

Unreal Engine 기반 가상환경에서 OpenPose를 활용한 인체 자세 데이터 생성 방법 및 특성 분석

루벤에스페조*, 우동현**, 김중락***

Analysis of Human Posture Data Generation Method and Characteristics using OpenPose in Unreal Engine-based Virtual Environments

Ruben D. Espejo Jr.*, Donghyun Woo**, and Joongrock Kim***

본 논문은 2025년도 교육부 및 경상남도의 재원으로 경상남도RISE센터의 지원을 받아 수행된 지역혁신중심 대학지원체계(RISE)의 결과입니다(2025-RISE-16-002). 또한, 2025년도 교육부의 재원으로 글로벌대학사업의 지원을 받아 수행된 사업의 결과입니다.

요 약

단안 인간 자세 추정은 단일 RGB 이미지로부터 인체의 자세 구성을 복원하는 것을 목표로 하며, 컴퓨터 비전 분야에서 활발히 연구되어 왔다. 최근 딥러닝 기반 기법의 발전에도 불구하고, 자세 추정 결과는 카메라 시점 변화와 관절 가림(Occlusion)에 민감하여 실제 환경에서의 체계적인 분석에 한계가 존재한다. 이러한 문제를 해결하기 위해, 본 논문에서는 Unreal Engine과 OpenPose를 활용한 가상 환경 기반 인체 자세 데이터 생성 프레임워크를 제안한다. 애니메이션이 적용된 인체 모델을 다양한 카메라 시점에서 렌더링하고, 생성된 RGB 이미지에 OpenPose를 적용하여 자세 데이터를 획득한다. 생성된 데이터셋을 기반으로 카메라 시점 및 자세 변화에 따른 관절 검출 특성과 신뢰도 안정성을 분석한다. 실험 결과, 관절 검출 안정성은 카메라 시점뿐만 아니라 자세에 따른 자기 가림(Self-occlusion)의 영향을 크게 받으며, 특히 말단 관절에서 신뢰도 저하가 두드러지게 나타남을 확인하였다.

Abstract

Monocular human pose estimation aims to recover human body configurations from a single RGB image and has been widely studied in computer vision. Despite recent advances in deep learning-based methods, pose estimation results remain sensitive to camera viewpoint variations and joint occlusion, which complicates systematic analysis in real-world settings. To address this limitation, this paper proposes a human pose data generation framework using Unreal Engine and OpenPose in a controlled virtual environment. Animated human models are rendered under diverse camera viewpoints, and pose data are obtained by applying OpenPose to the generated RGB images. Using the resulting dataset, joint detection characteristics and confidence stability are analyzed with respect to viewpoint and pose variations. Experimental results demonstrate that joint detection stability is affected not only by camera viewpoint but also by pose-dependent self-occlusion, with particularly notable degradation observed in distal joints.

Keywords

human pose estimation, synthetic data, OpenPose, Unreal Engine, camera viewpoint control

* 국립창원대학교 인공지능융합공학과 박사과정

- ORCID: <https://orcid.org/0009-0007-7458-8619>

** 국립창원대학교 첨단방위공학과정 박사과정

- ORCID: <https://orcid.org/0000-0002-5562-4158>

*** 국립창원대학교 인공지능융합공학과 부교수(교신저자)

- ORCID: <https://orcid.org/0009-0001-5284-1149>

· Received: Jan. 22, 2026, Revised: Feb. 11, 2026, Accepted: Feb. 14, 2026

· Corresponding Author: Joongrock Kim

Dept. of Artificial Intelligence Convergence Engineering, 20
Changwondaehak-ro, Uichang-gu, Changwon-si, Gyeongsangnam-do, 51140,
Korea

Tel.: +82-55-213-3962, Email: jrkim@changwon.ac.kr

I. 서 론

단안 인체 자세 추정(Monocular human pose estimation)은 단일 RGB 영상으로부터 인체의 자세 및 관절 구성을 복원하는 것을 목적으로 하며, 인간-컴퓨터 상호작용, 증강현실, 로봇공학, 비디오 분석 등 다양한 응용 분야에서 활용되어 컴퓨터 비전 분야에서 활발히 연구되고 있다[1][2]. 최근 딥러닝 기반 방법의 발전에도 불구하고, 단안 환경에서는 원근 투영으로 인해 깊이 정보가 소실되고 자기 가림(Self-occlusion)이 빈번하게 발생하므로, 자세 추정 문제는 본질적으로 불완전(ill-posed)한 특성을 갖는다.

자세 추정 성능은 학습 데이터의 품질과 다양성에 의해 크게 좌우된다. Human3.6M과 MPI-INF-3DHP와 같은 대규모 데이터셋은 정밀한 주석을 제공하나, 통제된 실내 환경에서 수집되어 데이터 변동성이 제한적이라는 한계가 있다[3][4]. 반면, 3DPW와 같은 현장(In-the-wild) 데이터셋은 장면 다양성을 확보할 수 있으나, 수집 비용이 높고 규모 확장에 제약이 따른다[5].

이러한 실제 데이터 수집의 한계를 보완하기 위한 대안으로 합성 데이터 생성이 감독 신호의 한 형태로 검토되고 있다[6][7]. 가상 환경은 자세, 시점, 조명 및 배경 조건을 명시적으로 제어할 수 있어 다양한 학습 샘플을 체계적으로 생성할 수 있다. 또한 단일 RGB 이미지로부터 3차원 인체 자세를 추정하기 위한 체적(Volumetric) 또는 구조화(Structured) 표현 기반 접근법도 제안되었다[8][9]. 특히 Unreal Engine과 같은 게임 엔진은 물리 기반 렌더링 및 유연한 카메라 모델링을 지원하므로 가상 데이터 생성 플랫폼으로 활용 가능하다[10][11].

OpenPose는 다중 사용자 2D 인간 자세 추정을 위한 대표적인 오픈소스 프레임워크로 알려져 있다[12][13]. 가상 이미지에 OpenPose를 적용할 경우 수동 주석 없이 관절 키포인트를 자동 추출할 수 있다는 장점이 있다. 다만, 기존 연구에서는 가상 환경에서 생성된 OpenPose 기반 자세 데이터가 구조적 특성 및 시점 변화에 따른 안정성 측면에서 어떠한 특성을 보이는지에 대한 분석이 충분히 이루어지지 않았다.

본 연구의 목적은 Unreal Engine 기반 가상 환경에서 OpenPose를 활용하여 인간 자세 데이터를 생성하는 방법을 제안하고, 생성된 데이터의 특성을 분석하는 데 있다. 구체적으로 본 연구는 데이터 생성 파이프라인의 설계와 관절 검출 특성 분석에 중점을 둔다. 반면, 생성 데이터에 기반한 학습 성능 평가는 본 논문의 범위를 벗어나며, 향후 연구로 수행하고자 한다.

II. 관련 연구

2.1 단안 인체 자세 추정

초기 단안 자세 추정 방법은 주로 회귀(Regression) 기반 모델을 활용하여 2D 관절(Keypoint) 예측 결과를 3차원 공간으로 승격(Lifting)하는 방식으로 제안되었다[1][2]. 한편, 일부 연구에서는 체적(Volumetric) 표현 또는 구조화(Structured) 표현을 도입하여 RGB 이미지로부터 3D 관절 좌표를 직접 회귀하는 접근을 제시하였다[8][9]. 그러나 이러한 방법들은 일정 수준의 성과에도 불구하고, 단일 시점(Monocular) 영상에 내재된 깊이 모호성(Depth ambiguity)과 가림(Occlusion) 문제로 인해 근본적인 한계를 갖는다.

2.2 인간 자세 추정을 위한 합성 데이터

SURREAL과 같은 합성 데이터셋은 3차원 인체 모델과 모션 캡처 데이터를 기반으로 렌더링된 인간 이미지를 통해 다양한 자세 및 외형 변화를 제공함으로써 인체 데이터의 다양성을 효과적으로 확장할 수 있음을 보여주었다[6]. 또한 모션 캡처(Motion capture) 기반 증강 접근법은 합성 자세를 실제 영상에 삽입함으로써 기존 실제 데이터셋의 규모와 다양성을 추가로 확장하는 방식으로 활용된다[7]. 그러나 다수의 합성 데이터 생성 파이프라인은 시각적 사실감 또는 자세 다양성 확보에 주로 초점을 두고 있으며, 생성된 자세 데이터의 구조적 특성 및 분포에 대한 체계적인 분석은 아직 제한적인 실정이다.

2.3 가상 환경 및 게임 엔진

게임 엔진은 컴퓨터 비전 과제를 위한 합성(또는 가상) 데이터 생성에 활용되어왔다[10]. 특히 UnrealCV는 Unreal Engine에 대한 프로그램적 접근을 제공함으로써 카메라 제어와 데이터 추출 절차를 효율화한다[11]. 가상 환경은 포즈 관련 작업에도 적용되어 왔으나, 기존 연구는 OpenPose와 같은 추정 모델을 통해 생성된 자세 데이터의 세부 특성에 대한 정량적·체계적 분석보다는 데이터의 규모 확대 및 시각적 현실성 확보에 주로 초점을 두는 경향이 있었다.

III. 제안 시스템 설계 및 가상 환경 구성

3.1 시스템 개요

본 연구는 Unreal Engine 기반 가상 환경과 OpenPose를 결합하여 인간 자세 데이터를 생성하고, 생성 데이터의 특성을 분석하는 시스템을 제안한다. 그림 1은 제안 시스템의 전체 파이프라인을 나타내며, (a) 가상 인간 자세 구성, (b) Unreal Engine 기반 애니메이션, 구성 및 렌더링, (c) 제어된 카메라 설정 하에서의 이미지 생성, (d) OpenPose 기반 관절 추정의 네 단계로 구성된다. 최종적으로 (e) 단계에서는 2D 관절 좌표와 관련 메타데이터를 포함

하는 구조화된 데이터셋을 출력한다.

입력 단계에서는 Unreal Engine에서 구성된 가상 장면과 애니메이션이 적용된 인체 모델을 기반으로 렌더링된 RGB 프레임을 입력으로 사용한다. 반면, 출력 단계에서는 각 프레임에 대해 OpenPose가 추정한 2D 관절 키포인트 좌표 및 신뢰도 점수, 그리고 생성 조건 메타데이터(카메라/조명/배경 등)를 포함하는 데이터셋을 출력한다.

제안 시스템은 가상 환경 구성 및 인체 모델 시뮬레이션을 위해 Unreal Engine 5.5를 사용하여 구현하였으며, 2D 관절 키포인트 추정을 위해 OpenPose 1.7.0을 적용하였다. 모든 실험은 Windows 10 운영체제 환경에서 수행하였고, 하드웨어 사양은 RAM 16 GB 및 NVIDIA GeForce RTX 5080(16 GB VRAM)으로 구성하였다. 렌더링 이미지는 1920×1080 해상도로 생성하였으며, PNG 형식으로 저장하고 RGB 색공간을 사용하였다.

3.2 가상 인간 모델

그림 2에 제시된 바와 같이, 사전 정의된 관절 계층 구조를 갖는 골격 기반 인간 모델을 Unreal Engine에서 구현하였다. 또한 고정된 뼈 길이와 관절 회전 제약을 적용하여 해부학적 타당성을 유지하였으며, 다양한 포즈를 생성하기 위해 복수의 애니메이션 시퀀스를 적용하였다.




그림 1. Unreal Engine 기반 가상 환경에서 OpenPose를 활용한 인체 자세 데이터 생성 파이프라인

(a) 가상 인간 모델 (b) 애니메이션 (c) 렌더링 (d) 오픈포즈 (e) 저장소

Fig. 1. Pipeline for generating human pose data using OpenPose in an Unreal Engine - based virtual environment

(a) Virtual human model (b) Animation (c) Rendering (d) OpenPose (e) Storage



그림 2. 가상 인간 모델

Fig. 2. Virtual human model

골격 및 관절 정의는 OpenPose BODY_25 관절 체계를 기준으로 구성하였으며, 인체 모델은 신장 1.8 m로 고정 스케일링하였다. 또한 Unreal Engine에서 관절별 회전 제한(Euler 각도 기반 제약 범위)을 적용하였다.

3.3 장면 및 렌더링 설정




그림 3. OpenPose 데이터 및 렌더링 설정이 적용된 인체 모델

Fig. 3. Human model with OpenPose data and rendering settings

데이터의 다양성을 확보하기 위해 배경 레이아웃, 조명 조건, 카메라 위치 및 거리 등 환경 매개변수를 그림 3과 같이 무작위로 설정하였다. 이러한 변형은 제어된 기하 구조를 유지한 상태에서 다양

한 시각적 조건 하에서의 자세 추정 동작을 분석할 수 있도록 한다. 한편, 가상 환경 구성 및 렌더링 설정에 사용된 매개변수 정보는 표 1에 정리하였다.

표 1. 그림 3에 기반한 가상 환경 및 렌더링 설정 매개변수

Table 1. Virtual environment and rendering settings parameters based on figure 3

Item	Setting range	Description
(a) Background type	Indoor	Environmental diversity
(b) Camera angle	60°	Azimuth change
(c) Light intensity	Low	Light source condition
(d) Camera distance	4m	Human-camera distance

3.4 OpenPose 기반 포즈 데이터 생성

Unreal Engine에서는 스켈레탈 애니메이션을 통해 정확한 관절 위치 정보를 직접 획득할 수 있다. 그러나 본 연구의 목적은 이상적인 정답 관절 데이터를 생성하는 것이 아니라, 실제 단안 자세 추정 환경에서 사용되는 모델의 동작 특성과 한계를 분석하는 데 있다. 실제 응용 환경에서는 RGB 이미지를 기반으로 OpenPose와 같은 자세 추정 모델을 적용하므로, 본 연구에서는 렌더링된 이미지를 입력으로 사용하여 현실적인 자세 추정 조건을 모사하였다.

OpenPose에서 제공하는 관절 검출 신뢰도는 관절별 heatmap에서 최대 응답값을 기반으로 산출되며, 해당 위치에 관절이 존재할 확률을 의미한다. 본 연구에서는 OpenPose의 원본 신뢰도 값을 사용하여 관절 검출 안정성을 정량적으로 분석하였다.

렌더링된 이미지에 OpenPose를 적용하여 2D 관절 키포인트를 추정한다[12][13]. 각 프레임에 대해 관절 좌표와 신뢰도 점수를 추출하여 저장하며, 데이터는 관절 인덱스, 픽셀 좌표 및 가시성 지표를 포함하는 구조화된 형식으로 구성된다.

그림 4는 서로 다른 각도에서의 가상 인간 모델과 이에 대응되는 OpenPose 관절 정의를 나타낸다. 그림 4(a)는 가상 인간 모델의 우측 측면에서의 정지 자세를, 그림 4(b)는 좌측 측면에서의 점프 자세를, 그림 4(c)는 우측 측면에서의 점프 자세를, 그리고 그림 4(d)는 좌측 측면에서의 정지 자세를 각각 보여준다. 이러한 구성은 다양한 카메라 위치에서

관절 정의의 안정성을 검증할 수 있도록 한다. 또한 OpenPose 기반 자세 추정은 수동 라벨링 없이 관절 정보를 자동으로 획득할 수 있으므로, 합성 이미지로부터 대규모 자세 데이터셋을 효율적으로 구축하는 데 적합하다.




그림 4. 다양한 시점과 포즈에서의 가상 인간 모델 및 OpenPose 관절 정의

Fig. 4. Virtual human model and OpenPose joint definitions across different viewpoints and poses




그림 5. OpenPose 기반 자세 데이터 생성 알고리즘
Fig. 5. OpenPose-based pose data generation algorithm

그림 5는 본 연구에서 제안하는 OpenPose 기반 인체 자세 데이터 생성 절차를 요약하여 나타낸다. 먼저 Unreal Engine을 이용하여 가상 장면과 애니메이션이 적용된 인체 모델을 구성하고, 제어된 카메라

라 설정 하에서 RGB 이미지를 렌더링한다. 이후 생성된 이미지를 OpenPose의 입력으로 제공하여 각 프레임에 대해 2차원 관절 좌표와 이에 대응되는 신뢰도 점수를 자동으로 추출한다. 마지막으로, 추출된 자세 정보는 관절 인덱스, 픽셀 좌표, 신뢰도 값을 포함하는 구조화된 형식으로 저장된다.

IV. 자세 데이터 분석

본 절에서는 학습 성능을 평가하기보다는, 생성된 자세 데이터의 특성을 중심으로 분석한다.

4.1 관절 검출 안정성 분석

그림 6은 대표적인 동적 자세에 대해 전방, 측면 및 후면 카메라 시점에서의 OpenPose 기반 관절 검출 결과를 나타낸다.



그림 6. 정면, 측면 및 후면 카메라 시점에서의 동적 인간 자세에 대한 관절 검출 결과

Fig. 6. Joint detection results for a dynamic human pose under frontal, side, and rear camera viewpoints

그림 6은 서로 다른 카메라 시점에서 OpenPose 기반 관절 검출 결과를 비교한 것이다. 정면 시점에서는 대부분의 관절이 안정적으로 검출되는 반면,

측면 및 후면 시점에서는 자기 가림(Self-occlusion)의 영향으로 손목 및 발목과 같은 말단 관절의 신뢰도가 감소하는 경향이 나타난다. 특히 동적 자세에서는 관절 굽힘과 신체 중첩으로 인해 일부 관절이 누락되거나 낮은 신뢰도로 검출되는 현상이 관찰되었다. 이러한 결과는 카메라 시점과 자세 변화가 관절 검출 안정성에 중요한 영향을 미친다는 것을 보여준다.

Confidence Range는 주어진 조건에서 관절 검출 신뢰도의 최소값과 최대값 범위를 의미하며, 관절 검출 안정성의 변동 정도를 나타낸다. 관절 수준의 분석 결과, 몸통(Core) 부위 관절은 대체로 높은 신뢰도 범위에 분포하는 반면, 말단(Distal) 관절은 상대적으로 낮은 신뢰도의 검출 결과와 더 빈번하게 연관되는 경향이 나타났다.

표 2. 그림 4를 기반으로 한 평균 관절 검출 신뢰도
Table 2. Average joint detection confidence based on figure 4

Joint	Confidence	Confidence range	Analysis basis
Head	High	0.80 - 1.00	Consistently detected across all viewpoints
Neck	High	0.80 - 1.00	Stable connectivity maintained under pose changes
Shoulder	Medium	0.50 - 0.79	Partial confidence reduction in side-view poses
Elbow	Medium	0.50 - 0.79	Variability observed during arm flexion
Wrist	Low	0.00 - 0.49	Frequent misses under strong joint bending and self-occlusion
Hip	High	0.80 - 1.00	Centrally located joint with stable detection
Knee	Medium	0.50 - 0.79	One-sided instability in jumping poses
Ankle	Low	0.00 - 0.49	Detection failures during airborne and landing phases

표 2에서 확인할 수 있듯이, 머리 및 몸통과 같은 중심부 관절은 비교적 좁은 수치 범위(Confidence range)를 보여 안정적인 검출 성능을 나타낸다. 반면 손목과 발목을 포함한 말단 관절은 더 넓은 수치 범위를 보이며, 이는 카메라 시점 변화

및 자세에 따른 자기 가림(Self-occlusion)에 대한 민감도가 상대적으로 높음을 의미한다.

표 3의 이미지별 분석 결과, 정면 직립 자세에서는 전반적으로 높은 신뢰도의 관절 검출이 이루어지는 반면, 점프 동작 및 후방 시야 조건에서는 관절 신뢰도가 주로 중간 범위에 분포하는 경향이 나타났다. 특히 말단(Distal) 관절은 이러한 조건에서 누락률이 상대적으로 높게 관찰되었다.

표 3. 그림 4를 기반으로 한 이미지별 오픈포즈 관절 검출 특성

Table 3. Image-wise OpenPose joint detection characteristics based on figure 4

Image	Confidence	Confidence range	Missing Joints	Remarks
Image (a)	High	0.80 - 1.00	None	No self-occlusion, stable joint configuration
Image (b)	Medium	0.50 - 0.79	Wrist, Ankle	Combined effect of viewpoint and airborne motion
Image (c)	Medium	0.50 - 0.79	Wrist	Arm flexion causes partial occlusion
Image (d)	Medium	0.50 - 0.79	Wrist, Ankle	Rear view increases distal joint ambiguity

또한, 표 2와 표 3에 제시된 바와 같이 OpenPose 기반 관절 검출 신뢰도는 자세 구성과 카메라 관점에 따라 체계적으로 변화한다. 몸통 및 중심부 관절은 높은 신뢰도 범위에서 비교적 일관되게 검출되는 반면, 말단 관절은 자기 가림(Self-occlusion) 및 극단적인 관절 자세에서 낮은 신뢰도 범주에 포함되는 경우가 빈번하다. 이러한 결과는 그림 4에서 확인되는 신뢰도 분포의 전반적인 추세와도 일치한다.

4.2 가시성 및 구조적 특성 분석

자기 가림(Self-occlusion) 정도에 따른 키포인트 검출 특성을 분석하기 위해, 누락되거나 낮은 신뢰

도를 보이는 키포인트의 발생 빈도를 비교하였다. 분석 결과, 가림이 발생한 관절은 전반적으로 낮은 검출 신뢰도 및 누락과 일관되게 연관되는 경향이 확인되었다.

손목 및 발목과 같은 말단 관절은 신체 중심부에 비해 픽셀 크기가 작고, 가림 및 빠른 움직임이 빈번하게 발생하여 검출 신뢰도가 상대적으로 낮게 나타난다. 이를 완화하기 위한 방안으로 고해상도 입력 사용, 시점 다양성 확대, 시간적 정보 기반 후처리 기법 등이 향후 연구로 고려될 수 있다.

또한 생성된 포즈 데이터의 구조적 타당성을 평가하기 위해 관절 간 상대적 위치 관계를 분석하였다. 표 2 및 표 3의 결과에 따르면, 생성된 데이터는 다양한 자세 및 관점 조건에서도 전반적으로 해부학적으로 타당한 관절 관계를 유지하는 것으로 나타났다.

V. 결 론

본 연구에서는 Unreal Engine 기반 가상 환경에서 OpenPose를 활용하여 인간 자세 데이터를 생성하는 방법을 제안하고, 생성된 데이터의 특성과 관절 검출 안정성을 분석하였다. 분석 결과, 가상 환경과 OpenPose를 결합함으로써 인간 자세 데이터를 체계적으로 생성할 수 있음을 확인하였으며, 생성된 데이터는 전반적으로 구조적 일관성을 유지하였다. 또한 카메라 시점 변화와 자기 가림(Self-occlusion)이 관절 검출 안정성에 유의한 영향을 미치는 것으로 나타나, 데이터 생성 및 구축 과정에서 시점 및 가림 요인을 고려하는 것이 중요함을 확인하였다.

다만 단순화된 텍스처, 제어된 동작 패턴 등 가상 환경 특성으로 인해 실제 이미지 기반 데이터와의 차이는 여전히 존재하며, 본 연구는 데이터 생성과 특성 분석에 범위를 한정하였다. 향후 연구에서는 생성된 데이터를 활용한 자세 추정 모델 학습 성능을 정량적으로 평가함으로써, 가상 환경 기반 자세 데이터의 효과를 보다 명확히 검증할 예정이다.

References

[1] J. Martinez, R. Hossain, J. Romero, and J. J.

Little, "A simple yet effective baseline for 3d human pose estimation", Proc. IEEE Int. Conf. Computer Vision (ICCV), Venice, Italy, Vol. 17, pp. 2380-7504, Oct. 2017. <https://doi.org/10.1109/ICCV.2017.288>.

[2] D. Pavlo, C. Feichtenhofer, D. Grangier, and M. Auli, "3D human pose estimation in video with temporal convolutions and semi-supervised training", IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Long Beach, CA, USA, Jun. 2019. <https://doi.org/10.1109/CVPR.2019.00794>.

[3] C. Ionescu, D. Papava, V. Olaru, and C. Sminchisescu, "Human3.6M: Large Scale Datasets and Predictive Methods for 3D Human Sensing in Natural Environments", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 36, No. 7, pp. 1325-1339, Jul. 2014. <https://doi.org/10.1109/TPAMI.2013.248>.

[4] D. Mehta, H. Rhodin, D. Casas, P. Fua, O. Sotnychenko, W. Xu, and C. Theobalt, "Monocular 3D Human Pose Estimation in the Wild Using Improved CNN Supervision", 2017 International Conference on 3D Vision (3DV), Qingdao, China, Oct. 2017. <https://doi.org/10.1109/3DV.2017.00064>.

[5] T. v. Marcard, R. Henschel, M. J. Black, B. Rosenhahn, and G. Pons-Moll, "Recovering Accurate 3D Human Pose in the Wild Using IMUs and a Moving Camera", Proc. Eur. Conference Computer Vision (ECCV), Munich, Germany, Vol. 11214, pp. 614-631, Oct. 2018. https://doi.org/10.1007/978-3-030-01249-6_37.

[6] G. Varol, J. Romero, X. Martin, N. Mahmood, M. J. Black, I. Laptev and C. Schmid, "Learning from Synthetic Humans", IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, Jul. 2017. <https://doi.org/10.1109/CVPR.2017.492>.

[7] G. Rogez and C. Schmid, "MoCap-Guided Data Augmentation for 3D Pose Estimation in the Wild", Advances in Neural Information Processing

- Systems (NeurIPS), Barcelona, Spain, Dec. 2016. <https://doi.org/10.48550/arXiv.1607.02046>.
- [8] G. Pavlakos, X. Zhou, K. G. Derpanis, and K. Daniilidis, "Coarse-to-Fine Volumetric Prediction for Single-Image 3D Human Pose", IEEE Conference on Computer Vision and Pattern Recognition, Honolulu, HI, USA, Jul. 2017. <https://doi.org/10.1109/CVPR.2017.139>.
- [9] F. Moreno-Noguer, "3D Human Pose Estimation from a Single Image via Distance Matrix Regression", IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Honolulu, HI, USA, pp. 561-1570, Jul. 2017. <https://doi.org/10.1109/CVPR.2017.170>.
- [10] S. R. Richter, V. Vineet, S. Roth, and V. Koltun, "Playing for Data: Ground Truth from Computer Games", 14th European Conference on Computer Vision (ECCV), Amsterdam, The Netherlands, Sep. 2016. https://doi.org/10.1007/978-3-319-46475-6_7.
- [11] W. Qiu and A. Yuille, "UnrealCV: Connecting Computer Vision to Unreal Engine", Computer Vision - ECCV, Nov. 2016. https://doi.org/10.1007/978-3-319-49409-8_75.
- [12] Z. Cao, G. Hidalgo, T. Simon, S.-E. Wei, and Y. Sheikh, "OpenPose: Realtime Multi-Person 2D Pose Estimation using Part Affinity Fields", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 43, pp. 172-186, Jan. 2021. <https://doi.org/10.1109/TPAMI.2019.2929257>.
- [13] Z. Cao, G. Hidalgo, T. Simon, S.-E. Wei, Y. Raaj, H. Joo, and Y. Sheikh, "OpenPose: Real-time multi-person keypoint detection library for body, face, hands, and foot estimation", IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 43, No. 1, pp. 172-186, Jan. 2021. <https://doi.org/10.1109/TPAMI.2019.2929257>.

저자소개

루벤 에스페조 (Ruben D. Espejo Jr.)



2013년 4월 : STI 대학 컴퓨터학과 (학사)
2018년 4월 : President Ramon Magsaysay State University 컴퓨터학과(석사)
2024년 9월 ~ 현재 : 국립창원대학교

인공지능융합공학과 박사과정
관심분야 : 컴퓨터비전, 모션캡처

우 동 현 (Donghyun Woo)



2012년 2월 : 배재대학교 전자공학과(공학사)
2018년 8월 : 중국 동북전력대학교 정보및통신공학(공학석사)
2021년 3월 ~ 현재 : 국립창원대학교 첨단방위공학과정 박사과정

관심분야 : 컴퓨터비전, 증강/가상현실

김 중 락 (Joongrock Kim)



2005년 3월 : 고려대학교 전자정보 공학(공학사)
2005년 1월 ~ 2006년 7월 : 엠텍비전 연구원
2008년 8월 : 연세대학교 생체인식 공학(공학석사)
2014년 2월 : 연세대학교 전기전자

공학(공학박사)
2014년 2월 ~ 2024년 12월 : LG전자 CTO인공지능연구소 Vision Intelligence 연구실 팀장
2025년 1월 ~ 현재 : 국립창원대학교 인공지능융합공학과 부교수
관심분야 : 2D/3D 컴퓨터비전, 인공지능, On-Device