

# 시뮬레이션 되는 휴머노이드 컨트롤을 위한 잠재변수 매칭\*

김민수<sup>0</sup>, 이윤상

한양대학교 인공지능학과, 한양대학교 컴퓨터 소프트웨어학과  
igotaspot426@gmail.com, yoonsanglee@hanyang.ac.kr

## Latent Matching for Simulated Humanoid Control

Minsu Kim<sup>0</sup>, Yoonsang Lee

Dept. of Artificial Intelligence, Hanyang University, Dept. of Computer Science, Hanyang University

### 요약

본 연구에서는 참조 모션 데이터셋을 추종하도록 사전 학습된 물리 기반 캐릭터의 저수준 정책 모델을 이용해, 사용자의 실시간 입력을 따르도록 캐릭터를 제어하는 잠재변수 매칭 기법을 제안한다. 이 기법을 통해 추가적인 고수준 정책의 학습 없이도 사용자가 시뮬레이션 되는 캐릭터의 이동 속력, 방향 등을 실시간으로 제어할 수 있다.

### 1. 서론

물리 기반 환경에서 시뮬레이션 되는 휴머노이드 캐릭터를 자유롭게 움직이도록 제어하는 방법은 게임, 가상현실, 시뮬레이션 분야에서 중요한 주제이다. 물리법칙에 의해 캐릭터의 움직임이 제약을 받기 때문에 물리 기반 캐릭터 컨트롤은 최적화가 어렵다. 한 편 최근 심층강화학습의 발전으로 인해, 물리 환경의 캐릭터의 보행 뿐만 아니라 난이도가 높은 묘기까지 보여줄 수 있게 되었다. 최근에는 적은 양의 모션이 아닌 많은 양의 모션 시퀀스를 잠재공간에 임베딩하는 사전학습 모델이 등장하면서 물리 기반 캐릭터 연구가 가속되었다. 이 사전학습 모델에 추가적인 모델을 연결해 특정 태스크를 수행하는 계층적 구조의 에이전트의 구조가 많이 연구되었고, 기존에는 볼 수 없었던 자연스러우면서 다양한 높은 품질의 움직임을 보여줄 수 있었다. 그러나 이러한 계층적 구조는 추가적인 심층강화학습 에이전트의 학습과 모델, 그리고 복잡한 보상 설계가 요구된다.

우리는 운동학적 캐릭터 애니메이션 제어를 위해 많이 사용되는 모션 매칭 기법에 영감을 받아 [1, 2], 추가적인 모델과 학습 없이 기존에 사전 학습된 저수준 정책 모델만으로 시뮬레이션 되는 캐릭터를 실시간으로 제어할 수 있는 방법인 잠재변수 매칭 기법을 제안한다.

### 2. 물리 기반 모션 임베딩 모델

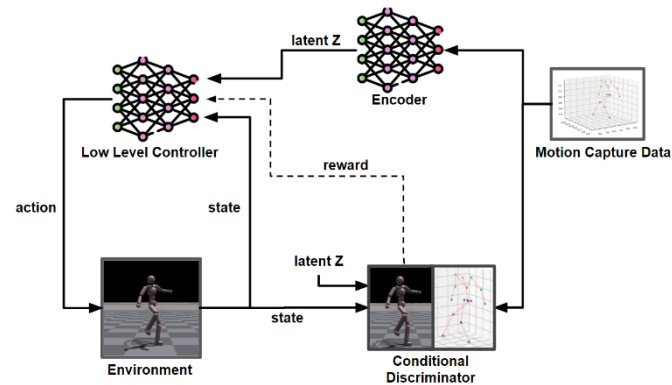


그림 1: 물리 기반 모션 임베딩 모델 구조

물리 기반 모션 임베딩 모델은 모션 데이터셋의 임의의 모션 시퀀스를 잠재공간의 특정 포인트에 임베딩하는 모델로서, 임베딩 된 포인트가 캐릭터의 상태와 함께 저수준 정책 네트워크에 입력되면 해당 모션 시퀀스를 재현할 수 있는 액션을 출력하도록 임베딩을 담당하는 인코더와 저수준 정책이 함께 학습된다. 우리는 물리 기반 모션 임베딩 모델의 학습을 위해 CALM [3]에서 제안한 방법을 사용하였다. 이 모델은 동시에 학습되는 판별자가 물리 환경에서 시뮬레이션 된 모션과 원본 모션 시퀀스와의 차이를 구분을 하지 못할 수록 높은 보상을 얻도록 강화학습 프레임워크에서 학습이 된다. 인코더, 판별자, 정책은 한꺼번에 end-to-end로 학습이 된다. 저수준 정책 모델은 상태와 잠재변수를 입력받고 액션을

\* 구두 발표논문, 요약논문 (Extended Abstract)

\* 본 논문은 요약논문 (Extended Abstract) 으로서, 본 논문의 원본 논문은 현재 타 학술대회 (논문지)에 제출 준비중임.

\* 본 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(RS-2023-00222776) 과 정보통신기획평가원의 지원(No.RS-2020-II201373, 인공지능대학원지원(한양대학교)) 과 문화체육관광부 및 한국콘텐츠진흥원의 2024 년도 문화체육관광 연구개발사업 지원을 (RS-2024-00399136) 받아 수행되었음.

출력한다. 잠재변수는 인코더 모델의 출력으로부터 얻을 수 있다. 인코더는 모션 시퀀스를 단일 잠재변수로 변환하는 역할을 하기 때문에 상태의 시퀀스를 입력으로 받는다. 결과적으로 원본 모션 시퀀스는 인코더에 의해 특정 잠재변수로 변환이 되고, 학습이 완료되면 인코더 없이 학습된 잠재변수만으로 저수준 정책 모델의 입력으로 사용될 수 있다. 그림 1 은 물리기반 모션 임베딩 모델의 구조를 보여주고 있다.

#### 4. 잠재변수 매칭

우리가 제안하는 잠재변수 매칭 방법은 우선 현재 캐릭터의 상태와 유저의 입력을 조합하여 쿼리 feature를 만들고, 모션 데이터베이스의 각 프레임에 해당하는 feature를 미리 계산하여 저장해놓은 feature 데이터베이스에 이를 쿼리하여 가장 가까운 feature에 해당하는 모션 프레임을 찾는다. 모션 매칭에서는 해당 모션 프레임부터 캐릭터 모션을 재생하지만, 우리의 잠재변수 매칭 방법에서는 해당 모션 프레임에 해당하는 잠재변수를 계산하여 이를 저수준 정책에 입력으로 제공하여 캐릭터의 동작을 제어하게 된다. 우리가 쿼리에 사용하는 feature는 다음과 같은 27 차원의 벡터이다.

$$\mathbf{x}_i = \{\mathbf{p}_i^{LH}, \mathbf{p}_i^{RH}, \mathbf{p}_i^{LF}, \mathbf{p}_i^{RF}, \mathbf{v}_i^{root}, \mathbf{t}_i, \mathbf{d}_i\} \in \mathbb{R}^{27}$$

$\mathbf{p}_i^{LH}, \mathbf{p}_i^{RH}, \mathbf{p}_i^{LF}, \mathbf{p}_i^{RF}$  는 각각 양 손과 양 발의 위치를 의미하는 3 차원 벡터이다.  $\mathbf{v}_i^{root}$  는 캐릭터의 루트의 속도를 의미하는 3 차원 벡터이고,  $\mathbf{t}_i$  는 루트의 미래 세 시점에 대한 평면 위치인 6 차원 벡터이며,  $\mathbf{d}_i$  는 루트의 미래 세 시점에 대한 평면 각도인 6 차원 벡터이다. 그림 2 에서 잠재변수 매칭의 구조를 볼 수 있다.

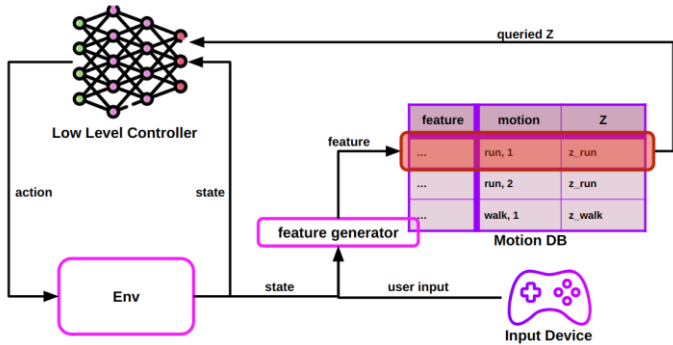


그림 2: 잠재변수 매칭 구조

#### 5. 실험

우리는 잠재변수 매칭의 정성적 평가를 위해 매칭 주기를 변화시켜 가며 시뮬레이션 결과를 확인했고 그림 3 은 그 결과를 4 개의 프레임에 대해 캡처한 이미지다. 매칭 주기  $n$  은  $n=1, 5, 10$  으로 3 가지로 했는데, 여기서  $n$  은 프레임 단위이고  $n=1$  일 때는 매 프레임마다 쿼리를 수행한다는 의미이다.

$n=10$  일 때는 캐릭터의 움직임이 부드럽지 못한 결과를 보여주었다.  $n=5$  일 때는 부드러우면서 충분히 민첩한 움직임을 볼 수 있었다.  $n=1$  때는 비교적 더 민첩하고 부드럽게 움직이지만, 매 프레임마다 매칭하기 때문에 연산 오버헤드가 발생해 fps가 떨어지는 것을 확인했다.

그림은 우리의 잠재변수 매칭 기법이 보행뿐만 아니라 게임패드의 특정 버튼을 눌러 점프 모션까지 수행할 수 있음을 보여준다. 이 때 버튼을 누르면 점프 모션을 하도록 명령하는 것이 아니라, 그 순간 만들어진 feature값을 쿼리한 결과가 점프 모션의 특정 프레임과 가장 가깝기 때문에 점프 모션에 대한 잠재변수를 반환하고 저수준 정책이 점프 모션을 시뮬레이션 하게 되는 것이다.

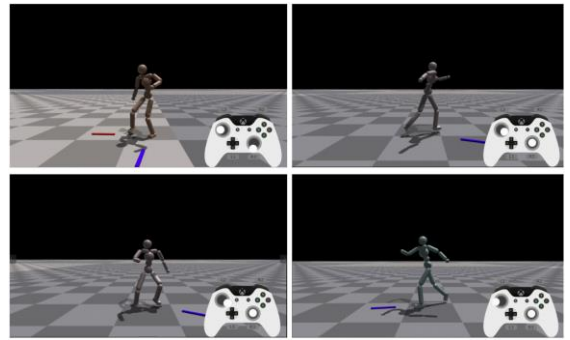


그림 3: 잠재변수 매칭 결과

#### 6. 결론

우리의 잠재변수 매칭 기법은, 사전학습한 물리기반 모션 임베딩 모델에 추가적인 학습없이 사용자의 입력에 기반한 컨트롤을 가능하도록 한다. 우리는 CALM [3]에 기반한 물리기반 모션 임베딩 모델을 통해 잠재공간을 사전학습했다. 우리의 제안은 상황에 맞는 적절한 잠재변수들을 찾아내는 방법으로 그 어떤 물리기반 모션 임베딩 모델에도 적용될 수 있는 방법이며 앞으로 다양한 방향의 추가 연구가 가능할 것이다.

#### 참고문헌

[1] CLAVET S.: Motion matching and the road to next-gen animation, In Proc. of Game Developers Conference (GDC) (2016)  
 [2] Lee Jeongmin, Taesoo Kwon, Hyunju Shin, Yoonsang Lee, Utilizing Motion Matching with Deep Reinforcement Learning for Target Location Tasks, Eurographics 2024 Short Papers, April 2024  
 [3] Chen Tessler, Yoni Kasten, Yunrong Guo, Shie Mannor, Gal Chechik, and Xue Bin Peng. 2023. CALM: Conditional Adversarial Latent Models for Directable Virtual Characters. In ACM SIGGRAPH 2023 Conference Proceedings (SIGGRAPH '23). Association for Computing Machinery, New York, NY, USA, Article 37, 1–9.