

비전 기반 실내 스포츠를 위한 동작 특징 분석 및 동작 분류 방법

박철우¹, 김휘강^{2*}, 이상범², 김규형², 이성학¹

¹ 경북대학교, ² 한국전자통신연구원

potatotommy@gmail.com, {hwigangkim*, sblee230, jaykim}@etri.re.kr, shak2@ee.knu.ac.kr

Motion features analysis and motion classification method for vision-based indoor sports

Cheul Woo Park¹, Hwi-Gang Kim^{2*}, Sangbeom Lee², Kyu Hyung Kim², Sung-Hak Lee¹

¹ School of Electronics Engineering, Kyungpook National University,

² Electronics and Telecommunications Research Institute

요 약

본 논문은 카메라를 활용한 비전 기반의 동작 특징 분석 및 동작 분류 방법과 관련한 것으로, 이는 실내 스포츠를 지원하는 u-헬스케어 시스템의 개발을 목적으로 하며 사용자의 동작에 대한 평가 및 시각화 방법을 포함한다. 이와 관련하여 본 논문에서는 사용자의 스켈레톤으로부터 동작 분류에 핵심적인 18 개의 특징들을 정의하였으며, Dynamic Time Warping 알고리즘을 사용하여 각 동작에 따른 특징들의 시계열 데이터 사이 유사도를 계산하여 이를 바탕으로 사용자의 동작을 분류하였다. 또한 분류한 동작에 대하여 유의미한 매칭 점수를 산출하고, 각 동작 특징에 대한 매칭 점수를 시각화하여 사용자에게 동작에 대한 피드백을 제공함으로써 보다 효과적이고 능동적인 실내 스포츠 서비스의 제공이 가능할 것으로 보인다.

I. 서 론

최근 의료계 및 관련 행정기관에서는 u-헬스케어에 대한 인식과 관심이 증가함에 따라 u-헬스케어 활성화의 필요성을 인지하고 구체적인 실천방안을 모색하고 있다. 기존 u-헬스케어 장비들은 사람의 동작을 평가하기 위해 사용자의 신체에 별도의 센서를 부착하거나 직접 장비를 만져야 하는 등 한계가 있어 서비스 제공 동작에 제약이 있었다. 이러한 문제들을 해결하기 위해 카메라를 이용한 자세 추정 기반의 다양한 시스템들이 개발되고 있으며, 이를 위하여 사용자의 움직임을 분석, 분류 및 평가하는 방법들의 고도화 또한 요구되고 있다.

이와 관련하여 영상에서 사람의 키포인트를 추출하는 비전 기반의 자세 추정 기술들은 OpenPose, MediaPipe 등과 같이 딥러닝 기반 방법들이 많이 소개되고 있으며 [1, 2], 이를 활용한 서비스를 위해 사용자로부터 추출한 스켈레톤 정보로 동작을 정확하고 효율적으로 분석, 분류 및 평가하는 기술들도 활발하게 연구되고 있다. Xiaoqun Yu 외 연구진들은 노인들의 재택 재활 운동을 위하여 8 개의 스켈레톤 벡터를 특징으로 하여 특징 간 유사도를 계산함으로써 사용자의 동작을 평가하는 Dynamic Time Warping (DTW) 기반의 알고리즘을 제안하였으며, 이 때 사용한 DTW 알고리즘은 속도 또는 길이가 다른 두 시계열 데이터 간의 유사성(거리)을 측정하는 대표적인 알고리즘으로 시간에 대하여 연속적인 동작에 이산 비교 알고리즘을 적용하게 되면 동작의 연속성과 속도에 대한 정보를 잃어버리게 되므로 동작의 시차 및 속도 변화를

고려하여 가이드 동작과 사용자 동작 사이의 유사도를 평가하는데 사용되었다 [3].

본 논문에서는 딥러닝 기반의 자세 추정 알고리즘을 통하여 추출한 사용자의 스켈레톤으로부터 동작 분류에 핵심적인 동작 특징을 정의하고, 각 특징에 대한 시계열 데이터 간 DTW 거리값을 바탕으로 DTW 값들의 분포 및 이상치를 동시에 고려한 새로운 동작 분류 방법을 제안하였다. 또한 DTW 값 분포를 고려한 동작 일치율에 따른 평가 방법을 제안하여 동작 평가에 대한 신뢰도를 확보하였다. 본 방법은 보다 정확한 동작 분류 및 평가를 가능하게 하며, 이를 활용하여 보다 우수한 성능의 u-헬스케어 시스템의 개발이 가능할 것으로 기대된다.

II. 본 론

일반적으로 딥러닝 기반의 자세 추정 알고리즘을 통해 획득한 인체에 대한 키포인트는 그림 1 의 파란 점들과 같고, 얼굴 내 키포인트들을 제외하고 신체의 관절들을 연결하여 영상 내 사용자에게 대한 스켈레톤 구조를 얻게 된다. 본 연구에서는 각 키포인트 정보로부터 얻을 수 있는 동작의 특징들을 기반으로 동작을 분석하여 이를 분류하고 평가하고자 하였으며, 이를 위하여 그림 1 과 같이 총 18 개의 특징들을 정의하였다. 동작 특징들은 크게 두 키포인트 사이의 거리와 세 키포인트로 이뤄진 각도 두가지로 구분되며, 각 동작 특징들은 본 연구에서 사전 정의한 동작들을 수행함에 있어 결정적인 움직임이 될 수 있는 특징들로 제한하여 선택하였다.




그림 1. 동작 특징 (총 18 개, 거리 특징 12 개 (주황) 및 각도 특징 6 개 (초록))

다음으로 사전 정의한 동작 수행에 따른 위 특징들의 변화를 시계열 데이터로 표현하면 그림 2 와 같고, 본 논문에서 정의한 동작들은 i) 팔벌러뛰기 (Jumping jack), ii) 숄더 프레스 (Shoulder press), iii) 사이드 니업 (Side knee up)으로 3 가지이다. 이 때, 각 동작의 한 주기에 대한 6, 13 번에 해당하는 특징의 시계열 데이터를 보면, 동작 i)의 경우, 팔을 머리위로 올렸다가 내림에 따라 손목-골반의 거리가 증가했다가 감소하며, 동작 ii)의 경우, i) 과 유사하게 손목-골반의 거리가 증가했다 감소하지만, 동작 시작에 있어 팔이 머리 위에서 올라갔다 내려오기 때문에 거리 변화의 폭이 작고 일정한 거리에 해당하는 오프셋이 있는 것을 확인할 수 있다. 동작 iii)의 경우, 두 손을 머리 뒤로 한 채 몸의 양 옆으로 팔꿈치와 무릎을 닿게 하는 동작으로 손목-골반의 거리가 크게 변화없이 일정하게 유지되다가 팔꿈치와 무릎이 닿는 시점에 잠깐 감소하는 것을 볼 수 있다. 또한 13 번 특징은 동작 i)의 경우, 양 팔을 곧게 편 상태로 동작을 수행하기 때문에 팔꿈치의 각도가 180°로 유지되는 것을 볼 수 있으며, 동작 ii)의 경우 동작 시작 시 팔을 굽힌 상태에서 팔을 위로 곧게 폈다가 다시 내리는 동작으로 팔꿈치 각도가 90°에서 180°, 다시 90°로 변하는 것을 확인할 수 있다. 동작 iii)의 경우, 두 손이 머리 뒤에 고정되어 있으므로 팔꿈치의 각도가 90°이하의 예각으로 항상 일정한 것을 확인할 수 있다. 이와 같이 각 동작에 따른 사전 정의한 동작 특징의 변화에 대한 그래프가 고유한 형태를 띠는 것을 볼 수 있으며, 다른 동작에 대해서는 분명한 차이가 있는 것을 확인할 수 있다. 간혹 다른 동작을 수행함에 있어 일부 특징에 대한 변화가 유사하다 하더라도 그림 3 과 같이 위 정의한 다양한 특징들의 변화가 각 동작에 따라 고유한 형태를 갖기 때문에 이를 종합적으로 모두 비교함으로써 그 차이를 구분할 수 있게 된다. 따라서, 본 논문에서는 동작을 수행함에 따른 각 특징 변화에 대한 그래프의 형태들을 비교하여 사용자의 동작을 분류하고 평가하고자 한다.

다음으로 동작 분류 및 평가를 위해 앞서 설명한 것과 같이 각 특징 변화에 대한 그래프의 차이를 비교하여야 하는데, 이 때 동작 수행 시 필연적으로 발생하는 속도 차이에 의하여 각 그래프의 형태가 달라질 수 있어 본 논문에서는 시간 및 속도 차이에도 강건한 동작 비교를 위하여 DTW 알고리즘을 사용하였다. DTW 알고리즘을 사용하면 두 시계열 데이터를 비교함에 있어, 데이터 내 배열 순서를 고려하여 가장 유사한 형태를 갖는 부분을 서로 매칭하여 두 시계열 데이터 간 상관관계를 찾게 된다. 하지만 이 때 전혀 다른 두 시계열 데이터 간 비교 시에도 데이터 전체 범위를 대상으로 유사한 형태를 찾아 매칭함으로써 잘못된 매칭이 발생할 수 있는데, 대표적으로 동작의 시작과 끝 시점이 달라 시계열에 포함되는 머리, 꼬리 영역의 미세한 차이로 인해 DTW의 정확도가 크게 저하되는 경우를 들 수 있다. 따라서 이런 영역을 고려한 데이터 비교가 필요하며, 제안 방법에서는 이를 방지하기




그림 2. 동작 특징 시계열 데이터의 예 (6, 13 번)

위한 파라미터 튜닝을 포함하였다 [4, 5]. 이렇게 계산한 DTW 값은 두 시계열 데이터 사이의 차이를 의미하므로 그 값이 작을수록 유사한 데이터라고 볼 수 있다.

위의 설명과 같이 각 동작 특징 별 계산한 DTW 값을 기반으로 동작을 분류하기 위해서는, 수행한 동작이 사전 정의된 동작들 중 하나와 일치하는 경우 모든 특징들에 대한 DTW 값이 모두 충분히 작아야 하고, 하나의 동작 특징에서라도 DTW 값이 크면 정의되지 않은 동작이라고 간주해야 한다. 따라서 본 논문에서는 아래의 수식 1 과 같이 동작을 분류하게 된다.

$$Classification(X) = \begin{cases} X = G_i, & \text{if } \min(\mu_i) \text{ and } \max(DTW(G_{ij}, X_j)) \leq T_m \\ X = \text{other}, & \text{if } \max(DTW(G_{ij}, X_j)) > T_m \end{cases} \quad (1)$$

$$\text{where } \mu_i = \frac{\sum_{j=1}^N \{DTW(G_{ij}, X_j)\}}{N}, \quad \begin{cases} i : \text{number of motions} \\ N : \text{number of features} \end{cases}$$

위 수식 1 과 같이 동작의 분류는 동작 X 를 수행했을 때, 사전에 정의한 동작들 (G_i) 중 각 동작 특징들로부터 계산한 DTW 값의 평균이 가장 작은 동작 하나를 같은 동작으로 판단하여 분류하게 되며, 이 때 DTW 값들 중 최대값 또한 임계값(T_m)보다 작아야 한다. 만약 최대값이 임계값보다 크면 정의하지 않은 동작으로 분류하게 된다. 위 수식에서 DTW 값의 평균은 μ 로, i 는 동작의 수를, N 은 특징의 개수를 의미하며 본 논문에서는 i 는 3, N 은 18 이 된다.

마지막으로 위와 같이 분류한 동작에 대하여 사용자의 동작이 주어진 동작을 얼마나 잘 따라하는지 정량적으로 평가하기 위하여, 위 수식 1 의 평균값을 바탕으로 동작 분류 결과에 대한 일치율을 계산하고 이를 0 에서 100 사이의 점수로 환산하였다. 동작 평가 정량화를 위하여 만족해야 하는 조건은 DTW 값의 평균이 작을수록, 또한 DTW 가 전체적으로 작을수록, 즉 작은 값의 평균 DTW로부터 각각의 DTW 값의 편차가 작을수록 동작 점수가 높아야 한다. 이 때, DTW 값의 평균이 작더라도 일부 특징에서 DTW 값이 높은 경우, 즉 편차가 큰 특징이 있는 경우, 전체적인 동작은 잘 따라했지만 특정 부위의 동작을 제대로 수행하지 못한 것으로 보고 이를 반영해 낮은 점수를 부여할 수 있어야 한다. 이를 위하여 본 논문에서는 수식 2 와 같이 DTW 값의 편차에 가중치를 부여하는 방식으로 동작을 평가했으며, 최종적으로 수식 3 과 같이 이를 0 에서 100 사이의 점수로 환산하였다. 이 때, α_{scale} 은 평가값을 0 과 100 사이로 환산하기 위한 스케일 파라미터이다.

$$Eval(X_j) = \frac{\sum_{j=1}^N \{w_j \times DTW(G_{ij}, X_j)\}}{\sum_{j=1}^N w_j} \quad \text{where } w_j = e^{(DTW(G_{ij}, X_j) - \mu_i)} \quad (2)$$

$$Matching \ score = 100 \times \{1 - \frac{Eval(X_j)}{\alpha_{scale}}\} \quad (3)$$




그림 3. 동작 특징 시계열 데이터 (3 동작, 18 특징)

III. 시험 결과

본 논문에서는 제안한 방법의 성능을 확인하기 위하여 위 단락에 정의한 3 가지 동작에 대한 가이드를 기준으로, 사용자가 팔벌려뛰기(동작 i)를 수행했을 때의 동작 분류 및 평가 결과를 확인하였다.

그림 4 는 각 동작 특징들에 대한 DTW 값의 분포를 표현하였으며, 그림 4 와 같이 같은 동작을 수행했을 때 전체적인 DTW 값들이 작고 평균과의 편차 또한 작아 평균값 주변에 분포하고 있으며, 다른 동작을 수행하였을 때에는 평균이 상대적으로 크고 전체적인 DTW 값들이 아래 위로 넓게 퍼져 있는 것을 확인할 수 있다. 따라서 제안한 동작 분류 방법으로 사용자의 동작은 평균 DTW 가 최소값이고, DTW 값들 중 최대값이 임계값($T_m=5$)보다 작으므로 팔벌려뛰기 동작을 수행한 것으로 분류할 수 있다. 최종적으로 표 1 에서는 제안한 동작 일치도 평가 방법으로 환산한 각 동작들에 대한 정량적 평가 점수를 기록했다. 표 1 에서와 같이 주어진 동작과 같은 동작을 수행했을 때의 점수가 가장 높은 것을 확인할 수 있다.

IV. 결론

본 논문에서는 실내 스포츠를 위한 DTW 기반의 동작 분류 및 평가 방법을 제안하였으며, 이에 따른 결과들을 확인하였다. 결론적으로 본 논문의 방법은 보다 정확한 동작 분류 및 효과적인 동작 평가를 가능하게 하였으며, 이를 통하여 보다 우수한 성능의 u-헬스케어 시스템의 개발이 가능할 것으로 기대된다.




그림 4. 동작 특징들에 대한 DTW 값 분포 및 동작 분류 결과

표 1. 동작 일치도 평가 점수 결과

	Proposed Scoring
Jumping jack	97.132
Shoulder press	50.622
Side knee up	11.141

ACKNOWLEDGMENT

본 연구는 한국전자통신연구원 연구운영지원사업의 일환으로 수행되었음. [22ZD1140, 대경권 지역산업 기반 ICT 융합 기술 고도화 지원(의료)]

참 고 문 헌

- [1] Z. Cao, G. Hidalgo, T. Simon, S. Wei, and Y. Sheikh, "Realtime multi-person 2d pose estimation using part affinity fields," *2017 IEEE Conference on Computer Vision and Pattern Recognition*, pp. 7291-7299, 2017.
- [2] C. Lugaresi et al., "Mediapipe: A framework for building perception pipelines," *Third Workshop on Computer Vision for AR/VR at 2019 IEEE Conference on Computer Vision and Pattern Recognition*, 2019.
- [3] X. Yu and S. Xiong, "A Dynamic Time Warping Based Algorithm to Evaluate Kinect-Enabled Home-Based Physical Rehabilitation Exercises for Older People," *Sensors*, vol.19, no.13, pp.1-17, 2019.
- [4] Z. Geler et al., "Dynamic Time Warping: Itakura vs Sakoe-Chiba," *2019 IEEE International Symposium on Innovations in Intelligent Systems and Application*, pp.1-6, 2019.
- [5] D. Silva, G. Batista, and E. Keogh, "On the effect of endpoints on dynamic time warping," *SIGKDD Workshop on Mining and Learning from Time Series*, 2016.