

# 컴퓨터 비전 정확도 향상을 위한 시뮬레이션 기반 가상 데이터 생성기법

강지수<sup>1</sup>, 최창범<sup>1</sup>, 장한얼<sup>1</sup>

<sup>1</sup>한밭대학교 컴퓨터공학과

dev.newjacob19@gmail.com, cbchoi@hanbat.ac.kr, hejang@hanbat.ac.kr

## Virtual Data Generation Method based on Simulation to Improve Accuracy of Computer Vision

Ji-Su Kang<sup>1</sup>, Chang-Beom Choi<sup>1</sup>, Han-Eol Jang<sup>1</sup>

<sup>1</sup>Dept. of Computer Engineering, Han-Bat University

### 요 약

기계학습 분야에서 모델을 학습시키려면 많은 양의 데이터가 필요하다. 최근에는 컴퓨터 비전 분야에서 데이터가 적은 환경에서 모델을 학습하는 다양한 방법들이 소개되고 있다. 하지만 대부분의 방법을 사용하기 위해서는 어느 정도 최소한의 학습 데이터가 필요하기 때문에 극심하게 데이터가 부족한 환경에서는 사용하기 어렵다. 본 논문에서는 컴퓨터 비전 분야에서 기계학습을 사용할 때 극심하게 데이터가 부족한 환경에서 시뮬레이션 도구를 활용한 인조 데이터 생성 방법을 제안한다. 실험 결과를 통해 시뮬레이션 도구를 활용하여 생성한 인조 데이터로 학습한 모델이 실제 데이터만을 학습한 모델을 대체할 수 있음을 확인하였고, F-1 점수와 정확도가 향상함을 실험적으로 확인하였다.

### 1. 서론

하드웨어의 발전과 다양한 인공지능 알고리즘의 개발로 인하여 많은 분야에 인공지능이 적용되고 있다. 특히 기계학습은 학습 데이터가 많고 정제되어 있는 경우 해당 응용 분야의 문제를 해결하는데 우수한 결과를 보이고 있다.

하지만, 기계학습을 적용하기 위해 필요한 데이터를 수집, 가공, 처리하는데 많은 시간과 비용이 소요된다. 또한, 데이터의 발생빈도가 희소하거나 시행을 많이 할 수 없는 상황이 존재할 수 있기 때문에 데이터를 구하기 어려울 수 있다.

특히 컴퓨터 비전 분야에서 기계학습에 활용할 데이터가 충분하지 않거나 데이터의 불균형한 상황에서의 학습 데이터 확보를 위하여 다양한 연구가 진행되고 있다. 대표적으로 데이터 증강[1], 전이 학습[2], 생산적 적대 신경망[3] 등이 있으나, 대부분의 방법은 기계학습을 수행하기 위한 최소의 데이터가 필요하며, 데이터를 생성하는 방법에 따라 정확성을 떨어뜨리거나 만들어진 데이터들의 분산이 적어 과적합 되어 인식률 저하 문제가 발생할 수 있다는 문제가 있다.

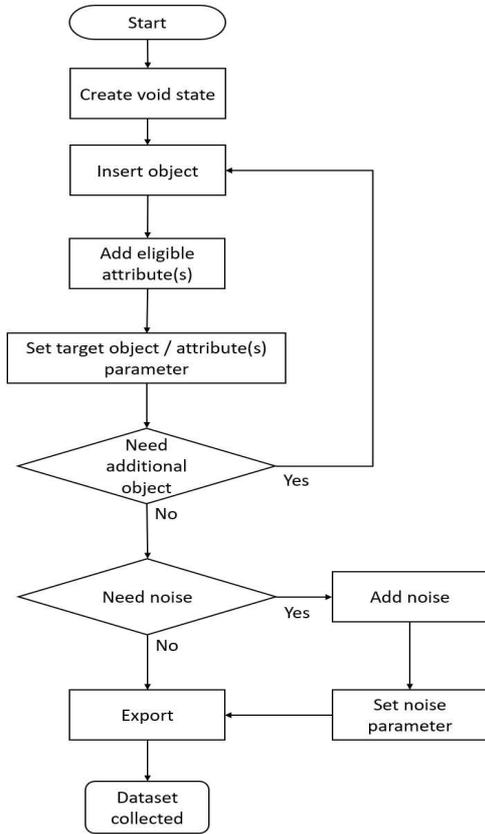
본 연구는 실제 데이터 확보에 제한이 발생할 수 있는 컴퓨터 비전 분야에서 기계학습을 적용할 수 있도록 하기 위해 시뮬레이션 기반의 데이터 생성기법을 제안한다. 제안하는 데이터 생성기법은 모델링 및 시뮬레이션 이론과 도구를 기반으로 현실에서 발생할 수 있는 형태의 데이터를 생성한다. 생성된 데이터는 다양한 기계학습 알고리즘에 활용되어 컴퓨터 비전 분야에서 활용할 수 있다.

본 논문의 2장에서는 본 연구에서 주장하는 시뮬레이션 도구를 활용하여 데이터를 생성하는 방법을 소개한다. 3장에서는 시뮬레이션 도구를 활용하여 생성한 데이터를 활용한 사례 연구 및 실제 데이터와 시뮬레이션 데이터의 성능 비교를 한다. 마지막 4장에서는 결론을 내린다.

### 2. 시뮬레이션 기반 학습 데이터 생성 방법

시뮬레이션 기반 학습 데이터 생성은 특정 도메인 분야에서의 시뮬레이션을 활용하여 현실 세계에서는 획득하기 어려운 데이터를 모델링 및 시뮬레이션 이론과 기법을 활용하여 데이터를 획득할 수 있으며 많은 시간과 비용을 들이지 않고 데이터를 생성할 수 있다는 장점이

있다.



(그림 1) 시뮬레이션 데이터 생성 순서

본 논문에서 제안하는 모델링 및 시뮬레이션을 활용하여 데이터 생성하는 과정은 다음과 같으며 순서도는 그림 1과 같다.

1. 기계학습 데이터를 생성하기 위한 대상을 식별하고 해당 체계의 특성에 대하여 모델링을 수행한다.

2. 모델링이 완료되면 기계학습 데이터를 생성시킬 대상 체계에 대하여 기계학습에서 필요한 데이터를 제외한 부수적인 데이터에 대한 통제를 수행하여 기계학습의 목적에 부합하는 데이터 생성이 가능하게 한다.

3. 대상 체계로부터 획득할 수 있는 데이터를 고려하여 다양한 특성들을 부여한다. 예를 들어 크기, 밝기, 색상 등 대상 객체가 가질 수 있는 특성들을 대상 체계에 추가한다.

4. 잡음에 강인한 기계학습 모델을 생성하기 위해 의도적으로 잡음이 될만한 데이터를 학습 데이터에 추가한다.

### 3. 사례 연구

도로 교통체계에서의 수신호 데이터의 경우 빠르게 이동하는 이동체에 카메라를 설치하고 이동하는 과정에서

취득한 데이터를 활용해야 하므로 데이터 취득이 어렵다. 또한, 수신호의 주체가 경찰, 소방관, 공사장 신호수 등으로서 다양하므로 데이터의 수가 많아 데이터 취득에 큰 비용이 소모될 수 있는 특징이 있다. 그리고 데이터 수집에 있어 자동차 정비, 경찰의 교통단속 등으로 인해 우측 수신호가 좌측 수신호보다 상대적으로 많으며 그로 인해 데이터 불균형의 문제가 있다.

#### 3.1 데이터 수집

기계학습을 위한 시뮬레이션 데이터를 생성하기 위해서 Magic Poser[4]라는 웹 기반 시뮬레이터로 사람의 관절을 움직여 포즈를 생성하여 크기, 밝기, 피부색, 그림자 등을 추가하여 시뮬레이션 인조 데이터를 생성하는 방법을 사용하였다.



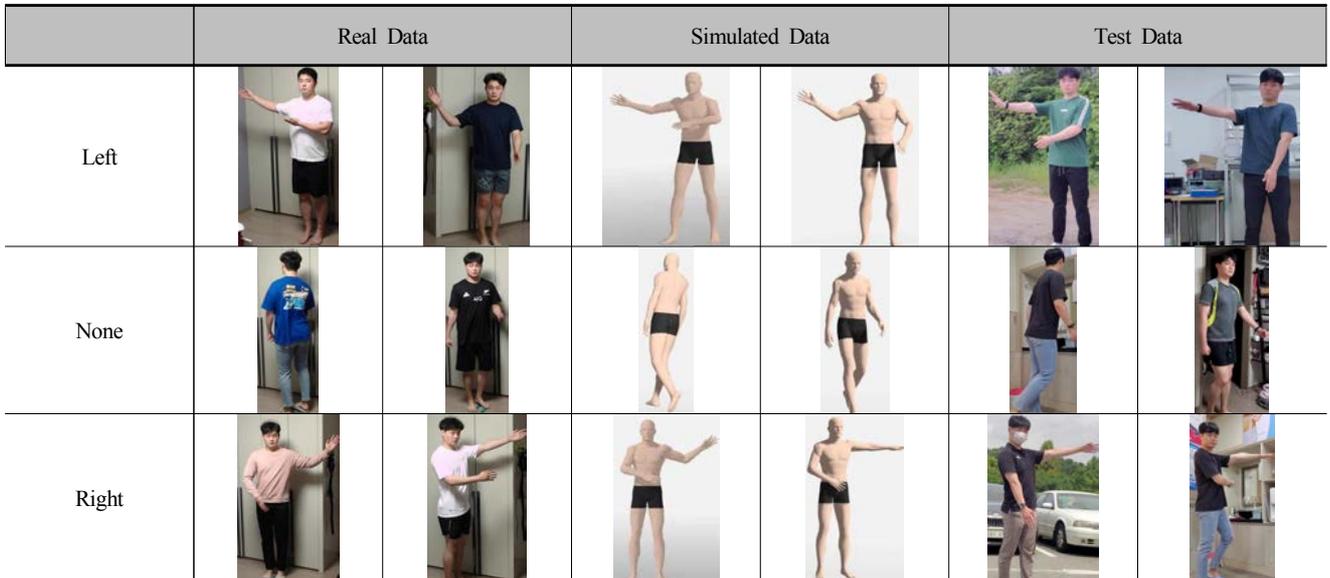
(그림 2) Magic Poser

본 연구에서는 Left, Right, None으로 수신호 포즈를 크게 3가지로 구별하였고, 각 포즈에는 2~3개의 핵심 포즈를 선정하였다. 선정한 포즈는 그림 3과 같으며, 수집한 데이터의 수는 표1과 같다.

<표 1> 수집된 데이터 개수

Data	Data amount	Left
		Right
		None
Real data (data imbalance)	1,500	200
		500
		800
Real data	2,400	800
		800
		800
Simulation data	2,400	800
		800
		800
Test data	2,400	800
		800
		800

1) 데이터가 불균형한 현실 데이터, 2) 데이터가 균형을 현실 데이터, 3) 본 연구에서 주장하는 시뮬레이션 데이터, 4) 성능 체크를 위해 배경이 복잡한 테스트 데이터로 수집하였다.



(그림 3) 현실, 시뮬레이션, 테스트 데이터 사진들

**3.2 실험 환경**

이미지 분류 모델로는 높은 정확도를 갖는 VGG-16[5]을 사용하였고, Loss 함수는 Cross Entropy 를 사용하였다. Optimizer로는 수렴이 빠른 Adam을 사용하였다. 네트워크의 구성에 맞춰 이미지는 224X224의 크기로 사용하였다[5].

**3.3 실험 결과**

모델의 성능평가는 Test data에 대한 정확도와 불균형한 데이터가 모델에 미치는 영향을 확인하기 위해 F-1 점수를 선택하였다. 각 데이터셋에 대한 결과는 표2 와 같다.

<표 2> 각 데이터셋 실험 결과

Data	Left	Left f-1 score	F-1 Score average	Model accuracy
	Right	Right f-1 score		
	None	None f-1 score		
Real data (data imbalance)	200	0.330	0.516	56.25%
	500	0.655		
	800	0.564		
Real data	800	0.450	0.607	63.58%
	800	0.696		
	800	0.674		
Simulation data	800	0.582	0.687	69.96%
	800	0.761		
	800	0.718		
Simulation data x2	1,600	0.730	0.750	75.20%
	1,600	0.779		
	1,600	0.743		

불균형한 현실 데이터가 가장 낮은 결과를 보였고, 균형한 현실 데이터는 좀 더 높은 결과를 보였다. 제안한 시뮬레이션 데이터는 데이터의 분산이 적어 균형한 현실 데이터 대비 높은 정확도를 얻은 것으로 보이며, 시뮬레이션 데이터를 더 많이 획득하였을 때는 75.2%로서 실 생활에 사용 가능할 정도의 높은 정확도를 보였다.

**4. 결론**

본 논문에서는 기계학습 정확도 향상을 위한 시뮬레이션 데이터 생성기법을 제시했다. 현실의 데이터는 시간과 비용의 제한으로 인하여 실제 사용할 수 있을 정도로 높은 정확도를 얻을 만큼의 데이터를 획득하기에는 어려움이 있으나 시뮬레이션 데이터의 경우 양질의 데이터를 생성할 수 있다는 장점이 있어 대상 객체가 가질 수 있는 특성의 종류와 양, 크기를 다변화함으로써 도메인 별로 최적화된 시뮬레이션 데이터 생성기법에 대한 연구가 향후 연구로 고려될 수 있다.

**참고문헌**

[1] Shorten, Connor, and Taghi M. Khoshgoftaar. "A survey on image data augmentation for deep learning." Journal of big data 6.1, 1-48. (2019)  
 [2] Torrey, Lisa, and Jude Shavlik. "Transfer learning." Handbook of research on machine learning applications and trends: algorithms, methods, and techniques. IGI global, 242-264 . (2010)  
 [3] Goodfellow, Ian, et al. "Generative adversarial networks." Communications of the ACM 63.11. 139-144. (2020)  
 [4] <https://magicposer.com>  
 [5] Simonyan, Karen, and Andrew Zisserman. "Very deep convolutional networks for large-scale image recognition." arXiv preprint arXiv:1409.1556 (2014).