

PoseNet과 GRU를 이용한 Skeleton Keypoints 기반 낙상 감지

강윤규¹, 강희용², 원달수^{3*}

¹송실대학교 대학원, ²송실대학교 정보과학대학원, ³배화여자대학교 스마트IT학과

Human Skeleton Keypoints based Fall Detection using GRU

Yoon Kyu Kang¹, Hee Yong Kang², Dal Soo Weon^{3*}

¹Department of ITPM, Graduate School, Soongsil University,

²Adjunct Professor, Information & Science Graduate School, Soongsil University

³Professor, Department of Smart IT, Baewha Womens University

요약 낙상 판단을 위한 최근 발표되는 연구는 RNN(Recurrent Neural Network)을 이용한 낙상 동작 특징 분석과 동작 분류에 집중되어 있다. 웨어러블 센서를 기반으로 한 접근 방식은 높은 탐지율을 제공하나 사용자의 착용 불편으로 보편화 되지 못했고 최근 영상이나 이미지 기반에 딥러닝 접근방식을 이용한 낙상 감지방법이 소개 되었다. 본 논문은 2D RGB 저가 카메라에서 얻은 영상을 PoseNet을 이용해 추출한 인체 골격 키포인트(Keypoints) 정보로 머리와 어깨의 키포인트들의 위치와 위치 변화 가속도를 추정함으로써 낙상 판단의 정확도를 높이기 위한 감지 방법을 연구하였다. 특히 낙상 후 자세 특징 추출을 기반으로 Convolutional Neural Networks 중 Gated Recurrent Unit 기법을 사용하는 비전 기반 낙상 감지 솔루션을 제안한다. 인체 골격 특징 추출을 위해 공개 데이터 세트를 사용하였고, 동작분류 정확도를 높이는 기법으로 코, 좌우 눈 그리고 양쪽 귀를 포함하는 머리와 어깨를 하나의 세그먼트로 하는 특징 추출 방법을 적용해, 세그먼트의 하강 속도와 17개의 인체 골격 키포인트가 구성하는 바운딩 박스(Bounding Box)의 높이 대 폭의 비율을 융합하여 실험을 하였다. 제안한 방법은 기존 원시골격 데이터 사용 기법보다 낙상 탐지에 보다 효과적이며 실험 환경에서 약 99.8%의 성공률을 보였다.

Abstract A recent study of people physically falling focused on analyzing the motions of the falls using a recurrent neural network (RNN) and a deep learning approach to get good results from detecting 2D human poses from a single color image. In this paper, we investigate a detection method for estimating the position of the head and shoulder keypoints and the acceleration of positional change using the skeletal keypoints information extracted using PoseNet from an image obtained with a low-cost 2D RGB camera, increasing the accuracy of judgments about the falls. In particular, we propose a fall detection method based on the characteristics of post-fall posture in the fall motion-analysis method. A public data set was used to extract human skeletal features, and as a result of an experiment to find a feature extraction method that can achieve high classification accuracy, the proposed method showed a 99.8% success rate in detecting falls more effectively than a conventional, primitive skeletal data-use method.

Keywords : Pose Estimation, Skeleton Keypoints, Fall Detection, Deep Learning, LSTM, PoseNet

*Corresponding Author : Dal-Soo Weon(Baewha Womens Univ.)

email: dsweon@baewha.ac.kr

Received October 26, 2020

Accepted February 5, 2021

Revised November 24, 2020

Published February 28, 2021

1. 서론

세계적으로 낙상은 노인 부상의 또는 사망의 주요 원인으로 높은 사회적 비용을 발생시키고 또한 제조업을 비롯한 현장에서 빈번하게 발생하는 낙상의 정확한 감지를 통한 신속한 조치가 요구된다. 이에 다양한 감지 기법이 소개되었으나 신체에 부착하는 센서 기반 낙하 감지 장치[1][6][7]는 사용자의 불편과 응답시간이나 제한된 하드웨어 리소스로 인해 여전히 효과가 낮았다.

따라서 신뢰할 수 있는 소비자 중심의 낙상 감지 시스템을 설계 및 테스트한 후 상업적인 보급이 필요하다. 특히 의료 및 산업현장에서는 상황 발생시 대응 및 구조 시간이 중요하므로 신속한 감지 및 즉각적인 알람 시스템을 구축하여 사고를 방지할 수 있어야 한다. 이를 위해 의료용 및 산업 현장용으로 센서를 몸에 부착할 필요가 없는 저렴한 일반 카메라를 사용하는 비전기반 낙상 감지 시스템이 필요하다.

연구 방법은 제 2장에서 기존 연구와 본 연구에 사용된 기술의 설명 및 장단점의 비교와 본 제안 기법을 서술하였다. 제 3장은 실제적인 관점에서 문제를 분석 정의하고 이를 해결하기 위한 적용기법을 기술별로 서술하였으며, 최적의 방식으로 문제를 해결하기 위한 아키텍처를 정의하였다. 제 4장은 제안 기법의 실험에 조건과 각종 파라미터, 데이터 세트 등을 포함하여 기술하였다. 제 5장은 실험 결과를 정리하였으며 테스트 및 성능 지표, 성능 결과를 평가하고 기존 연구와 비교하였다.

2. 관련 연구

비전기반(Vision-based) 추락 감지 시스템은 비디오 장비를 통한 영상을 획득하고 영상을 감지, 사용하여 추락을 감지한다. 이미지에서 배경을 삭제하거나[1][4] 비디오에서 사람 골격 데이터를 추출하고 이의 특징에 따라 비디오에서 사람의 모양이나 실루엣을 특성화하여 추락을 감지한다[4,5]. 최근에는 골격 데이터를 기반[8]으로 인간 활동을 인식하는 낙상 감지 방법에 중점을 두고 있다. 스켈레톤 데이터는 Microsoft에서 개발한 Kinect와 같은 3D depth 카메라 또는 2D RGB 비디오를 이용하여 PoseNet과 같은 CNN 기반 기술을 사용해 획득된다[9]. 즉, PoseNet은 카메라로 캡처한 이미지로부터 편리하고 빠르게 관절 데이터의 추출이 가능하다. 인체의 골격 정보를 기반으로 수행하기 때문에 정확도가 높을

뿐만 아니라 간단하고 저렴하다는 특징이 있다[1]. 추출된 스켈레톤 데이터는 시간에 따라 변화하는 시공간 데이터(spatial-temporal data)이다. 순환신경망(Recurrent Neural Network)은 시계열 데이터의 분류를 처리하는 강력한 방법이나, 학습에 오랜 시간이 소요되고 결과의 일부인 기울기 값(weight)이 사라지는 문제(vanishing gradient problem) 또는 너무 커지는 문제(exploding gradient)가 발생한다. 이러한 문제를 해결하기 위해 LSTM(Long-short term memory)과 GRU(gated recurrent unit)를 사용하는 기술이 소개되었다[1][10]. LSTM은 RNN과 같은 문제가 발생하지 않는다. GRU는 LSTM의 변형으로 간단한 구조로 학습시간이 짧다는 장점이 있다.

일반적으로 의료시설 내 병실과 산업 현장에서 사용하는 CCTV는 2D RGB 카메라이다. 일부 개인정보 보호를 염려할 수 있으나 카메라는 신체의 골격, 즉 스켈레톤 추출이 목적이므로 개인정보보호법의 규제를 받지 않을 것으로 판단된다.

본 논문은 카메라를 통해 획득된 영상을 PoseNet를 사용하여 이미지 또는 영상에서 스켈레톤 데이터를 추출하고, 추출된 데이터를 인공지능을 활용해 분류 및 추론하여 그 결과를 기반으로 낙상 또는 추락을 감지하는 FDSG(Fall Detection Method Based on Skeleton Keypoints using GRU)를 제안한다.

3. 낙상감지 기법

3.1 알고리즘

본 연구가 제안하는 FDS(Fall Detection System)의 낙상 감지 기법 아키텍처는 Fig. 1과 같으며 제안한 낙상 감지 방법은 PoseNet으로 추출한 골격 데이터 키포인트(SD: Standard Data)에 HSSC(Head and Shoulder Segment Keypoint Coordinates), VHSSC(Velocity of HSSC) 그리고 RWHC(Ratio of body Width and Height Coordinates)를 융합한 방법이다. 알고리즘은 6단계로 구성한다.

단계1, 카메라에서 2D RGB 비디오 데이터를 수집하는 데이터 수집 프로세스이다.

단계2, 낙상 판단을 위한 원시 골격 데이터가 Fig. 2와 같이 PoseNet를 통해 비디오 또는 이미지에서 추출된다. 사람의 머리부터 발까지 17개의 키포인트를 각각의 프레임 별로 출력한다. 코, 양쪽 눈 그리고 양쪽 귀를

포함한 머리 부분 포인트와 어깨 부분을 합하여 하나의 세그먼트로 구분한다(HSS: Head and Shoulder Segment).

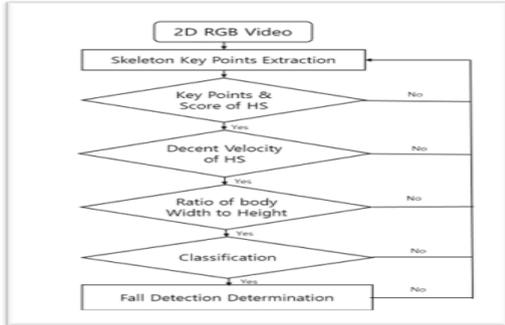


Fig. 1. Architecture of FDHG

단계3, 추출된 HSS 키포인트의 하강 속도를 계산해 적용한다.

단계4, 특징 추출(feature extraction) 방법에 따라 17개 골격 데이터를 연결한 신체 모양 직사각형의 폭 대 높이 비율을 적용한다.

단계5, 처리된 입력 데이터를 학습된 GRU에 입력해 낙상 판단 추론을 위한 자세 분류 프로세스이다.

단계6, 최종 프로세스로서 입력 영상에서 추출된 데이터를 GRU 추론 결과를 기준으로 낙상 여부를 결정한다.

낙상 자세 학습 데이터 세트는 국내의 AI HUB와 URFD dataset를 사용하였다[3]. 상세 학습자료(Learning source)는 모션 캡처(motion capture) 데이터 세트와 주석을 달은 2D 이미지(Annotated 2D images)이다.

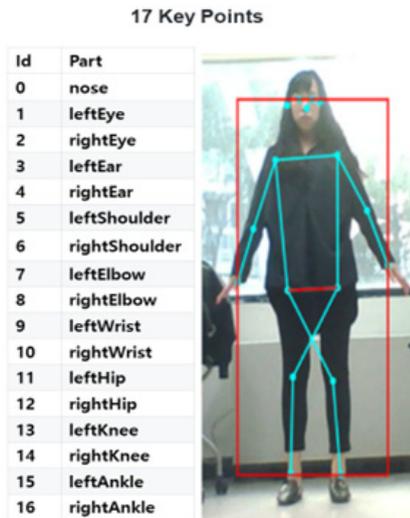


Fig. 2. Keypoints information of Human Body

3.2 특징 추출(Feature Extraction for HSSC)

제안하는 특징 추출 방법은 다음 두 가지 방법을 사용하였다. HSSC(Head and Shoulder Segment Keypoint Coordinates)는 머리와 어깨가 하나의 세그먼트로 키포인트 좌표(HSSC)이다. 병상 낙상의 경우, 머리 및 상체 부분의 위치변화가 낙상 감지에 있어 가장 중요한 요소이다. HSSC는 신체가 중력 방향에서 낙상 시에 가장 높은 곳에서 추락하는 신체에 해당하는 x, y 좌표이다.

HSSC는 7개의 X, Y 좌표로 구성된다. 좌표는 얼굴의 코(0), 눈(1,2), 귀(3,4)와 왼쪽 어깨(5)와 오른쪽 어깨(6) 등 7개 부분의 키포인트 좌표로 구성된다.

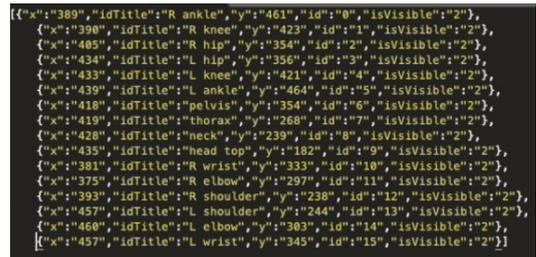


Fig. 3. PoseNet Key Points Extraction example

3.3 HS 하강 속도(Velocity of HS Descent)

낙상 시의 HS(Head and Shoulder)의 무게 중심은 갑자기 수직 방향으로 변한다. 사람의 HS 중심점은 인체의 최상단의 중력 중심을 나타내며 낙상을 판단하는 중요한 특징으로 사용된다.

PoseNet에서 얻은 HS 좌표 데이터를 처리하여 이미지 각 프레임의 HSS 중심점의 수직 좌표를 구한다. 서있는 자세에서 넘어지는 자세까지의 변화 과정은 매우 짧은 과정이고 사용되는 시간도 매우 짧기 때문에 0.25초의 시간 간격으로 5개의 인접한 프레임마다 한 번씩 감지한다[1].

추출할 특징은 HSSC의 추락 속도(VHSSC: Velocity of Head and Shoulder Segment Keypoint Coordinates)이다. 속도는 비디오 또는 이미지의 원도우/프레임의 처음 위치와 나중 위치를 이용한 시간 계산으로 얻으며[2], 각 프레임의 머리 위치와 HSGC 순차적 변화를 임계 값 함수로 사용하였다.

길이 n 프레임의 슬라이딩 윈도우를 학습 데이터 세트로 사용하고 HSSC의 평균 가속도, 각 프레임 평균 속도 v 와 n 프레임의 머리위치 변화 속도의 평균값은 다음과 같다.

$$S = \left| \sqrt{(x_{i-1} - x_i)^2 + (y_{i-1} - y_i)^2} \right| \quad (1)$$

Eq. (1)은 유클리드 거리 방법을 사용하였으며 S는 X, Y 값의 HSSC 위치의 가속도이다.

$$v = \frac{1}{n} \sum_{i=1}^n Dataset_i \dots\dots\dots (2)$$

Eq. (2)의 v는 각 슬라이딩 윈도우에서 머리 위치 속도의 평균값이고, n은 데이터 세트의 프레임 수이다.

$$S_{rd} = \frac{1}{n} \sum_{i=1}^n RDS_i \dots\dots\dots (3)$$

Eq. (3)의 S_{rd}는 머리 위치 변환 속도의 평균값이고, n은 슬라이딩 윈도우의 1초 동안의 프레임 수이고, 실시간 가속 RDS_i는 시리즈의 각 슬라이딩 윈도우의 머리 위치 변환 속도이다.

3.4 신체 폭 대 키의 비율(Ratio of Body Width to Height)

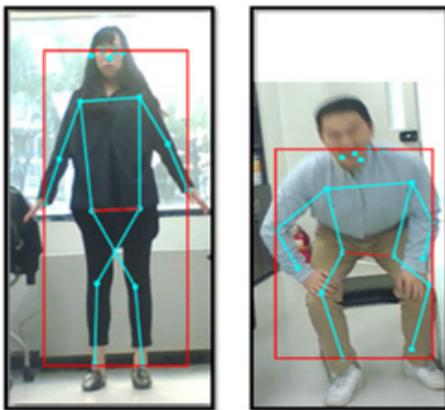


Fig. 4. PoseNet's Body Bounding Box

감지된 낙상의 가장 큰 특징은 각 관절 데이터를 기준으로 구성되는 신체 윤곽(Body Bounding Box)의 변화이므로 변화하는 자세의 가로(신체의 폭)길이와 세로(키)의 높이를 비교하면 판단 가능하다. Fig. 4는 서있는 자세와 몸을 쭉그려 앉는 자세의 바운딩 박스의 변화의 예

시를 보인다. 그러나 신체의 가로 세로의 비율은 움직이는 자세 변화와 카메라와 피사체의 거리에 따라 자세 폭과 높이가 모두 변하지만 그 비율은 알 수 없다[1].

사람의 신체 외곽을 나타내는 직사각형의 폭과 높이의 변화로 낙상 동작의 구별이 가능하다. 관절의 키 포인트의 조합으로 생성된 바운딩 박스의 폭과 높이의 비율을 이용하여 동작의 특징을 구별하고 낙상을 식별하는 과정을 Fig. 5에 보였다.

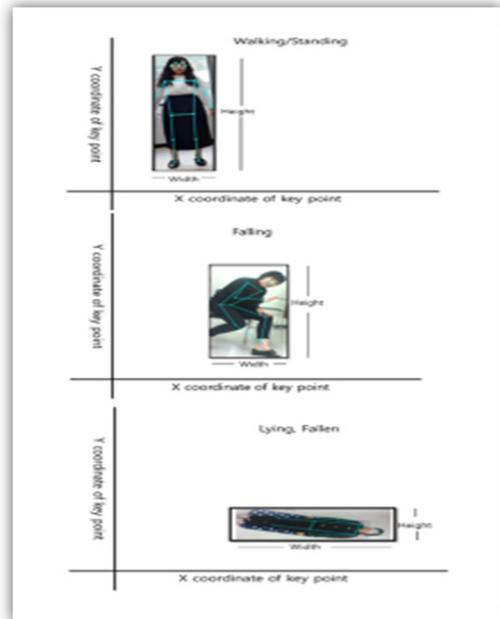


Fig. 5. Bounding Box By Human Pose

Fig. 5의 “walking/standing”은 일상생활(ADL: Activity of Daily Lives) 상황으로 인체 외곽의 직사각형(outer rectangle)의 폭과 높이를 구별할 수 있고 폭과 높이의 비율은, $R = \text{Width}/\text{Height}$, $R < 1$ 이다. 반면 하단의 낙상(Lying/Fallen) 상황에서의 폭과 높이의 비율은 $R > 1$ 이다. 제안된 특징 추출방법은 자세 변화에 수반하는 인체 비율의 변화를 추가적인 변수로 낙상 여부를 감지한다.

Eq. (4)의 $w(t)$, $h(t)$ 는 각각 현재 시간 t의 바운딩 박스의 폭과 높이이고 $R(t)$ 는 현재 시간의 폭(width) 대 높이(height)의 비율을 나타낸다.

$$R(t) = \frac{w(t)}{h(t)} \dots\dots\dots (4)$$

Eq. (5)의 $\mu_r(t)$ 값은 현재시간 t 에서의 폭 대 높이의 평균값이고, $\mu_r(t-1)$ 값은 이전 시점($t-1$)의 폭과 높이의 평균값이다. α 는 업데이트된 매개 변수이다.

Eq. (6) $\sigma_r(t)$ 는 현재 시간 t 의 폭 대 높이의 비율의 변화 값이다. 자세를 변경하면 비율 변화 값이 커지고, 변화 값이 설정한 임계값을 초과하면 변경된 자세는 학습된 GRU기반 분류 과정에서 낙상 여부를 결정하는 요소를 구성한다 [8].

$$\mu_r(t) = (\alpha - 1)\mu_r(t-1) + \alpha R(t) \dots (5)$$

$$\sigma_r(t) = R(t) - \mu_r(t-1) \dots (6)$$

4. 실험

4.1 실험 환경(Experimental Configuration)

제안한 기법은 PoseNet으로 추출한 관절 데이터 keypoint(SD)에 HSSC, VHSSC 그리고 RWHC를 융합한 방법이다. 인체 관절 좌표 추출을 위하여 PoseNet을 사용하였고 사람 자세분류 정확도 개선을 위해, 기울기 소실 문제(vanishing gradient problem)가 있는 LSTM 기법 대신 간소화되어 시간 단축이 가능한 GRU를 적용하였다.

GRU는 2개의 스택과 256개의 히든 레이어로 설정하였다. 실행 시간과 분류 정확도 등의 효율을 고려해 조합을 구성하였다. GRU의 파라미터는 batch_size, epoch, learning_rate로, batch_size는 입력을 연산할 데이터의 크기로 128로 하였다. 학습 데이터의 반복 학습 횟수를 나타내는 파라미터 epoch는 5000으로 설정했다. 또한 학습 Learning_rate는 Adam[1][5] optimizer로 이에 따른 초기 학습률은 0.0001로 설정하였다.

데이터 세트는 국내 AI HUB와 공개된 URFD Dataset를 낙상 구분을 위해 사용하였다.

PoseNet 설정은 Table 1과 같다.

Table 1. PoseNet Configuration 설정

algorithm	single-pose
architecture	ResNet50
inputResolution	250
outputStride	32
multiplier	1
quantbytes	2

5. 실험 결과

실험에 사용된 데이터 세트는 공개된 국내의 AI HUB와 UR Fall Dataset(URFD)를 사용하였고 걷기, 앉기, 쓰러짐 낙상을 학습용으로 사용하였다. 입력된 이미지의 원시 골격 데이터(SD: Skeleton Data)를 SD, 머리와 어깨 부분을 하나의 세그먼트로 한 HSSC 기법, HSSC의 하강 속도를 추가한 VHSSC 기법과 골격 데이터에 의해 생성되는 자세 별 신체의 가로(폭) 대 세로(높이) 비율을 추가한 기법(RWHSC)을 실험하였다.

PoseNet로 생성한 스켈레톤의 키포인트 좌표를 기준 데이터 세트로 사용하였다. 동작의 작은 변화에도 상응하는 많은 데이터가 생성되어 1. 앉은 자세 2. 의자에 앉는 자세 3. 쓰러지는 자세 4. 쓰러진 자세 등 4 가지 자세를 기준으로 정제하였다.

낙상으로 판별되는 원시 골격 데이터(SD: Skeleton Data)와 머리와 어깨를 하나의 세그먼트로 HSSC 기법을 적용한 낙상에 대응하는 각 keypoint의 x, y 좌표와 신뢰값(Confidence score)은 Table 2와 같다.

Table 2. HSSC의 낙상 x, y, 좌표 및 score(신뢰점수)

		x(width)	y(height)	score(신뢰점수)
1	head+shoulder	44.8378536542765	29.6835843543787	0.9498823059600
2	leftElbow	65.8753425222545	41.7345342125375	0.9460365844748
3	rightElbow	45.5378215783780	25.9365245745354	0.9245643580977
4	leftWrist	75.5783527858000	57.2156378637370	0.9815611980416
5	rightWrist	55.8353788112353	37.8727542452425	0.9859810826347
6	leftHip	65.4537834527527	44.7837354345378	0.9554020891864
7	rightHip	35.7873737837834	15.2378378227837	0.9418022064184
8	leftKnee	15.6546587373543	97.5828528280000	0.9716006545777
9	rightKnee	65.6546546542765	49.1586374837837	0.9337711781269
10	leftAnkle	45.6783753738765	27.2878245347583	0.9878408746095
11	rightAnkle	85.9375278542535	59.8235348378000	0.9881633553867

[Legend]

M1 : SD(Skeleton Key point Coordinate)

M2 : SD+HSSC(Head Shoulder Segment Key Point Coordinate)

M3 : SD+VHSSC(Velocity of Shoulder Segment Key Point Coordinate)

M4 : HSSC+VHSSC+RWHC(Ratio of Width to Height body Key point coordinate)

Table 3. AI hub + URFD Dataset로 분류 및 낙상감지 결과

방법	Data size	Data Set	Classification Accuracy(%)					낙상감지 정확도 (%)
			평균	앞은 자세	일어나는 자세	쓰러지는 자세	쓰러진 자세	
M1	34	Alhub URFD	97.52	98.52	97.39	96.93	97.25	98.87
M2	38	Alhub URFD	98.36	99.78	99.3	97.41	96.95	98.99
M3	40	Alhub URFD	99.06	99.84	99.84	98.43	98.15	99.00
M4	40	Alhub URFD	99.46	99.90	99.89	99.05	99.02	99.97

Table 3은 SD와 제안한 HSSC, VHSSC 그리고 RWHSC 기법을 추가로 적용한 결과 분류 및 낙상감지 정확도를 계산한 값이다. 기법 적용없이 SD의 특징 분류 정확도는 평균 97.52% 이고 SD+HSSC의 M2, SD+VHSSC의 M3 그리고 바운딩 박스의 폭과 높이의 비율을 추가 적용한 M4의 평균 자세 특징 분류 정확도는 각각 98.36%, 99.06% 그리고 99.46%로 M4가 낙상 특징 분류가 가장 높았다. 낙상 감지 정확도 또한 제안한 기법 M4가 제안 기법을 적용하지 아니한 SD 보다 낙상 분류 정확도는 1.1% 증가하였다.

6. 결론

본 논문은 2개의 공공 낙상감지 데이터 세트, AI HUB와 URFD를 PoseNet을 이용하여 비디오 기반으로 동작 인식에서 낙상 감지 분류를 위한 GRU 신경망 기법을 적용한 새로운 낙상 감지 방법을 제시하였다.

추출한 사람 골격 데이터로 제안한 특징 추출 방법의 조합을 실험한 결과 제안한 FDSG 기법이 낙상 감지 정확도를 개선한 것을 증명하였다. 그러나 다양한 낙상 데이터 세트가 부재하고 실험 환경이 단순하여 실험 결과가 실제 환경에도 실험 결과와 같은 높은 자세 분류와 낙상 감지 정확도를 유지하기는 어려울 것이다. 비전 기반 낙상 감지 기능을 실제 배포해 적용하기 위해서는 빛의 강도와 복잡한 환경에 대응하는 기술과 정보의 공유 및 다양하고 충분한 데이터 세트 확보 등 개선의 여지가 있다.

References

[1] Weiming Chen, Zijie Jiang, Hailin Guo and Xiaoyang, "Fall Detection Based on Key Points of Human-

Skeleton Using OpenPose," Symmetry May 2020,12, 744;

DOI: <https://doi.org/10.3390/sym12050744>

- [2] Wu, G. (2000). "Distinguishing fall activities from normal activities by velocity characteristics," Journal of biomechanics, 33(11), 1497-1500.
DOI: [https://doi.org/10.1016/s0021-9290\(00\)00117-2](https://doi.org/10.1016/s0021-9290(00)00117-2)
- [3] X. Ma, H.Wang, B. Xue, M. Zhou, B. Ji and Y. Li, "Depth-Based Human Fall Detection via Shape Features and Improved Extreme Learning Machine," IEEE Journal of Biomedical and Health Informatics, vol. 18, no. 6, pp. 1915 -1922, Nov. 2014.
DOI: <https://doi.org/10.1109/JBHI.2014.2304357>
- [4] A. Abobakr, M. Hossny and S. Nahavandi, "A Skeleton-Free Fall Detection System From Depth Images Using Random Decision Forest," in IEEE Systems Journal, vol. 12, no. 3, pp. 2994-3005, Sept. 201.,
DOI: <https://doi.org/10.1109/JSYST.2017.2780260>
- [5] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," ICLR,2015.
<https://hdl.handle.net/11245/1.505367>
- [6] AK Bourke, JV O'brien, and GM Lyons, "Evaluation of a threshold-based tri-axial accelerometer fall detection algorithm," Gait & Posture, 2007.
DOI: <https://doi.org/10.1016/j.gaitpost.2006.09.012>
- [7] KWC Cheng, and DM Jhan, "Triaxial accelerometer - based fall detection method using a self-constructing cascade-Ada Boost-SVM classifier," IEEE Journal of Biomedical and Health Informatics, 2013.
DOI: <https://doi.org/10.1109/ibhi.2012.2237034>
- [8] W. Lie, A. T. Le and G. Lin, "Human fall-down event detection based on 2D skeletons and deep learning approach," 2018 International Workshop on Advanced Image Technology (IWAIT), Chiang Mai, 2018, pp. 1-4,
DOI: <https://doi.org/10.1109/IWAIT.2018.8369778>.
- [9] Kripesh Adhikari, Hamid Bouchachia, Hammadi Nait-Charif, "Deep Learning Based Fall Decton Using Silplified Human Posture," International Journal of Computer and Systems Engineering, Vol:13, No:5, 2019.
<https://pdfs.semanticscholar.org/f953/09544f8bac647b7503ba6c849ccbd9bc8e19.pdf>
- [10] M. D. Solbach and J. K. Tsotsos, "Vision-Based Fallen Person Detection for the Elderly," 2017 IEEE International Conference on Computer Vision Workshops (ICCVW), Venice, 2017, pp. 1433-1442,
DOI: <https://doi.org/10.1109/ICCVW.2017.170>

강 윤 규(Yoon-Kyu Kang)

[정회원]



- 2012년 2월 : 고려대학교 대학원 정보통신학과 (공학석사)
- 2017년 8월 : 서울대학교 대학원 경영학과 (경영학석사)
- 2017년 8월 : 연세대학교 대학원 정보산업공학 박사 수료
- 2020년 3월 ~ 현재 : 송실대학교 대학원 박사과정

<관심분야>

인공지능, 사물인터넷, Pose Estimation, 빅데이터

강 희 용(Hee-Yong Kang)

[정회원]



- 1994년 8월 : 고려대학교 대학원 경영학과 (경영학석사)
- 1999년 2월 : 송실대학교 대학원 정보과학과 (이학석사)
- 2015년 8월 : 송실대학교 대학원 IT정책학과 공학박사
- 2017년 3월 ~ 현재 : 송실대학교 정보과학대학원 교수

<관심분야>

사물인터넷, 빅데이터, 인공지능, Human Pose Estimation

원 달 수(Dal-Soo Weon)

[정회원]



- 1981년 8월 : 송실대학교 공과대학 전자계산학과(공학사)
- 1986년 2월 : 송실대학교 산업대학원 전자계산학과 (공학석사)
- 2013년 2월 : 송실대학교 대학원 컴퓨터학과 공학박사
- 2004년 9월 ~ 현재 : 배화여자대학교 스마트IT학과 교수
- 1981년 8월 ~ 1996년 2월 : 국민은행 전산부
- 1996년 3월 ~ 2002년 12월 : 현대전자(현대정보기술) 금융공공사업본부 상무

<관심분야>

사물인터넷, 빅데이터, PMO