

# 피트니스 AI 코칭을 위한 자세 추정 기술의 실용적 분석 리뷰: 자세 교정, 반복 횟수, 운동 범위 분석

(A Practical Analytical Review of Posture Estimation Technology for Fitness AI Coaching: Posture Correction, Repetition, and Range of Motion Analysis)

정희용\*, 신춘성\*\*, Okada Shima\*\*\*

(Hieyong Jeong, Choonsung Shin, Shima Okada)

## 요약

본 논문은 실제 피트니스 코칭 환경에서 마커리스 인체 자세 추정 기술의 적용 가능성을 비판적으로 검토해 본다. 학술적 연구 성과와 실제 상용화 사이의 간극을 줄이는 것을 목표로, 본 리뷰는 자세 교정, 반복 횟수 계산, 운동 범위 분석, 운동 인식이라는 네 가지 핵심 기능의 배포 준비성에 초점을 맞췄다. PRISMA 프로토콜에 따라 2020년에서 2025년 사이의 최신 연구 43개를 분석하여, 각 기술의 성과 뿐만 아니라 실제 환경에서 마주하는 근본적인 한계와 과제를 심층적으로 조명해 보았다. 분석 결과, 딥러닝 모델의 발전에도 불구하고, 데이터셋의 편향성, 표준화된 평가 기준의 부재, 다양한 사용자 및 환경에 대한 일반화 성능 부족, 그리고 파편화된 기능 개발이 기술 상용화의 주요 병목 현상임을 확인할 수 있었다. 본 논문은 이러한 한계를 극복하고, 프로토타입 수준의 연구를 넘어 신뢰할 수 있고 확장 가능한 AI 피트니스 코칭 시스템을 구축하기 위한 구체적인 미래 연구 로드맵을 제안해 본다.

■ 중심어 : 인간 자세 추정 기술 ; 머신러닝 ; 딥러닝 ; AI 피트니스 코치

## Abstract

This paper critically examines the applicability of markerless human posture estimation technology in real-world fitness coaching environments. Aiming to bridge the gap between academic research and commercialization, this review study focuses on the deployment readiness of four core functions: posture correction, repetition counting, range of motion analysis, and exercise recognition. Following the PRISMA protocol, we analyzed 43 recent studies published between 2020 and 2025 to deeply examine not only the achievements of each technology but also the fundamental limitations and challenges it faces in real-world settings. Our analysis reveals that despite advances in deep learning models, dataset bias, the absence of standardized evaluation criteria, poor generalization across diverse users and environments, and fragmented feature development remain key bottlenecks to technology commercialization. This paper proposes a concrete future research roadmap to overcome these limitations and build a reliable and scalable AI fitness coaching system beyond prototype-level research.

■ keywords : Human Pose Estimation Technology ; Machine Learning ; Deep Learning ; AI Fitness Coach

## 1. 서론

스마트폰과 웹캠의 보편화는 인공지능(AI)을 개인의 일상 속으로 가져왔으며 [1], 피트니스 분야 역시 예외는 아니다. 마커리스 인체 자세 추정 기술[2]은 사용자가 특별한 센서 없이도 자신의 운동 자세를 분석하고 코칭을 받을 수 있는 혁신적인 가능성을 열었다 [3]. 효과적인 AI 피트니스 코칭 시스템은

자세 교정(Posture Correction), 반복 횟수 계산(Repetition Counting), 운동 범위 분석(Range of Motion, ROM), 그리고 운동 인식(Exercise Recognition)의 네 가지 핵심 기능을 기반으로 한다. 최근 몇 년간 이와 관련된 다수의 리뷰 논문이 발표되었다 [4], [5]. 그러나 대부분의 연구는 새로운 모델 아키텍처나 특정 기술의 성능 향상에 초점을 맞추고 있어, 실제 소비자가 사용하는 애플리케이션으로 구현될 때 마주하는 실용적인 문제들을 충

\* 정희원, 전남대학교 인공지능융합학과

\*\* 정희원, 전남대학교 문화전문대학원

\*\*\* 정희원, Graduate School of Science and Engineering, Ritsumeikan University

본 연구는 한국연구재단지원(NRF-2021R111A3055210)과 전남대 교내중견연구지원(해외공동연구, No. 2024-1159-01)으로 수행됨.

접수일자 : 2025년 10월 20일

게재확정일 : 2025년 11월 21일

수정일자 : 2025년 11월 13일

교신저자 : 정희용 e-mail : h.jeong@jnu.ac.kr

분히 다루지 못하고 있다.

본 논문은 이러한 간극을 메우기 위해 과제 중심적 접근(task-first lens)을 취해 본다. 즉, 최종 목표인 효과적인 AI 코칭 시스템 구축의 관점에서 현재 기술들의 준비 상태를 평가하면서, 아래의 다섯 가지 연구 질문(RQ)에 대한 해답을 찾아보고자 한다.

- RQ1 (자세 교정): 실시간 피드백에 가장 효과적인 자세 교정 방법론과 그 트레이드오프는 무엇인가?
- RQ2 (반복 횟수 계산): 다양한 운동 속도와 변칙적인 움직임 속에서 강건하게 작동하는 계산 방법은 무엇인가?
- RQ3 (운동 범위 분석): 2D 영상의 한계 속에서 ROM을 신뢰성 있게 추정하는 기술은 무엇이며, 왜 이 분야의 연구는 더딘가?
- RQ4 (운동 인식): 적은 데이터로도 새로운 운동을 빠르게 인식할 수 있는 효과적인 방법은 무엇인가?
- RQ5 (배포 준비성): 현재 기술들이 파편화된 기능을 넘어, 일반 사용자의 기기에서 원활하게 작동하는 통합적이고 확장 가능한 시스템으로 발전하기 위해 무엇이 필요한가?

이를 위해 PRISMA 프로토콜[6]에 따라 118개의 연구를 선정하고, 그 중 43개의 핵심 연구를 심층 분석하였다. 본 리뷰는 단순히 기술을 나열하는 것을 넘어, 각 기술의 실용적 한계를 명백히 하고, 데이터셋 문제, 실패 사례 분석을 통해 진정으로 사용자에게 가치를 제공할 수 있는 AI 코칭 시스템 개발의 방향성을 제시한다.

## II. 관련 연구

여러 리뷰 논문들이 이미 인체 자세 추정과 그 활용 분야를 검토했지만, 각각의 초점은 다르다.

Roggio[1]은 저비용 이미징 시스템을 사용한 정밀하고 비침습적인 동작 분석을 위해 컴퓨터 비전과 머신러닝의 최신 발전에 중점을 두고 머신러닝 자세

추정 모델(PEM)과 그것이 인간 운동 과학에 미치는 영향을 평가하였다. 이 리뷰에서는 OpenPose, PoseNet, AlphaPose, DeepLabCut, HRNet, MediaPipe, BlazePose, EfficientPose, MoveNet과 같은 PEM들의 개발, 성능, 그리고 적용 사례를 강조한다.

Stenum[2]은 인간 발달, 수행 능력 최적화, 부상 예방, 그리고 신경학적 손상이나 질병이 있는 개인의 운동 평가 분야에서의 응용에 특별히 초점을 맞추었다.

Tharatipyakul[3]은 45개의 논문을 검토하여 인체 자세 추정, 움직임 평가, 사용자 피드백 제공 및 평가 기술을 정리하였다. 저자들은 규칙 기반 방법, 머신러닝, 수학적 공식이나 모델 등 다양한 움직임 평가 기법이 있음을 발견하였다. 이 논문은 자세 교정을 위한 일반적인 움직임 평가 기법을 논의하지만, 반복 횟수 계산이나 운동 범위 분석은 구체적으로 강조하지 않았다.

Salisu[5]은 3D 딥러닝 기반 인체 자세 추정 모델의 발전을 강조하며 정확성, 실시간 성능, 데이터 제한이라는 주요 문제를 다뤘다. 인체 자세 추정 모델과 사용된 데이터셋은 언급되었으나, 자세 교정, 반복 횟수 계산, 운동 범위 분석에 대한 자세한 내용은 없었다.

Mennella[4]은 재활 서비스에서의 스마트 보조 및 원격 모니터링에 집중하였다. 컴퓨터 비전 외에도, 이 논문은 Kinect 기반, IMU 센서, 가속도계 기반 웨어러블 센서, 스마트워치 및 유사 장치에 기반한 자세 추정 방법을 언급하였다.

이전 연구들과 달리, 본 리뷰는 운동을 위한 자세 추정 응용에 집중한다. 목표는 모델들의 자세 교정, 반복 횟수 계산, 운동 범위 분석, 그리고 운동 인식 활용 사례를 요약하고 평가하는 것이다. 주요 연구들에서 간단한 규칙, 동적 시간 왜곡(Dynamic Time Warping, DTW), 머신러닝, 컨볼루션 신경망(Convolutional Neural Networks, CNNs), 순환 신경망(Recurrent Neural Networks, RNNs)을 사용하는 자세 교정 파이프라인을 발견하였다.

반복 횟수 계산에 관한 또 다른 큰 그룹의 논문들은 규칙 기반 임계값과 CNN, 장단기 메모리(Long Short-Term Memory, LSTM), 그래프 컨볼루션 네트워크(Graph Convolutional Network, GCN) 방법을 사용한다. 운동 범위 분석을 다루는 논문은 거의 없으며, 대개 각도 임계값, 회귀 분석, 또는 초기 단계의 자기 지도 학습(self-supervised learning)을 사용한다. 운동 인식 분야는 성장하고 있으며, CNN, CNN+RNN 하이브리드, DTW 파이프라인이 운동을 분류하는데 사용된다. 마지막으로, 여러 논문이 배포에 대해 논의하지만, 여러 과제를 종단 간 시스템으로 결합하거나 피트니스, 요가, 치료 환경에서 확장성을 테스트한 경우는 거의 없었다.

### III. 연구 방법론

피트니스에서의 자세 추정에 대한 검토에 관한 문헌을 검토하기 위해, 체계적 문헌고찰과 메타분석을 위한 주요 보고 항목(PRISMA) 프로토콜[6]에 따라 광범위한 범위 scoping 연구를 수행하였다. PRISMA는 데이터 출처, 검색 전략, 스크리닝, 그리고 자격 결정에 대한 투명한 보고를 위한 체크리스트를 제공한다. 제시한 다섯 가지 연구 질문에 따르며, 식별되고, 스크리닝되며, 포함된 기록들의 PRISMA 스타일 흐름 요약을 제공한다.

#### 1. 검색 전략 및 데이터 출처

최대한의 범위를 확보하기 위해 수동 및 자동 검색을 모두 사용하였다. 주요 검색 엔진으로는 ACM Digital Library, arXiv, IEEE Xplore를 사용하였다. 범위를 넓히기 위해, 광범위한 통합 검색 엔진 역할을 하는 구글 스칼라(Google Scholar)를 사용하여 MDPI, Elsevier, Springer, IET, CVF, Heliyon, PeerJ 등 다른 출판사의 더 관련성 있는 연구들을 수집하였다. 교차 참조와 추가적인 구글 스칼라 검색을 통해 PubMed에 색인된 관련 논문과 기타 출처가 포함되도록 하였다. 검색에는 동일한 불리언(Boolean) 문자열이 사용되었으며, 각 플

랫폼의 구문에 맞게 제한되었고, 2020년부터 2025년까지의 출판물에 초점을 맞추었다. 대표적인 불리언 검색 문자열은 다음과 같다.

- (“pose estimation” AND “fitness”) OR (“pose estimation” AND exercise)
- (“repetition counting” OR “rep counting”)
- (“range of motion” OR “ROM analysis”)
- (“posture correction” OR “pose correction”)
- (“AI coach” OR “exercise feedback”)
- (“monocular pose estimation” AND “fitness”)
- (“real-time AI coach” AND “fitness”)
- (“exercise feedback” AND “computer vision”)

데이터베이스 검색 외에도, 포함된 논문들의 참고 문헌 목록에서 스노우볼링(snowballing) 기법을 사용하여 추가적인 관련 연구를 찾았다. PRISMA 흐름 템플릿을 사용하여(식별-스크리닝-자격-포함) 단계별 수를 보고하는 구조를 만들었다.

#### 2. 포함/제외 기준

리뷰가 포괄적이고 연구 요구사항에 맞춰지도록 IEEE Xplore, ACM Digital Library, arXiv, 구글 스칼라에서 전문(full-text) 검색을 수행하였다. 포함 또는 제외 자격을 결정하기 위해 초록과 제목을 바탕으로 한 2단계 스크리닝 과정을 시행하였다.

##### ■ 포함 기준

- 2020~2025년 사이의 영어로 된 학회 논문 또는 동료 심사를 거친 학술지 논문
- 자세 추정을 이용한 신체 운동 활동의 시각 기반 평가
- 자세 교정, 반복 횟수 계산, 운동 범위 평가 중 최소 하나의 특정 과제에 집중
- 종합적인 분석을 뒷받침할 수 있는 충분한 방법론적 세부사항과 실시간 성능 및 정확성에 대한 정량적 평가

##### ■ 제외 기준

- 시각적 요소 없이 웨어러블 기기나 센서(예: IMU)만을 활용한 연구

- 운동 관련 평가가 없는 순수 자세 추정 모델 논문

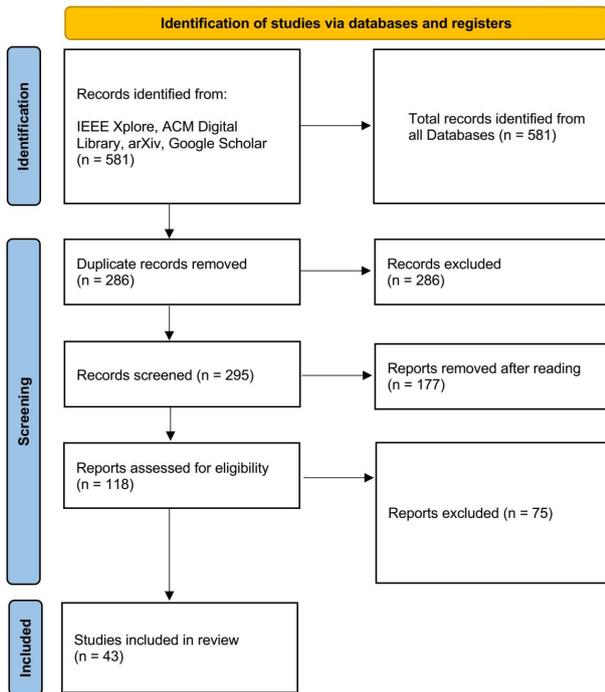


그림 1. 식별부터 포함까지의 PRISMA 흐름.

- 중복, 무관한 기록, 주제를 벗어난 항목
- 접근 가능한 방법론/결과가 없는 논문; 영어가 아닌 논문; 동료 심사를 거치지 않은 자료

### 3. 결과

문헌 검색을 통해 피트니스 및 운동 분석에서의 자세 추정과 관련된 총 581개의 기록을 확인하였다. 중복을 제거한 후, 286개의 고유한 기록이 남았다. 제목과 초록을 스크리닝하여 118개의 논문으로 줄였다. 전문 평가 후 75개가 제외되어, 최종적으로 43개의 연구가 이 리뷰에 포함되었다. 그림 1은 식별부터 포함까지의 PRISMA 흐름을 보여주며, 포함/제외 기준이 적용된 지점을 포함한다 (PRISMA 2020 템플릿에 따름). 그림 1에서 보여주고 있는 PRISMA 흐름도는 체계적이고 문헌 고찰 과정에서 논문을 어떻게 검색하고 선별했는지 보여주는 표준 다이어그램이다.

Identification(식별 단계)는 연구 주제와 관련된 모든 잠재적 문헌을 데이터베이스에서 검색하는 초기 단계이다. 저자들이 IEEE Xplore, ACM

Digital Library, arXiv, Google Scholar라는 4개의 학술 데이터베이스 및 검색 엔진에서 키워드 검색을 수행하였다. 결과 총 581개의 논문이 검색되었다.

Screening(선별 단계)는 식별된 문헌들 중에서 실제 연구 주제와 관련 없는 문헌, 중복된 문헌 등을 제외하는 ‘필터링’ 과정이다. 581개의 논문 중 서로 다른 데이터베이스에서 동일한 논문이 검색되는 등 중복된 문헌 286개를 제거하였다. 중복이 제거된 295개의 고유한 문헌을 대상으로 본격적인 1차 선별 작업(스크리닝)을 시작한다. 이 단계에서는 주로 제목과 초록을 읽고 연구 주제와 관련이 있는지 평가한다. 295개 문헌의 제목과 초록을 읽어본 결과, 연구 주제와 명백히 관련이 없다고 판단된 177개의 문헌을 제외하였다. 1차 선별에서 살아남은 118개의 문헌들은 제목과 초록만으로는 제외 근거가 불충분하거나 연구 주제와 관련이 있을 가능성이 높아, 전문을 모두 읽어보는 2차 선별(적격성 평가)을 진행한다. 118개 문헌의 전문을 모두 읽어본 후, 미리 정해진 선정/제외 기준에 맞지 않는 75개의 문헌을 최종적으로 제외하였다. 연구 방법론이 다르거나, 측정하려는 결과 변수가 없거나, 연구 대상이 다른 경우 등이 제외 사유가 될 수 있다.

Included(포함 단계)는 모든 선별 과정을 통과하여 최종적으로 분석에 사용될 문헌을 확정하는 단계이다. 전문 평가를 통과한 최종 43개의 논문이다. 이 43개의 논문이 바로 이 체계적 문헌 고찰 연구에서 심층적으로 분석하고 종합될 대상이 된다.

이 연구는 처음에 581개의 논문을 찾았으나, 중복 제거, 초록 검토, 전문 검토 과정을 거쳐 최종적으로 43개의 논문을 선정하여 분석하였다. 표 1~4은 각 연구의 초점(자세 교정 / 반복 횟수 계산 / 운동 범위 / 운동 인식), 방법, 그리고 성과 및 한계를 상세히 기술한 마스터 비교표이다.

## IV. 방법론별 심층 분석 및 비교

1. RQ1 - 자세 교정: 해석 가능성과 정확성의 트레이드오프

자세 교정은 AI 코칭의 핵심으로, 22개(51%)의 연구가 이 주제에 집중하였다. 방법론은 크게 규칙/휴리스틱 기반과 데이터 기반으로 나눌 수 있다.

규칙 기반 및 휴리스틱 방법은 관절 각도나 신체 부위 간의 거리를 미리 정의된 임계값과 비교하는 직관적인 방식이다. (Ji et al., 2022)나 (Renugadevi et al., 2023)의 연구처럼, 이 접근법은 계산 비용이 낮아 실시간 처리에 유리하고, 피드백의 근거가 명확하여 사용자가 이해하기 쉽다는 장점이 있다. 하지만 운동의 종류나 개인의 신체적 특성에 따라 규칙을 수동으로 미세 조정해야 하므로 확장성이 떨어지고, 다양한 변칙 상황에 대처하기 어렵다.

데이터 기반 학습은 SVM, Random Forest 같은 전통적 머신러닝(ML)과 CNN, RNN, GCN 기반의 딥러닝(DL) 모델을 사용한다. 이들은 데이터로부터 직접 패턴을 학습하므로 복잡하고 미묘한 자세 오류를 잡아낼 잠재력이 있다. 특히 (코매 et al., 2022)의 GCN 모델이나 (Rao et al., 2025)의 Bi-CGRU 모델은 시퀀스 데이터의 시간적 맥락을 이해하여 높은 정확도를 보였다. 그러나 이들의 가장 큰 한계는 대규모의 고품질 데이터셋에 대한 의존성이다. 또한, 모델이 복잡해질수록 왜 그런 판단을 내렸는지 설명하기 어려운 블랙박스 문제가 발생하며, 이는 사용자 신뢰도에 영향을 줄 수 있다. 흥미롭게도 (Raza et al., 2023)과 (Ko et al., 2024)의 연구에서는 특정 과제에서 ML 모델이 DL 모델을 능가하는 결과를 보였는데, 이는 피트니스 데이터의 특성상 과적합(overfitting)을 피하고 일반화 성능을 확보하는데 있어 신중한 특징 공학(feature engineering)이 여전히 중요함을 시사한다.

실용적 관점에서 최적의 선택은 하나가 아니다. 빠른 프로토타이핑이나 특정 소수 운동을 타겟팅할 경우, 규칙 기반 접근이 효율적이다. 반면, 다양한 운동과 사용자를 지원하는 상용 서비스를 목표로 한다면 데이터 기반 모델이 필수적이지만, 데이터 수집 비용과 해석 가능성 문제를 해결해야 하는

과제가 따른다.

## 2. RQ2 - 반복 횟수 계산: 주기성과 변칙성의 딜레마

총 13개(30%)의 연구가 반복 횟수 계산을 다뤘다. 이 기능은 운동의 주기적 패턴을 감지하는 것이 핵심이다.

규칙 및 신호 처리 기반 방법은 관절 각도 변화의 정점(peak)을 찾거나, 신호의 주기를 분석하는 방법이다. (H. Chen et al., 2024)의 연구처럼 스쿼트나 푸시업과 같이 명확하고 일정한 리듬을 가진 운동에서는 매우 효율적이고 빠르게 작동한다. 하지만 사용자가 지치거나 자세가 무너져 동작의 속도나 패턴이 불규칙해지면 정확도가 급격히 떨어지는 강건성 문제를 보인다.

딥러닝 모델(CNN, GCN, LSTM)은 (Li et al., 2023)의 ResGCN 모델처럼, 딥러닝은 비디오 시퀀스 전체의 시공간적 특징을 학습하여 불규칙하고 복잡한 패턴 속에서도 반복을 감지하는 능력이 뛰어나다. 그러나 이는 반복이라는 개념 자체를 데이터로부터 학습해야 하므로, 각기 다른 운동에 대한 방대한 양의 비디오 데이터가 필요하며, 이는 확장성의 큰 장벽으로 작용한다.

현재 기술은 명확한 주기성을 가진 운동에는 충분히 신뢰할 만한 성능을 보이지만, 버피 테스트나 케틀벨 스윙처럼 복합적이고 변칙적인 움직임이 많은 운동에서는 여전히 한계가 명백하다. 실용적인 시스템은 두 접근법을 결합한 하이브리드 방식 즉, 신호 처리로 명확한 주기를 먼저 감지하고, 감지가 어려운 구간에서만 딥러닝 모델을 보조적으로 사용하는 방식이 효과적일 수 있다.

## 3. RQ3 - 운동 범위 분석: 연구가 부족한 미개척 분야

운동 범위 분석(RoM: Range of Motion)은 단 4개(9%)의 연구만이 다룰 정도로 가장 연구가 미진한 분야이다. 이는 2D 이미지 한 장에서 3차원 공간의 움직임 깊이(depth)를 정확히 추정하는 것이 기술적으로 매우 어렵기 때문이다. 대부분의 연구

는 (Rosique et al., 2021)의 사례처럼 측면 영상에서 관절 각도를 측정하는 수준에 머물러 있으며, 이는 카메라의 위치와 각도에 매우 민감하여 일반 사용 환경에 적용하기 어렵다. (Parmar et al., 2022)의 자기 지도 학습(self-supervised learning) 접근은 레이블링 비용 없이 데이터의 잠재적 특징을 학습하려는 시도라는 점에서 주목할 만하지만, 아직 초기 단계에 머물러 있다.

ROM 분석의 부재는 AI 코칭 시스템의 반쪽짜리 성공을 의미한다. 단순히 자세가 맞고 횡수를 세는 것을 넘어, 충분히 깊게 앉았는지, 팔을 완전히 펴는지를 평가하지 못하면 운동의 질을 보장할 수 없다. 이 분야의 발전을 위해서는 단일 2D 카메라의 한계를 인정하고, 여러 시점의 영상을 활용하거나, 사용자의 신체 비율 등을 사전 정보로 활용하여 3D 자세를 재구성하는 연구가 시급하다.

#### 4. RQ4 - 운동 인식: 데이터 효율성과 일반화 성능의 균형

사용자가 어떤 운동을 하는지 자동으로 분류하는 운동 인식은 개인화된 코칭의 시작점이다. 이 기능은 주로 두 가지 상반된 접근법으로 나뉜다.

동적 시간 왜곡(DTW) 기반 방법은 미리 저장된 표준 운동 템플릿과 사용자의 실시간 동작 시퀀스를 비교하여 가장 유사한 템플릿을 찾는 방식이다. 가장 큰 장점은 데이터 효율성이다. 단 몇 개의 시연 영상만으로도 새로운 운동을 시스템에 추가할 수 있어, 프로토타이핑이나 사용자 맞춤형 운동 추가 기능에 매우 유리하다. (Yeh & Yang, 2025)의 연구는 일부 동적 운동에서 99%의 높은 정확도를 달성하며 그 가능성을 보여주었다. 하지만 템플릿에 의존하기 때문에, 사용자의 개인적인 스타일, 속도, 체형 등 템플릿에 없는 다양한 변형에 매우 취약하며, 운동 종류가 많아질수록 비교해야 할 템플릿이 늘어나 확장성이 떨어지는 한계가 있다.

신경망 기반 방법(CNN, RNN 등)은 대규모 데이터셋으로부터 운동 동작의 핵심적인 시공간적 특징을 직접 학습한다. (Alatiah & Chen, 2020),

(Riccio, 2024) 등의 연구에서 보고된 98% 이상의 높은 정확도는 신경망이 다양한 사용자와 환경에서도 강건한 일반화 성능을 보일 잠재력이 있음을 시사한다. 하지만 이는 대규모 데이터셋에 대한 극심한 의존성이라는 명확한 단점을 동반한다. 수십, 수백 가지의 운동을 인식하는 상용 시스템을 만들기 위해서는 각 운동마다 수 천 개의 비디오 데이터가 필요하며, 이는 엄청난 데이터 수집 및 레이블링 비용을 발생시킨다. 또한, 모델이 프레임 단위로 독립적인 분석을 수행하여 시간적 맥락을 완전히 활용하지 못하는 경우도 있다.

실용적인 관점에서 운동 인식 기능은 명확한 트레이드오프 관계에 놓여 있다. 적은 데이터로 빠르게 시작하고 싶다면 DTW가, 다수의 사용자를 대상으로 한 확장성 있고 강건한 서비스를 원한다면 신경망이 적합하다. 이상적인 시스템은 두 가지를 결합하여, 신경망으로 대중적인 운동들을 인식하되, 사용자가 직접 시연하여 새로운 운동을 추가하는 온디바이스 개인화(On-device Personalization) 기능에는 DTW를 활용하는 하이브리드 전략을 취할 수 있다.

#### 5. RQ5 - 배포 준비성: 파편화된 기능에서 통합 시스템으로

궁극적으로 AI 피트니스 기술의 가치는 실제 사용자의 기기에서 얼마나 안정적이고 통합적인 경험을 제공하는지에 달려 있다. 하지만 현재 연구들은 이 최종 목표와 상당한 거리가 있다.

본 리뷰에서 가장 충격적인 발견은, 자세 교정, 반복 횟수, ROM 분석이라는 핵심 기능을 하나의 파이프라인으로 통합한 연구가 단 한 편도 없었다는 점이다. 대부분의 연구는 단일 기능만을 구현한 프로토타입에 머물러 있다. 이는 현재 연구가 기술 시연 단계에 있으며, 실제 사용자가 필요로 하는 종합 코칭 솔루션과는 거리가 멀다는 것을 의미한다.

다수의 연구가 실시간 작동을 주장하지만, 그 정의는 제각각이다. 대부분 고사양의 GPU를 탑재한

데스크톱 환경에서 실험이 이루어졌으며, 일반적인 스마트폰이나 웹캠 환경에서의 구체적인 성능 지표(FPS, 지연 시간)를 투명하게 공개한 연구는 거의 없었다. 이로 인해 실제 소비자 기기에서의 사용성을 예측하기가 매우 어렵다.

대부분의 시스템은 2개에서 8개 사이의 극히 제한된 운동 종류에 대해서만 테스트되었다. 이는 단순히 게으름의 문제가 아니라, 운동의 종류가 늘어날수록 데이터 수집 및 레이블링 비용이 기하급수적으로 증가하고, 운동마다 다른 신체 역학을 모두 처리할 수 있는 단일 모델을 설계하기가 어렵기 때문이다.

현재 AI 피트니스 연구는 제품이 아닌 부품을 만드는데 집중하고 있다. 개별 모델의 정확도를 높이는 학술적 성과는 많지만, 이들을 하나의 안정적인 애플리케이션으로 통합하고, 다양한 하드웨어에서 효율적으로 실행되도록 최적화하며, 끊임없이 추가되는 새로운 운동에 대응하는 소프트웨어 공학적, 시스템 아키텍처적 고민은 심각하게 부족한 상황이다. 진정한 배포 준비성을 갖추기 위해서는 개별 알고리즘 연구를 넘어, 모듈화된 파이프라인 설계, 모델 경량화, 그리고 지속적인 데이터 관리 및 업데이트를 포괄하는 시스템 레벨의 접근이 시급하다.

## V. 논의

### 1. 데이터셋과 평가 기준의 근본적 한계

본 리뷰의 모든 연구 성과를 비판적으로 바라봐야 하는 이유는 그 기반이 되는 데이터셋과 평가 방식의 한계 때문이다. 대부분의 연구는 통제된 실험실 환경에서, 소수의 건강한 젊은 참가자를 대상으로, 제한된 운동 종류에 대해서만 촬영된 데이터를 사용한다 (예: Yoga-82, Rep-Penn).

이는 크게 세 가지 심각한 일반화(Generalization) 문제를 야기할 수 있다. 우선, 환경 편향 문제를 들 수 있다. 즉, 다양한 조명, 복잡한 배경, 가구로 인한 가림(occlusion) 등 실제 가정 환경의 변수를 모델이 학습하지 못한다. 다음으

로, 사용자 편향 문제를 들 수 있다. 다양한 인종, 체형, 연령, 유연성 수준을 가진 사용자에 대한 성능을 보장할 수 없다. 현재 모델들은 이상적인 자세만을 정답으로 학습했을 가능성이 높다. 마지막으로, 운동 편향 문제를 들 수 있다. 스쿼트, 런지 등 일부 대중적인 운동에 데이터가 집중되어 있어, 요가, 필라테스, 재활 운동 등 다른 영역으로의 확장이 어렵다.

또한, 평균 절대 오차(MAE), OBO(Off-By-One) 정확도 등 표준화되지 않은 평가 지표는 연구 간의 공정한 성능 비교를 어렵게 만든다. 정확도 95%라는 수치가 실제 사용자 환경에서도 동일하게 재현될 것이라고 기대하기 어려운 이유이다.

### 2. 배포 준비성의 현실

아무리 정확한 모델이라도 실제 사용자의 기기에서 원활하게 작동하지 않으면 무용지물이다. 배포 준비성의 한계에 대해서 크게 세 가지로 정리해 보았다.

우선, 과편화된 기능을 들 수 있다. 본 리뷰에서 자세교정, 반복 횟수, ROM 분석을 모두 통합한 완전한(end-to-end) 시스템을 제시한 연구는 단 한 편도 없었다. 대부분의 연구는 단일 기능 구현에 그쳐, 통합적인 코칭 경험을 제공하지 못한다. 다음으로, 실시간 성능의 불확실성을 들 수 있다. 약 25개의 연구가 실시간을 주장했지만, 대부분 고사양 GPU 환경에서 테스트되었으며, 일반 스마트폰이나 노트북 내장 그래픽에서의 구체적인 FPS(초당 프레임) 정보를 제공하는 경우는 드물었다. 이는 실제 배포 시 심각한 성능 저하로 이어질 수 있다. 마지막으로, 공통된 실패 사례를 들 수 있다. 논문들이 명시적으로 다루지는 않지만, 표 1의 한계점들을 종합하면 가림(Occlusion), 특이 시점(Unusual Viewpoints), 빠른 움직임(Fast Motion), 그리고 의상 및 체형으로 공통된 실패 시나리오를 유추할 수 있다. 여기서, 가림은 신체 일부가 다른 신체 부위나 사물에 가려질 때 키포인트 추정에 실패하는 것을 의미하고, 특이 시점은 정면이나 측면

이 아닌 애매한 각도에서 촬영된 경우 정확도가 급격히 하락하는 것을 의미한다. 빠른 움직임은 모션 블러(motion blur)로 인해 프레임 단위 분석이 실패할 수 있다는 것을 의미하고, 의상 및 체형은 험령한 옷이나 비표준적인 체형은 키포인트 예측을 방해할 수 있다는 것을 의미한다.

## VI. 결론 및 미래 연구를 위한 로드맵

지난 5년간 인체 자세 추정을 이용한 AI 피트니스 코칭 연구는 괄목할 만한 성과를 거두었다. 하지만 본 리뷰에서 심층적으로 분석한 바와 같이, 현재 기술은 대부분 개념 증명(Proof-of-Concept) 단계를 벗어나지 못하고 있으며, 실제 사용자가 신뢰하고 사용할 수 있는 제품으로 발전하기까지는 여러 난관이 남아있다.

단순히 더 큰 데이터셋이나 더 좋은 모델을 외치는 것을 넘어, 다음과 같은 구체적인 연구 로드맵도 제안해 본다.

### ■ 데이터 문제 해결을 위한 패러다임 전환

- 자기/준지도 학습 도입 [44]~[48]

레이블이 없는 대규모 비디오 데이터로부터 먼저 움직임의 일반적인 패턴을 학습하고, 소량의 레이블 데이터로 특정 운동을 미세 조정(fine-tuning)하는 방식을 통해 데이터 수집 비용을 획기적으로 줄여야 한다.

- 합성 데이터(Synthetic Data)의 고도화 [49]
- 실제와 유사한 가상 환경에서 다양한 체형, 의상, 조명, 배경을 가진 3D 아바타를 생성하여 모델의 강건성과 일반화 성능을 높여야 한다.

### ■ 사용자 중심의 하이브리드 모델 설계

- 규칙-딥러닝 결합 [49]

스쿼트의 무릎이 발끝을 넘지 않도록과 같은 명확한 생체역학적 규칙은 하드 제약(Hard Constraint)으로 시스템에 내장하고, 딥러닝 모델은 사용자의 미묘한 움직임 패턴을 분석하는 소프트 제약(Soft Constraint)으로 활용하는 하이브리드 모델을 개발해야 한다. 이는 모델의 예측 안정성과 해석 가능성을 동시에 높일 수 있다.

### ■ 실용적 배포를 위한 표준화 노력

- 공개 벤치마크 데이터셋 구축 [48]

In-the-wild 환경(실제 가정집, 다양한 기기)에서 촬영된, 다양한 인구 통계학적 특성을 포함하는 표준 벤치마크 데이터셋을 구축하고 공유해야 한다.

- 성능 평가 지표 표준화 [44]~[47]

모델의 정확도뿐만 아니라, 특정 하드웨어(예: Apple A-Series, Qualcomm Snapdragon)에서의 FPS, 메모리 사용량, 전력 소모량을 함께 보고하도록 표준화하여 실질적인 배포 가능성을 평가해야 한다.

AI 피트니스 코칭은 거대한 잠재력을 가지고 있다. 이 잠재력을 현실로 만들기 위해서는 실험실의 이상적인 환경을 벗어나, 실제 사용자의 다양성과 현실 세계의 복잡성을 포용하는 방향으로 연구의 초점이 이동해야 할 것이다. 본 논문이 그 여정에 의미 있는 이정표가 되기를 바란다.

## 사 사

본 연구는 한국연구재단 지역대학우수과학자 지원 사업(Grant Number: NRF-2021R1I1A3055210)과 전남대학교 교내 중견연구(해외공동연구) 지원(No. 2024-1159-01) 사업의 지원을 받아 수행되었다.

## REFERENCES

- [1] F. Roggio, B. Trovato, M. Sortino, and G. Musumeci, G. "A comprehensive analysis of the machine learning pose estimation models used in human movement and posture analyses: A narrative review," *Heliyon*, vol. 10, no. 21, 2024.
- [2] J. Stenum, K.M. Cherry-Allen, C.O. Pyles, R.D. Reetzke, M.F. Vignos, and R.T. Roemmich, "Applications of pose estimation in human health and performance across the lifespan," *Sensors*, vol. 21, no. 21, 2021.
- [3] A. Tharatipyakul, T. Srikaewsiew, and S. Pongnumkul, "Deep learning-based human body pose estimation in providing feedback for physical movement: A review," *Heliyon*, vol. 10, no. 17, 2024.

- [4] C. Mennella, U. Maniscalco, G. De Pietro, and M. Eposito, "The Role of Artificial Intelligence in Future Rehabilitation Services: A Systematic Literature Review," *IEEE Access*, vol. 11, pp. 11024 - 11043, 2023.
- [5] S. Salisu, K.U. Danyaro, M. Nasser, I.M. Hayder, and H.A. Younis, "Review of models for estimating 3D human pose using deep learning," *PeerJ Computer Science*, 11, 2025.
- [6] M.J. Page, J.E. McKenzie, P.M. Bossuyt, I. Boutron, T.C. Hoffmann, C.D. Mulrow, I. Shamseer, J.M. Tetzlaff, E.A. Akl, S.F. Brennan, R. Chou, J. Glanville, J.M. Grimshaw, A. Hróbjartsson, M.M. Lalu, T. Li, E.W. Loder, E. Mayo-Wilson, S. McDonald, and D. Moher, "The PRISMA 2020 statement: An updated guideline for reporting systematic reviews," *BMJ*, vol. 372, 2021.
- [7] Z. Zhao, S. Kiciroglu, H. Vinzant, Y. Cheng, I. Katircioglu, M. Salzmann, and P. Fua, "3D Pose Based Feedback for Physical Exercises," *arXiv:2208.03257*, 2022.
- [8] R. Gajbhiye, S. Jarag, P. Gaikwad, and S. Koparde, "AI Human Pose Estimation: Yoga Pose Detection and Correction," *International Journal of Innovative Science and Research Technology*, vol. 7, no. 5, 2022.
- [9] H.A. Hassan, R. Osama, A. Aal, W.H. El-Behaidy, B.H. Abdallah, R.R. Numan, A.A. Abdallah, and A.K. Darwish, "Automatic Feedback For Physiotherapy Exercises Based On PoseNet," *International Journal of the bulletin of informatics*, vol. 2, no. 2, 2020.
- [10] A. Rahmadani, B.S.B. Dewantara, and D.M. Sari, "Human Pose Estimation for Fitness Exercise Movement Correction," *IES 2022 - 2022 International Electronics Symposium: Energy Development for Climate Change Solution and Clean Energy Transition, Proceeding*, pp. 484 - 490, 2022.
- [11] A. Raza, A.M. Qadri, I. Akhtar, N.A. Samee, and M. Alabdulhafith, "LogRF: An Approach to Human Pose Estimation Using Skeleton Landmarks for Physiotherapy Fitness Exercise Correction," *IEEE Access*, vol. 11, 2023.
- [12] G. Delmas, P. Weinzaepfel, F. Moreno-Noguer, and G. Rogez, "PoseFix: Correcting 3D Human Poses with Natural Language," *arXiv:2309.08480*, 2023.
- [13] Y.M. Ko, A. Nasridinov, and S.H. Park, "Real-Time AI Posture Correction for Powerlifting Exercises Using YOLOv5 and MediaPipe," *IEEE Access*, vol. 12, 2024.
- [14] M. Fieraru, M. Zanfir, S. Cristian Pirlea, V. Olaru, and C. Sminchisescu, "AIFit: Automatic 3D Human-Interpretable Feedback Models for Fitness Training," *2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2021.
- [15] T. Hande, B. Kakirwar, A.V. Bharadwaja, P. Kshirsagar, A. Gupta, and P. Vijayakumar, "Correction and Estimation of Workout Postures with Pose Estimation using AI," *Proceedings of the International Conference on Intelligent and Innovative Technologies in Computing, Electrical and Electronics, ICIITCEE 2023*, pp. 247 - 253, 2023.
- [16] H. Kotte, F. Daiber, M. Kravcik, and N. Duong-Trung, "FitSight: Tracking and Feedback Engine for Personalized Fitness Training," *UMAP 2024 - Proceedings of the 32nd ACM Conference on User Modeling, Adaptation and Personalization*, pp. 223 - 231, 2024.
- [17] S. Chen, and R.R. Yang, "Pose Trainer: Correcting Exercise Posture using Pose Estimation," *arXiv:2006.11718*, 2006.
- [18] G.S.J. Hsu, J.S. Wu, Y.K.D. Huang, C.C. Chiu, and J.H. Kang, "Automatic Detect Incorrect Lifting Posture with the Pose Estimation Model," *Life*, vol. 15 no. 3, 2025.
- [19] R. Gadhvi, P. Desai, and Siddharth, "PosePilot: An Edge-AI Solution for Posture Correction in Physical Exercises," *arXiv:2505.19186*, 2025.
- [20] P. Rao, C.S. Asha, and P.R. Rao, "Real-Time Posture Correction of Squat Exercise: A Deep Learning Approach for Performance Analysis and Error Correction," *IEEE Access*, vol. 13, pp. 39557 - 39571, 2025.
- [21] S. Agarwal, M. Gupta, S. Khandelwal, P. Jain, A. Aggarwal, D. Singh, and V.K. Mishra, "FitMe: A Fitness Application for Accurate Pose Estimation Using Deep Learning," *ICSCCC 2021 - International Conference on Secure Cyber Computing and Communications*, pp. 232 - 237, 2021.
- [22] J. Liu, N. Saquib, Z. Chen, R.H. Kazi, L.Y. Wei, H. Fu, and C.L. Tai, "PoseCoach: A Customizable Analysis and Visualization System for Video-based Running Coaching," *arXiv:2204.08805*, 2023.
- [23] J. Park, S.Y. Chung, and J.H. Park, "Real-Time Exercise Feedback through a Convolutional Neural Network: A Machine Learning-Based Motion-Detecting Mobile Exercise Coaching Application," *Yonsei Medical Journal*, vol. 63, pp. S34 - S42, 2022.

- [24] B. Dittakavi, D. Bavikadi, S. Vikas Desai, S. Chakraborty, N. Reddy, V.N. Balasubramanian, B. Callepalli, and A. Sharma, "Pose Tutor: An Explainable System for Pose Correction in the Wild," *2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshop (CVPRW)*, pp. 3539-3548, 2022.
- [25] U. Dedhia, P. Bhoir, P. Ranka, and P. Kanani, "Pose Estimation and Virtual Gym Assistant Using MediaPipe and Machine Learning," *2023 International Conference on Network, Multimedia and Information Technology, NMITCON 2023*.
- [26] A. Jaiswal, G. Chauhan, and N. Srivastava, "Using Learnable Physics for Real-Time Exercise Form Recommendations," *Proceedings of the 17th ACM Conference on Recommender Systems, RecSys, 2023*.
- [27] P. Parmar, A. Gharat, and H. Rhodin, "Domain Knowledge-Informed Self-Supervised Representations for Workout Form Assessment," *arXiv:2202.14019, 2022*.
- [28] M. Sideridou, E. Kouidi, V. Hatzitaki, and I. Chouvarda, "Towards Automating Personal Exercise Assessment and Guidance with Affordable Mobile Technology," *Sensors*, vol. 24, no. 7, 2024.
- [29] H. Chen, M.C. Leu, M. Moniruzzaman, Z. Yin, and S. Hajmohammadi, "Advancements in Repetitive Action Counting: Joint-Based PoseRAC Model With Improved Performance," *arXiv:2308.08632, 2024*.
- [30] Y. Chen, and X. Liu, "Design of Fitness Movement Detection and Counting System Based on MediaPipe," *Communications in Computer and Information Science, 1880 CCIS*, pp. 77 - 92, 2023.
- [31] N. Sonwani, and A. Pegwar, "Auto\_Fit: WORKOUT TRACKING USING POSE-ESTIMATION AND DNN," *International Journal of Engineering Applied Sciences and Technology*, vol. 5, 2020.
- [32] B. Ferreira, P.M. Ferreira, G. Pinheiro, N. Figueiredo, F. Carvalho, P. Menezes, and J. Batista, "Deep learning approaches for workout repetition counting and validation," *Pattern Recognition Letters*, vol. 151, pp. 259 - 266, 2021.
- [33] R. Renugadevi, P. Arul, V. Subashree, G. Sathi, M. Dharmateja, and G. Indhumathi, "Deep Learning-Based GYM Monitoring System using YOLOv5 and Pose Estimation Algorithm," *7th International Conference on Electronics, Communication and Aerospace Technology, ICECA 2023 - Proceedings*, pp. 697 - 702, 2023.
- [34] F. Japhne, K. Janada, A. Theodorus, and A. Chowanda, "Fitcam: detecting and counting repetitive exercises with deep learning," *Journal of Big Data*, vol. 11, no. 1, 2024.
- [35] C. Li, M. Shao, Q. Yang, and S. Xia, "High-precision skeleton-based human repetitive action counting," *IET Computer Vision*, vol. 17, no. 6, 2023.
- [36] A. Postlmayr, B. Garg, P. Cosman, and S. Dey, "PersonalPT: One-shot approach for skeletal-based repetitive action counting for physical therapy," *Smart Health*, vol. 34, 2024.
- [37] A. Sinclair, K. Kautai, and S.R. Shahamiri, "Puioio: On-device Real-Time Smartphone-Based Automated Exercise Repetition Counting System," *arXiv:2308.02420, 2023*.
- [38] Q. Yu, H. Wang, F. Laamarti, and A. El Saddik, "Deep learning-enabled multitask system for exercise recognition and counting," *Multimodal Technologies and Interaction*, vol. 5, no. 9, 2021.
- [39] R. Riccio, "Real-Time Fitness Exercise Classification and Counting from Video Frames," *arXiv:2411.11548, 2024*.
- [40] T. Alattia, and C. Chen, "Recognizing Exercises and Counting Repetitions in Real Time," *arXiv:2005.03194, 2020*.
- [41] F. Rosique, F. Losilla, and P.J. Navarro, "Applying vision based pose estimation in a telerehabilitation application," *Applied Sciences (Switzerland)*, vol. 11, no. 19, 2021.
- [42] S.C. Yeh, and C.K. Yang, "Yoga pose recognition and motion analysis for a home-based fitness monitoring and health management system," *Signal, Image and Video Processing*, vol. 19, no. 10, 2025.
- [43] H. Ji, K.S. Githinji, T. Kenji, "AI Fitness Coach at Home using Image Recognition," *International Journal of Human Movement and Spots Sciences*, vol. 11, no. 4, pp. 850-857, 2023.
- [44] T. Wang, H. Jeong, M. Watanabe, Y. Iwatani, and Y. Ohno, "Fault classification with discriminant analysis during sit-to-stand movement assisted by a nursing care robot," *Mechanical Systems and Signal Processing*, vol. 113, pp. 90-101, 2018.
- [45] T. Wang, H. Jeong, and Y. Ohno, "Evaluation of Self-Reliance Support Robot Through Relative Phase," *IEEE Access*, vol. 5, pp. 17816-17823, 2017.
- [46] Y. Woo, and H. Jeong, "Velocity-based training assessment: Effect of

Extended-Relative-Phase-based extracted features on classification,” 30<sup>th</sup> ACM KDD Conference on Knowledge Discovery and Data Mining (KDD) Workshop (AIDSH), 2024.

- [47] Y. Woo, and H. Jeong, “Exercise Assessment Based on Human Pose Estimation and Relative Phase for Real-Time Remote Exercise System,” *IEEE Access*, vol. 13, pp. 53203-53213, 2025.
- [48] Y. Woo, S. Ko, S. Ahn, H.T.P. Nguyen, C. Shin, H. Jeong, B. Noh, M. Lee, H. Park, and C. Youm, “Classification of Diabetic Walking for Senior Citizens and Personal Home Training System Using Single RGB Camera through Machine Learning,” *Applied Sciences*, vol. 11, no. 19, 2021.
- [49] H.T.P. Nguyen, Y. Woo, N.N. Huynh, and H. Jeong, “Scoring of Human Body-Balance Ability on Wobble Board Based on the Geometric Solution,” *Applied Sciences*, vol. 12, no. 12, 2022.



Okada Shima(정희원)

2000년 Faculty of Science and Engineering, Ritsumeikan University 학사 졸업.

2002년 Graduate School, Division of Science and Engineering, Ritsumeikan University 석사 졸업.

2006년 Division of Research and Development, Sanyo Electric Co., Ltd., 연구원.

2008년 Graduate School. Division of Medical Sciences, The University of Osaka, 박사 졸업.

2008년~ Graduate School. Division of Science and Engineering, Ritsumeikan University, 교수.

<주관심분야 : Biomedical Engineering, Sleep Research, Physical & Physiological Sensing>

#### 저자 소개



정희용(정희원)

2002년 8월 부경대학교 제어계측공학과 학사 졸업.

2004년 3월 Hiroshima University 로봇공학과 석사 졸업.

2009년 5월 The University of Osaka 기계공학과 박사 졸업.

2013년 11월 (주)삼성중공업 산업기술연구소 책임연구원.

2019년 8월 Graduate School of Medicine, The University of Osaka 부교수.

2019년 9월~ 전남대학교 인공지능학부 교수.

<주관심분야 : IoT시스템, 지능로봇, 헬스케어>



신춘성(정희원)

2010년 2월 광주과학기술원 정보통신공학과 박사 졸업.

2010년 11월 카네기멜론대학 HCI Institute 박사후연구원.

2013년 ~ 2019년 한국전자기술연구원 VR/AR연구센터 책임연구원.

2018년 ~ 2019년 문화체육관광부/

한국콘텐츠진흥원 문화기술PD.

2019년 9월~ 현재 전남대학교 문화전문대학원 미디어콘텐츠컬처테크전공 교수.

2020년 6월~ 현재 전남대학교 문화기술연구소장.

2023년 ~ 2024년 국가과학기술자문회의 ICT융합전문위원회 전문위원.

<주관심분야 : AR/VR/XR, 문화기술, 인간-컴퓨터 상호작용>

표 1. 자세 교정의 방법, 그리고 성과 및 한계를 기술한 마스터 비교표.

자세교정 (Pose Correction)				
No.	Author	Focus	Methods	Comments
1	(Zhao et al., 2022)[7]	Posture Correction	GCN	Achievement: The model's DTW loss is lower than the baseline, indicating better performance. Limitation: Framework struggles in correcting specific types of motions, such as not low enough lunges.
2	(Gajbhiye et al., 2022)[8]	Posture Correction	SVM, CNN	Achievement: The time-distributed CNN layer effectively minimized errors from false keypoint detection. Limitation: The CNN model indicated signs of overfitting.
3	(Hassan et al., 2020)[9]	Posture Correction	DTW-based	Achievement: The system offers an overall accuracy of 80% for providing correct feedback. Limitation: The system's feedback relies on video comparisons, which may vary in duration and actor positions, affecting accuracy.
4	(Rahmadani et al., 2022)[10]	Posture Correction	SVM	Achievement: The system achieved an accuracy of 96.87%. Limitation: The system may face issues with susceptibility to unrelated backgrounds during action recognition.
5	(Raza et al., 2023)[11]	Posture Correction	ML (LR, RF)	Achievement: Machine learning models outperform deep learning methods in human pose estimation tasks. Limitation: Low performance for human pose and gesture estimation when all dataset features are applied.
6	(Delmas et al., 2024)[12]	Posture Correction	ML (cVAE, Autoregressive Transformer)	Achievement: The system presented promising results for text-based pose editing and correctional text generation. Limitation: The added metrics rely on imperfect models, which have their own limitations.
7	(Ko et al., 2024)[13]	Posture Correction	ML, FCNN	Achievement: Machine learning models outperformed deep learning models for posture classification. Limitation: The study does not evaluate muscle engagement or activation patterns.
8	(Fieraru et al., 2021)[14]	Posture Correction, Repetition Counting	Angle-based	Achievement: Mean Absolute Error (MAE) reported as 0.253, and Off-By-One (OBO) error is 0.140. Limitation: Not mentioned in the paper.
9	(Hande et al., 2023)[15]	Posture Correction, Repetition Counting	Rule-based	Achievement: The model scored 97.25 % accuracy. Limitation: Side view evaluation produced noticeably lower ratings compared to frontal view.
10	(Kotte et al., 2024)[16]	Posture Correction, Repetition Counting	Angle-based	Achievement: The Feedback Group scored a mean of 42.1, outperforming the No Feedback Group's mean of 38.4. Limitation: The controlled study environment may not reflect real-world gym conditions.
11	(Chae et al., 2023)[17]	Posture Correction	LSTM + Convolution	Achievement: LSTM blocks and temporal convolution layers exhibited the highest performance with a test accuracy of 85%. Limitation: System might lack robustness based on camera positioning.
12	(Hsu et al., 2025)[18]	Posture Correction	BiLSTM	Achievement: High classification accuracy rates of 94.4% overall. Limitation: The classification model only defined correct and incorrect postures without further categorization.
13	(Gadhvi et al., 2025)[19]	Posture Correction	BiLSTM	Achievement: The paper claims a Pose Recognition accuracy of 97.52%. Limitation: The current system's latency needs optimization for better real-time performance on edge devices.

자세교정 (Pose Correction)				
No.	Author	Focus	Methods	Comments
14	(Rao et al., 2025)[20]	Posture Correction	LSTM (Bi-CGRU)	Achievement: The regression model for posture correction attained 99.0% accuracy using mean squared error loss. Limitation: The study's findings are based on squat analysis, limiting its applicability to other exercises.
15	(Agarwal et al., 2021)[21]	Posture Correction	Rule-based	Achievement: Results indicate high accuracy in pose estimation. Limitation: Compares static yoga poses, no feedback on technique.
16	(Liu et al., 2023)[22]	Posture Correction	Rule-based	Achievement: Success rates are 83.3%, 100%, and 91.7% for different attributes. Limitation: Changing viewpoints affect the accuracy of observational pose attributes.
17	(Park et al., 2022)[23]	Posture Correction	Rule-based	Achievement: MDMECA proved more effective than video streaming for improving quality of life and reducing pain. Limitation: The participant numbers in the MDMECA and control groups did not match 1:1, which is a limitation.
18	(Dittakavi et al., 2022)[24]	Posture Correction, Repetition Counting	CNN, KNN	Achievement: The system shows promising results on the Yoga-82 dataset. Limitation: The accuracy of the system can be improved by labeling keypoints for a small subset of train data.
19	(Dedhia et al., 2023)[25]	Posture Correction, Repetition Counting	ML (SVM, LR, NBC, DT)	Achievement: The logistic regression model achieved a 99% accuracy rate after hyperparameter tuning. Limitation: The small dataset size affects the results' accuracy.
20	(Jaiswal et al., 2023)[26]	Posture Correction, Repetition Counting	Peak Prominence, ML	Achievement: Best F1 score is achieved with Random Forest. Limitation: Reliance on pre-defined relational attributes for each exercise's Interaction Network.
21	(Parmar et al., 2022)[27]	Posture Correction, ROM Analysis	Self-supervised ML	Achievement: Self-supervised features outperformed HMR-TDM features on detecting KIE, CCRB, and KFE errors. Limitation: Manual annotation for domain-specific datasets requires significant resources and effort.
22	(Sideridou et al., 2024)[28]	Posture Correction, ROM Analysis, Exercise Recognition	Supervised ML	Achievement: Three machine learning classifiers achieved test-set accuracies between 94.76% and 100%. Limitation: The model's reduced performance in precise calculations limits its application suitability.

표 2. 반복 횟수 계산의 방법, 그리고 성과 및 한계를 기술한 마스터 비교표.

반복 횟수 계산(Repetition Counting)				
No.	Author	Focus	Methods	Comments
1	(H. Chen et al., 2024)[29]	Repetition Counting	Angle-based	Achievement: The results outperform previous state-of-the-art PoseRAC methods. Limitation: The paper does not explicitly state limitations of its own proposed method.
2	(Y. Chen & Liu, 2023)[30]	Repetition Counting	Angle-based	Achievement: Accuracy exceeded 90% during testing on a server platform. Limitation: System did not provide feedback when movements were performed incorrectly.
3	(Sonwani & Pegwar, 2020)[31]	Repetition Counting	CNN	Achievement: Validation accuracies reported as: Jumping jack 95%, and Shoulder lateral raise 86%. Limitation: Paper proposes only 2 exercises.
4	(Ferreira et al., 2021)[32]	Repetition Counting	CNN	Achievement: The model achieved over 92% precision in counting valid repetitions for 4 out of 5 exercises. Limitation: The system's ability to detect invalid repetitions may have limitations in accuracy.
5	(Renugadevi et al., 2023)[33]	Posture Correction	Rule-based	Achievement: Proposed Method claims to achieve 93% accuracy. Limitation: Not mentioned in the paper.
6	(Japhne et al., 2024)[34]	Exercise Recognition, Repetition Counting	LSTM, ML	Achievement: The neural network model achieved over 90% accuracy for evaluating exercise poses. Limitation: A large dataset and training is needed for each exercise.
7	(Li et al., 2023)[35]	Repetition Counting	GCN	Achievement: The proposed model achieved better results in counting and clipping compared to existing methods. Limitation: Overfitting issues arise with excessive synthetic data, leading to poor generalization.
8	(Postlmayr et al., 2024)[36]	Repetition Counting	ML (GMM)	Achievement: OBO 0.81 MAE 0.99 on variations dataset is achieved. Limitation: The model struggles with generalization across different exercises.
9	(Dedhia et al., 2023)[25]	Posture Correction, Repetition Counting	ML (SVM, LR, NBC, DT)	Achievement: The logistic regression model achieved a 99% accuracy rate after hyperparameter tuning. Limitation: The small dataset size affects the results' accuracy.
10	(Sinclair et al., 2023)[37]	Repetition Counting	Lucas-Kanade Optical Flow	Achievement: The system achieved 98.89% accuracy in real-world tests. Limitation: Classification requires extensive training data, posing data collection challenges.
11	(Yu et al., 2021)[38]	Exercise Recognition, Repetition Counting	CNN	Achievement: The paper achieved 95.69% accuracy in exercise recognition on the Rep-Penn dataset. Limitation: Limitations of the datasets also apply to the model.
12	(Riccio, 2024)[39]	Exercise Recognition, Repetition Counting	CNN, BiLSTM	Achievement: The model achieved over 99% accuracy on the test set. Limitation: The model does not fully exploit temporal dependencies in exercise movements, treating frames independently.
13	(Alatiah & Chen, 2020)[40]	Exercise Recognition, Repetition Counting	DNN	Achievement: The proposed method achieved an accuracy of 98.4% in exercise recognition. Limitation: Performance is influenced by joint angle measurements and the effectiveness of data preprocessing techniques.

표 3. 운동 범위의 방법, 그리고 성과 및 한계를 기술한 마스터 비교표.

운동 범위(Range of Motion)				
No.	Author	Focus	Methods	Comments
1	(Rosique et al., 2021)[41]	ROM Analysis	Angle-based	Achievement: The measurement error committed by ExerCam is less than 3%. Limitation: Manual measurements may introduce bias errors.
2	(Parmar et al., 2022)[27]	Posture Correction, ROM Analysis	Self-supervised ML	Achievement: Self-supervised features outperformed HMR-TDM features on detecting KIE, CCRB, and KFE errors. Limitation: Manual annotation for domain-specific datasets requires significant resources and effort.
3	(Sideridou et al., 2024)[28]	Posture Correction, ROM Analysis, Exercise Recognition	Supervised ML	Achievement: Three machine learning classifiers achieved test-set accuracies between 94.76% and 100%. Limitation: The model's reduced performance in precise calculations limits its application suitability.
4	(Yeh & Yang, 2025)[42]	Exercise Recognition	DTW-based	Achievement: Dynamic actions like Knee Lifts and Bicep Curls reached 99.0% accuracy. Limitation: Accuracy is affected by inconsistent movement execution and background variation.

표 4. 운동 인식의 방법, 그리고 성과 및 한계를 기술한 마스터 비교표.

운동 인식(Exercise Recognition)				
No.	Author	Focus	Methods	Comments
1	(Gajbhiye et al., 2022)[8]	Posture Correction	SVM, CNN	Achievement: The time-distributed CNN layer effectively minimized errors from false keypoint detection. Limitation: The CNN model indicated signs of overfitting.
2	(Y. Chen & Liu, 2023)[30]	Repetition Counting	Angle-based	Achievement: Accuracy exceeded 90% during testing on a server platform. Limitation: System did not provide feedback when movements were performed incorrectly.
3	(Ji et al., 2022)[43]	Posture Correction	Rule-based	Achievement: The angle of the image affects the accuracy rate. Limitation: The prototype can only process two fitness poses: "wall-sit" and "plank".
4	(Renugadevi et al., 2023)[33]	Posture Correction	Rule-based	Achievement: Proposed Method claims to achieve 93% accuracy. Limitation: Not mentioned in the paper.
5	(Japhne et al., 2024)[34]	Exercise Recognition, Repetition Counting	LSTM, ML	Achievement: The neural network model achieved over 90% accuracy for evaluating exercise poses. Limitation: A large dataset and training is needed for each exercise.
6	(Dedhia et al., 2023)[25]	Posture Correction, Repetition Counting	ML (SVM, LR, NBC, DT)	Achievement: The logistic regression model achieved a 99% accuracy rate after hyperparameter tuning. Limitation: The small dataset size affects the results' accuracy.
7	(Yu et al., 2021)[38]	Exercise Recognition, Repetition Counting	CNN	Achievement: The paper achieved 95.69% accuracy in exercise recognition on the Rep-Penn dataset. Limitation: Limitations of the datasets also apply to the model.
8	(Riccio, 2024)[39]	Exercise Recognition, Repetition Counting	CNN, BiLSTM	Achievement: The model achieved over 99% accuracy on the test set. Limitation: The model does not fully exploit temporal dependencies in exercise movements, treating frames independently.
9	(Alatiah & Chen, 2020)[40]	Exercise Recognition, Repetition Counting	DNN	Achievement: The proposed method achieved an accuracy of 98.4% in exercise recognition. Limitation: Performance is influenced by joint angle measurements and the effectiveness of data preprocessing techniques.
10	(Yeh & Yang, 2025)[42]	Exercise Recognition	DTW-based	Achievement: Dynamic actions like Knee Lifts and Bicep Curls reached 99.0% accuracy. Limitation: Accuracy is affected by inconsistent movement execution and background variation.