의 성능 지표에 대한 정확한 성능을 나타내기 위하여 동일한 Test Data Set을 통해 검증하였다.

표 1에서 볼 수 있듯이, 본 논문에서는 Confusion Matrix를 이용하여 각 모델의 자세 분류 성능을 나타낸 것으로 각 모델이 Case 0(바른 자세)부터 Case 1~3(올바르지 않은 자세)를 다중 분류(Multi Classification)로 구분하여 정답과 비교한 것이다.

Confusion Matrix는 정확도 측정값을 계산하는 기존 분류 방법에 적합하므로 행동 분류 분야에서 모델의 동작을 평가하거나 시각화하는 기계 학습에서 많이 사용된다. 행은 대상의 실제 클래스를 나타내고, 열은 예측 클래스를 나타내는 정방향 행렬이다. 그리고 이진 분류 작업을 처리하는 경우 True Positive(TP), True Negative(TN), False Positive(FP), False Negative(FN)를 나타낸다.

또한, 주어진 데이터 세트에 대한 분류 모델이 수행한 Raw Data가 포함되어 있고, 모델의 일반화 정확도를 평가하기 위해 해당 모델의 학습 과정에서 사용되지 않은 테스트 데이터 세트를 사용하는 것이 일반적이다.

성능 지표는 정밀도, 민감도, F1-Score 등이 될 수 있고, 적절한 수행 지표의 선택이 학습 문제의 목표와 직접적으로 연결된다^{30,31}.

$$Accuracy : \frac{TP + TN}{TP + FP + FN + TN} \quad (5)$$

$$Sensitivity : \frac{TP}{TP + FN} \quad (6)$$

표 1. 모델 혼동 행렬
Table 1. Model Confusion Matrix

SVM Model				LSTM Model			
Case 0	Case 1	Case 0	Case 1	Case 0	Case 1	Case 0	Case 1
TN 561	FP 39	TN 600	FP 2	TN 561	FP 39	TN 585	FP 15
FN 54	TP 146	FN 17	TP 181	FN 39	TP 161	FN 6	TP 194
Case 2	Case 3	Case 2	Case 3	Case 2	Case 3	Case 2	Case 3
TN 600	FP 0	TN 521	FP 3	TN 596	FP 4	TN 553	FP 47
FN 77	TP 123	FN 143	TP 133	FN 24	TP 176	FN 36	TP 164
RNN Model				ConvLSTM Model			
Case 0	Case 1	Case 0	Case 1	Case 0	Case 1	Case 0	Case 1
TN 588	FP 9	TN 581	FP 18	TN 598	FP 2	TN 596	FP 4
FN 21	TP 182	FN 3	TP 198	FN 4	TP 196	FN 0	TP 200
Case 2	Case 3	Case 2	Case 3	Case 2	Case 3	Case 2	Case 3
TN 595	FP 5	TN 600	FP 11	TN 595	FP 5	TN 600	FP 0
FN 13	TP 187	FN 8	TP 181	FN 0	TP 200	FN 7	TP 193

$$\text{Specificity} : \frac{TN}{FP + TN} \quad (7)$$

$$\text{Precision} : \frac{TP}{TP + FP} \quad (8)$$

$$\text{F1-Score} : \frac{TP}{TP + \frac{FN + FP}{2}} \quad (9)$$

$$\text{AUC} : \int_{x=0}^1 TPR(FPR^{-1}(x))dx \quad (10)$$

본 논문에서는 Confusion Matrix를 통하여 모델이 운동을 바르게 분류한 부분의 비율을 알 수 있는 정확도(Accuracy), Case별 운동 중에서 모델이 각각의 Case를 잘 분류한 비율을 알 수 있는 민감도(Sensitivity), 각각의 Case에 맞지 않는 운동이라 분류한 것 중에 실제 Case에 맞지 않는 것을 의미하는 특이도(Specificity), 모델이 각각의 Case별 운동이라고 분류한 것 중에 실제로 잘 분류한 것을 의미하는 정밀도(Precision) 그리고 데이터의 불균형도를 확인하기 위하여 F1-Score를 사용하였다. 또한, 모델의 성능 판별의 정확도를 지표로 평가하기 위해 ROC(Receiver Operating Characteristic) Curve와 AUC(Area Under the Curve)를 사용하였다.

ROC Curve는 x축은 1-특이도, y축은 민감도로 하여 다양한 상황에서의 이진 분류 모델의 예측 정확도를 평가한다. ROC 커브의 아래 면적을 의미하는 AUC는 1에 가까울수록 모델의 성능이 좋다는 것을 의미한다. 본 연구에서 활용된 모델별 ROC Curve와 AUC는 그림 12에서 확인 할 수 있다³²⁾.

표 2는 인공지능 모델의 Case별 성능을 나타낸 것으로 본 연구에서는 위에서 제시한 6가지 성능 지표를 기준으로 평가하였으며, 지표의 성능이 95% 이상일 때 성능이 좋다고 판단하였다.

또한, 모델 구조 이외의 다른 변수들이 결과에 영향을 주지 않도록 모델 복잡도, 활성화 함수, 최적화 함수 등을 유사하게 구성하여, 모델 구조에 따른 성능만을 비교할 수 있도록 하였다.

표 2에 따르면, SVM 모델은 Case 1을 제외한 모든 Case에서 9개의 좋지 않은 성능(90% 이하)을 가진 지표들이 보였고, 특히 Case 3의 민감도와 AUC는 48.1%, 74%로 가장 낮은 성능을 보이는 것을 확인할 수 있었다. 이는 벡터화된 데이터 간의 특징을 가중치

표 2. 인공지능 모델의 성능

Table 2. Performance of the Artificial Intelligence model

SVM Model						
Case Type	Accuracy	Sensitivity	Specificity	Precision	F1-Score	AUC
Case0	0.883	0.730	0.935	0.789	0.758	0.83
Case1	0.976	0.914	0.996	0.989	0.950	0.98
Case2	0.903	0.615	1.0	1.0	0.761	0.81
Case3	0.817	0.481	0.994	0.977	0.645	0.74

LSTM Model						
Case Type	Accuracy	Sensitivity	Specificity	Precision	F1-Score	AUC
Case0	0.902	0.805	0.935	0.805	0.805	0.87
Case1	0.973	0.970	0.975	0.928	0.948	0.97
Case2	0.965	0.880	0.993	0.977	0.926	0.94
Case3	0.896	0.820	0.921	0.777	0.798	0.87

RNN Model						
Case Type	Accuracy	Sensitivity	Specificity	Precision	F1-Score	AUC
Case0	0.962	0.896	0.984	0.952	0.923	0.94
Case1	0.973	0.985	0.969	0.916	0.949	0.98
Case2	0.977	0.935	0.991	0.973	0.954	0.96
Case3	0.976	0.957	0.981	0.942	0.950	0.97

ConvLSTM Model						
Case Type	Accuracy	Sensitivity	Specificity	Precision	F1-Score	AUC
Case0	0.992	0.980	0.996	0.989	0.984	0.99
Case1	0.995	1.0	0.993	0.980	0.990	1.0
Case2	0.993	1.0	0.991	0.975	0.987	1.0
Case3	0.991	0.965	1.0	1.0	0.982	0.98

로 사용하는 비선형 분류기인 SVM의 한계로, 데이터 분류간 특징점이라고 볼 수 있는 자이로 Y축 데이터의 비슷한 유사성이 원인으로 작용하였다.

LSTM 모델은 Case 1을 제외한 모든 Case에서 8개의 좋지 못한 성능을 기록한 지표를 보였고 특히 Case 3의 정밀도는 77.7%로 가장 낮았으며, AUC는 Case 0과 Case 3이 87%로 낮은 성능을 보였다. 이는 표 2에서 LSTM 모델의 Case 0이 민감도, 정밀도, F1-Score에서 낮은 성능이 나타내는데, AUC 값에 영향을 미치는 특이도가 낮은 성능을 보여 이와 같은 결과가 나온 것으로 보인다. 이러한 결과는 LSTM의 특징인 Layer의 상태와 가중치를 공유하는 다중 Cell State이 데이터 분류 간 특징점이라고 볼 수 있는 자이로 X축 데이터의 미세 떨림을 분류성능의 단점으로 작용해 발생한 것으로 사료된다. RNN 모델은 Case 0에서 민감도가 89.6%로 낮은 성능을 가지는 것으로 나타났는데 이는 명백하게 같은 주기를 반복하는

Case 0에서 가장 떨어지는 성능을 기록한 것은 이전 데이터가 아닌 과거 데이터가 현재 데이터에 영향을 끼치지 않는다는 RNN 모델의 구조적 특징이 작용한 것으로 보인다. RNN과 LSTM은 구조적 유사성을 가지므로 직접적으로 비교해보면 표 2에서 RNN의 전체적인 Case 별 성능이 LSTM보다 뛰어난 것을 확인할 수 있다.

그 이유는 본 논문에서 사용한 데이터는 자세의 특징을 강조한 데이터로 잡음이 거의 없고, 특징이 뚜렷하며, 규칙적인 성능을 가지고 있는 데이터로 많은 Gate에 복잡한 구조를 가진 LSTM 모델에 비교적 단순한 데이터가 적용될 때 발생하는 과소적합(Under-fitting) 현상이 발생한 것으로 보인다. 마지막으로 ConvLSTM 모델은 모든 지표가 좋은 성능을 보였으며 ConvLSTM을 제외한 다른 모델은 상대적으로 성능이 떨어지는 것으로 나타났는데 이는 ConvLSTM 모델을 제외한 모든 모델의 분류 성능이 유사한 데이터에 영향을 받아 성능 감소로 나타난 것으로 해석된다. 또한, ConvLSTM을 제외한 다른 모델에서 Case 1의 성능이 다른 Case 들에 비해 전체적으로 높게 나온 것을 확인할 수 있다. 이는 그림 5의 Case 1 데이터 파형을 보면 다른 Case 들의 데이터와 비교했을 때 자이로 Y축의 파형이 두드러지게 차이나는 것을 볼 수 있는데 이런 특성 때문에 Case 분류 성능이 상대적으로 높게 나타났다고 할 수 있다.

표 3은 각 모델의 자세 분류 평균 성능을 나타냈는데 SVM 모델은 특이도(98.1%)를 제외한 지표들이 낮은 성능을 갖는 것을 확인할 수 있고, LSTM 모델은 특이도(95.6%)를 제외하면 좋지 못한 성능을 기록하였다. 그리고 RNN 모델도 정확도(97.2%)와 특이도(98.1%)를 제외하고는 만족스럽지 못한 성능을 보이는 것을 확인할 수 있다.

하지만 ConvLSTM 모델은 모든 6개의 지표가 95% 이상으로 좋은 성능을 가지는 것을 알 수 있다. 이는 표 2에서 비교한 Case 별 성능뿐만 아니라 전체

표 3. 자세 분류 평균 성능
Table 3. Model Experiment Results

Model Type	Accuracy	Sensitivity	Specificity	Precision	F1-Score	AUC
SVM	0.894	0.685	0.981	0.938	0.778	0.83
LSTM	0.934	0.868	0.956	0.871	0.869	0.91
RNN	0.972	0.943	0.981	0.945	0.944	0.96
Conv LSTM	0.992	0.986	0.995	0.986	0.985	0.99

적인 모델의 성능에서도 ConvLSTM이 가장 좋다는 것을 보인 것이다.

그림 12는 각 모델별 ROC Curve와 AUC를 그림으로 나타낸 것이다. 그림 12에서 ROC Curve는 민감도와 특이도를 0에서 1까지로 변경하면서 모델의 성능을 측정했다. 특이도가 높을 때에는 ConvLSTM과 LSTM의 민감도가 뛰어나게 나타났다. 반면에 RNN과 SVM의 경우에는 민감도가 떨어지는 것을 볼 수 있다. 하지만 특이도가 낮아지는 과정에서는 SVM의 민감도가 3개의 모델보다 낮은 상태로 유지되며, RNN의 성능이 가장 큰 폭으로 증가했다. 또한, 표 3에도 표시된 각 모델 별 AUC 값을 비교했을 때, SVM 모델의 AUC는 83%, LSTM 모델의 AUC는 91%이며 RNN과 ConvLSTM 모델의 AUC는 96%와 99%로 나타났다. SVM과 LSTM 모델의 AUC는 기준 이하의 성능을 나타냈으며, RNN과 ConvLSTM 모델의 AUC는 기준 이상의 성능을 보였다. 특히, RNN 모델은 여러 개의 Gate를 이용하여 과거의 데이터가 현재의 데이터에 영향을 끼치는 LSTM과 달리, 이전의 데이터만이 현재의 데이터에 영향을 끼치는 구조라 운동을 반복하여 주기가 생기는 데이터의 특징이 잘 반영되어 상대적으로 우수한 성능을 보였다.

ConvLSTM을 이용한 딥러닝 모델은 다른 분류 모델에 비하여 우수한 분류 성능을 보였는데, 이는 일반적인 CNN과 다르게 시계열 데이터 분류에 강점이 있는 LSTM의 구조가 함께 사용되어 연속적인 데이터 분류에 강점으로 작용했다. 또한 다른 모델과 같이 단일 모델 구조를 사용하는 것이 아닌 Convolution 2D 구조와 LSTM 구조, 총 두 개의 모델 구조를 사용하여 데이터를 학습하므로 99%의 높은 성능을 기록할 수 있었다.

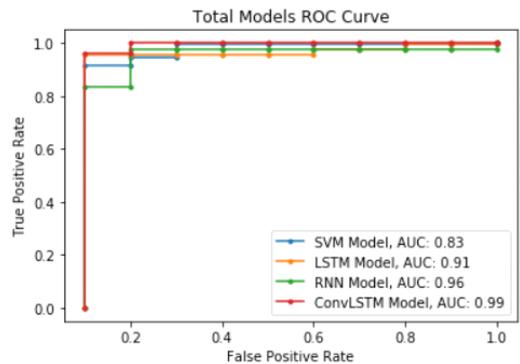


그림 12. 전체 모델의 ROC Curve 및 AUC
Fig. 12. ROC Curve and AUC of total models

특히, LSTM 모델과 다르게 시간적, 공간적 특성을 모두 학습하며, Convolutional Layer의 특징인 국소적 특징 추출 방법이 시계열 데이터에서도 작용한 것으로 확인된다. 또한 시계열 데이터를 기반으로 한 움직임 분류에서는 다른 모델 구조보다 Convolutional Layer의 특징과 데이터 연속성을 포함하는 것이 뛰어난 성능을 도출해내는 방법이라고 판단된다.

V. 결 론

본 논문에서는 영상 데이터 기반의 동작분석 인공지능 모델이 미세한 동작의 경우는 제대로 작동되지 못한다는 문제를 해결하기 위해서 움직임에 따른 IMU 센서 데이터를 활용하여 동작을 분석하는 인공지능 모델을 연구하였다. IMU 센서 데이터는 동작에 대한 직접적인 데이터로 영상 기반 인식 기술보다 높은 감지 능력과 정확성이 데이터의 가장 큰 특징이라고 할 수 있다.

본 연구에서는 덤벨컬 동작에 따른 IMU 센서 데이터를 입력으로 네 개의 인공지능 모델(SVM, LSTM, RNN, ConvLSTM)에 대한 성능 비교를 통하여 최적의 인공지능 모델을 찾는 과정을 수행하였다.

연구에 사용한 데이터는 덤벨컬 운동의 바른 자세와 잘못된 자세 3가지를 포함해, 총 4가지 운동 데이터로 구성하였으며, 연구결과 분석을 위해 Confusion Matrix를 사용하였고 Roc-Curve와 AUC를 이용하여 최적의 모델을 결정하였다. 그리고 ConvLSTM에서 Case 3이 민감도와 정밀도가 100%로 가장 높은 인식률을 보였다. 또한 모든 Case 지표들의 평균을 계산했을 때 ConvLSTM의 민감도가 99.5%로 가장 뛰어난 성능을 보였다.

결과적으로 인공지능 모델의 AUC를 분석한 결과 ConvLSTM이 99%로 가장 뛰어났으며 RNN이 96%, LSTM이 91% 그리고 SVM이 83%의 성능을 보였다. 이러한 연구 결과에 따라서 ConvLSTM 모델이 덤벨컬 동작의 자세 분류를 위한 인공지능 모델에서 가장 뛰어난 성능을 가진 것을 확인할 수 있었다.

본 연구에는 카메라를 통한 영상 데이터의 경우 카메라의 높이 및 각도, 몸통과 사지가 중복되는 문제 등으로 작은 움직임에 대한 분석에는 한계를 가지고 있다는 사실에 착안하여 IMU 센서를 활용하여 큰 동작뿐만 아니라 미세한 움직임에 대한 분류도 가능하다는 것을 알 수 있었다. 또한, 이러한 특징을 홈트레이닝에 활용한다면 사용자의 현재 운동 데이터를 기반으로 피드백을 제공하기 때문에 개인 트레이너 없

이도 PT 효과를 기대할 수 있으며 미세한 움직임까지 분류할 수 있어 부상의 위험을 현저히 낮출 수 있다는 것을 알 수 있었다.

향후 연구로는 공개 데이터 및 외부 데이터를 활용하여, 다수의 사용자를 대상으로 학습되지 않은 데이터에 관한 인공지능 모델의 성능을 평가할 예정이다. 또한, 향후 홈트레이닝에 대한 관심도가 높아지는 현대 사회에서 개인 트레이너 없는 경우도 동작분석 인공지능 시스템만으로도 충분한 피드백을 받을 수 있게 될 것이고 개인 PT의 경우도 데이터를 기반으로 정확한 분석자료를 피드백으로 추가 활용할 수 있을 것이다.

본 연구를 확대하여 다른 운동이나 부상이 우려되는 동작들을 추가하여 다양한 운동 동작들을 분류할 수 있는 인공지능 모델을 만들어갈 수 있을 것이다. 또한 영상 기반과 IMU 센서 기반의 데이터를 통합하여 좀 더 동작의 정확성을 높이는 연구로 발전시킬 수 있다.

References

- [1] J. Kwon, S.-J. Kim, and K.-K. Choi, "Analysis of user acceptance intention of home training application," *The Korean J. Sports Sci.*, vol. 30, no. 4, pp. 531-546, 2021. (<https://doi.org/10.35159/kjss.2021.8.30.4.531>)
- [2] Y.-J. Kim and K.-H. Kwak, "Keyword analysis of home training by period using big data," *The Korean J. Sports Sci.*, vol. 30, no. 1, pp. 103-115, 2021. (<https://doi.org/10.35159/kjss.2021.2.30.1.103>)
- [3] Grand View Research, Inc., "Fitness App Market Size, Share & Trends Analysis Report By Type (Exercise & Weight Loss, Diet & Nutrition, Activity Tracking), By Platform (Android, iOS), By Device, By Region, And Segment Forecasts, 2022 - 2030," 2022.
- [4] J. Choi, "Development of exercise program that enables posture and movement feedback using deep learning CNN" M.S. Thesis Sungkyunkwan University General Graduate School, Seoul, 2021.
- [5] J. Seo, M. Shin, and M. Moon, "Fitness system for correcting real-time posture using smart mirror," *J. IKEEE*, vol. 23, no. 1, pp.

- 74-79, Mar. 2019.
(<https://doi.org/10.7471/ikeee.2019.23.1.74>)
- [6] Korea Sports Safety Foundation, “2015 Sports Safety Accident Survey Results Report,” 2016.
- [7] Lululemon, *The Mirror*, Mar. 12, 2022, from <https://www.mirror.co/>
- [8] Samsung, *Home Fitness*, Mar. 12, 2022, from <https://www.samsung.com/sec/homefitness/>
- [9] A. Norhafizan, R. A. R. Ghazilla, and N. M. Khairi, “Reviews on various inertial measurement unit(IMU) sensor applications,” *Int. J. Signal Process. Syst.*, vol. 1, no. 2, pp. 256-262, Dec. 2013.
(<https://doi.org/10.12720/ijsp.1.2.256-262>)
- [10] S. Cho, M. Kim, J. Choi, T. Kim, J. Park, and N. Kim, “Implementation of face-touching action recognition system based on deep learning for preventing contagious diseases,” *The Korean Soc. Broad Eng.*, pp. 508-511, Korea, Jul. 2020.
- [11] J. Yang, J. Park, and C. Yu, “Accuracy verification of 3d motion analysis system using smart-phone monocular camera,” *Korean J. Sport Sci.*, pp. 464-471, Dec. 2021.
(<https://doi.org/10.24985/kjss.2021.32.4.464>)
- [12] F. Delavier and M. Gundill, *Anatomy Arm exercise guide*, Samho media, p. 91, 2016.
- [13] F. Delavier and M. Gundill, *Muscle exercise guide free weight*, Samho media, p. 78, 2013.
- [14] F. Delavier and M. Gundill, *Muscle exercise guide professional*, Samho media, p. 216, 2015.
- [15] A. Landeros and K. Lange, “Algorithms for sparse support vector machines,” *arXiv preprint arXiv:2110.07691*, 2021.
(<https://doi.org/10.48550/arXiv.2110.07691>)
- [16] S. Pal, Y. Peng, S. Barui, and P. Wang, “A support vector machine based cure rate model for interval censored data,” *arXiv preprint arXiv:2109.01098*, 2021.
(<https://doi.org/10.48550/arXiv.2109.01098>)
- [17] V. Cherkassky and Y. Ma, “Practical selection of SVM parameters and noise estimation for SVM regression,” *Neural networks*, vol. 17, no. 1, pp. 113-126, 2004.
([https://doi.org/10.1016/S0893-6080\(03\)00169-2](https://doi.org/10.1016/S0893-6080(03)00169-2))
- [18] C. Schuldt, I. Laptev, and B. Caputo, “Recognizing human actions: a local SVM approach,” in *Proc. IEEE 17th ICPR*, vol. 3, 2004.
(<https://doi.org/10.1109/ICPR.2004.1334462>)
- [19] W. Zaremba, I. Sutskever, and O. Vinyals, “Recurrent neural network regularization,” *arXiv preprint arXiv:1409.2329*, 2014.
(<https://doi.org/10.48550/arXiv.1409.2329>)
- [20] M. Schuster and K. K. Paliwal, “Bidirectional recurrent neural networks,” *IEEE Trans. Signal Process.*, pp. 2673-2681, 1997.
(<https://doi.org/10.1109/78.650093>)
- [21] K. Cho, B. Van Merriënboer, C. Gulcehre, D. Bahdanau, F. Bougares, H. Schwenk, and Y. Bengio, “Learning phrase representations using RNN encoder-decoder for statistical machine translation,” *arXiv preprint arXiv:1406.1078*, 2014.
(<https://doi.org/10.48550/arXiv.1406.1078>)
- [22] A. Sherstinsky, “Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network,” *Physica D: Nonlinear Phenomena*, vol. 404, 132306, 2020.
(<https://doi.org/10.1016/j.physd.2019.132306>)
- [23] Y. Yu, X. Si, C. Hu, and J. Zhang, “A review of recurrent neural networks: LSTM cells and network architectures,” *Neural computation*, vol. 31, no. 7, pp. 1235-1270, 2019.
(https://doi.org/10.1162/neco_a_01199)
- [24] A. Graves and J. Schmidhuber, “Framewise phoneme classification with bidirectional LSTM and other neural network architectures,” *Neural networks*, vol. 18, no. 5-6, pp. 602-610, 2005.
(<https://doi.org/10.1016/j.neunet.2005.06.042>)
- [25] D. P. Kingma and J. Lei Ba, “ADAM: A method for stochastic optimization,” *ICLR 2015*, p. 1, San Diego, USA, May 2015.
(<https://doi.org/10.48550/arXiv.1412.6980>)
- [26] M. Ma and Z. Mao, “Deep-convolution- based LSTM network for remaining useful life prediction,” *IEEE Trans. Industrial*

Informatics, vol. 17, no. 3, pp. 1658-1667, 2020.

(<https://doi.org/10.1109/TII.2020.2991796>)

- [27] X. Shi, et al., "Convolutional LSTM network: A machine learning approach for precipitation nowcasting," *Advances in NIPS*, 28, 2015. (<https://doi.org/10.48550/arXiv.1506.04214>)
- [28] R. Zhao, et al., "Bayesian graph convolution LSTM for skeleton based action recognition," in *Proc. IEEE/CVF Int. Conf. Comput. Vision*, pp. 6882-6892, 2019. (<https://doi.org/10.1109/ICCV.2019.00698>)
- [29] S. P. Singh, M. K. Sharma, A. Lay-Ekuakille, D. Gangwar, and S. Gupta, "Deep ConvLSTM with self-attention for human activity decoding using wearable sensors," *IEEE Sensors J.*, pp. 8575-8582, 2020. (<https://doi.org/10.1109/JSEN.2020.3045135>)
- [30] H. G. Lewis and M. Brown, "A generalized confusion matrix for assessing area estimates from remotely sensed data," *Int. J. Remote Sensing*, pp. 3223-3235, 2001. (<https://doi.org/10.1080/01431160152558332>)
- [31] O. Caelen, "A Bayesian interpretation of the confusion matrix," *Ann. Math. and Artificial Intell.*, pp. 429-450, 2017. (<https://doi.org/10.1007/s10472-017-9564-8>)
- [32] D. Brzezinski and J. Stefanowski, "Prequential AUC: Properties of the area under the ROC curve for data streams with concept drift," *Knowledge and Inf. Syst.*, vol. 52. pp. 531-562, 2017. (<https://doi.org/10.1007/s10115-017-1022-8>)

김 효 린 (Hyolin Kim)



2022년 2월 : 건양대학교 의료 IT 공학과 졸업

2022년 4월~현재 : 엠로 사원
<관심분야> 사물인터넷, 인공지능, 빅데이터

[ORCID:0000-0003-4994-6182]

김 선 아 (Sun-A Kim)



2023년 2월 : 건양대학교 의료IT 공학과 졸업 예정
<관심분야> 인공지능, 빅데이터, 전자공학

[ORCID:0000-0003-2769-7963]

한 주 혁 (Ju-Hyuck Han)



2018년 8월 : 건양대학교 의료IT 공학과 졸업

2020년 8월 : 건양대학교 의료 공학과 석사

2021년 3월~현재 : 건양대학교 의료공학과 박사과정

<관심분야> 인공지능, 의료공학, 전자공학

[ORCID:0000-0002-6987-2793]

조 용 석 (Yongseok Cho)



1989년 2월 : 성균관대학교 전기 공학과 졸업

1992년 8월 : 성균관대학교 전기 공학과 석사

1998년 2월 : 성균관대학교 전기 공학과 박사

1998년 2월~현재 : 건양대학교 의료IT공학과 교수

<관심분야> 디지털헬스케어, IoT, 인공지능

[ORCID:0000-0002-6425-8145]