

물리기반 캐릭터의 축구 드리블 스킬 학습*

김민수⁰, 이윤상
한양대학교 인공지능학과, 한양대학교 컴퓨터 소프트웨어학과
igotaspot426@gmail.com, yoonsanglee@hanyang.ac.kr

Learning Football Dribble Skills for Physics Based Character

Minsu Kim⁰, Yoonsang Lee
Dept. of Artificial Intelligence, Hanyang University, Dept. of Computer Science, Hanyang University

요약

우리는 물리 시뮬레이션 되는 휴머노이드 캐릭터가 축구공으로 드리블할 수 있도록 하는 정책을 학습하는 방법을 제안한다. 다양한 축구 모션 캡처 데이터를 잠재공간에 임베딩하고, 상황에 따라 적절한 잠재변수를 활용해 공과 복잡한 상호작용하는 드리블 정책을 학습시켰다.

1. 서론

드리블은 축구선수에게 기본적인 동시에 중요한 스킬이다. EA SPORTS FC, eFootball와 같은 축구 게임에서도 축구선수 캐릭터가 드리블하는 것이 게임 플레이의 주요 부분 중 하나이지만, 완전한 물리 시뮬레이션에 기반하지 않다 보니 선수의 동작과 공의 움직임이 실제 축구와는 차이가 있다. 완전한 물리 시뮬레이션을 통해 계산된 캐릭터의 동작과 축구공과의 움직임을 통해 드리블 스킬을 구현하게 되면 이러한 축구 게임의 사실성 향상에 크게 도움이 될 수 있을 뿐만 아니라, 물리 시뮬레이션에 기반한 축구선수의 퍼포먼스 분석 및 예측을 가능하게 하는 등 스포츠 사이언스 관점에서의 기여도 가능할 것이다. 이전에도 물리기반 캐릭터가 축구공을 드리블하는 것을 보여준 연구들이 있었지만, 걸으면서 공을 다루거나 [1] 동작이 부자연스럽거나 [2] 축구공과 선수 사이의 거리를 가깝게 유지하지 못하는 [3] 등의 한계점들이 있었다. 이에 우리는 심층강화학습을 통해 물리기반 캐릭터가 기민하게 드리블을 할 수 있도록 하는

정책을 학습하는 방법을 제안한다. 특히 게임과 같은 인터랙티브 애플리케이션에 적용가능 하도록 우리는 사용자의 실시간 입력에 기반하여 조종되는 캐릭터가 공을 드리블할 수 있도록 하는 것에 초점을 맞추었다.

2. 물리기반 모션 임베딩 모델

물리기반 모션 임베딩 모델은 잠재공간에 모션 시퀀스를 임베딩하는 모델이다. 모션 시퀀스는 주로 모션 캡처 데이터에서 추출되고 각 시퀀스는 잠재공간의 특정 포인트에 의해 표현된다. 우리는 물리기반 모션 임베딩 모델 학습을 하기 위해서 저수준 정책과 인코더, 판별자를 학습하는 CALM [4]의 방법을 사용하였다. 인코더는 고차원의 모션 시퀀스를 입력으로 받아 저차원의 잠재변수로 변환하여 출력하는 역할을 하며, 저수준 정책은 인코더로부터 만들어진 잠재변수와 캐릭터의 상태가 합쳐진 벡터를 입력으로 받고 시뮬레이션에 필요한 액션을 출력한다. 판별자는 시뮬레이션 된 모션과 원본 모션 시퀀스와 차이를 구분하지 못하면 높은 보상을 얻게 되는데, 이 보상 신호를 이용해 인코더와 저수준 정책, 판별자가 한꺼번에 end-to-end로 학습된다. 물리기반 모션 임베딩 모델의 학습이 완료되면 모션 시퀀스를 잠재변수로 변환하는 인코더의 역할은 더 이상 필요하지 않으므로 런타임에는 인코더를 제거해도 되며, 저수준 정책 모델에는 캐릭터의 상태와 학습된 잠재변수만을 입력으로 넣어서 캐릭터를 컨트롤 할 수 있다.

3. 드리블 정책 학습

학습에 사용된 축구 스킬 모션 캡처 데이터는 공과 상호작용하는 부분의 정보가 없는 데이터다. 따라서 모션이 임베딩 되어도 캐릭터가 축구공과 물리적으로 상호작용하고 컨트롤하는 능력은 추가로 학습을 해야

* 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.

한다. 그렇기 때문에 모델을 계층적으로 구성하고 드리블하는 정책을 학습시켰다.

고수준 정책 모델은 입력으로 캐릭터의 상태와 유저 입력 (목표 속도, 목표 방향)을 받고 잠재변수를 출력한다. 이 고수준 정책 모델은 미리 학습된 저수준 정책모델에 연결되어 계층적인 모델 구조를 갖는다. 이 두 모델은 함께 시뮬레이션 되며 학습하지만 저수준 정책의 파라미터는 고정되어 고수준 정책 모델만 학습이 된다.

고수준 정책을 학습하는데 사용된 보상 함수는 다음과 같다.

$$r_t = 0.3 \exp\left(-10\left(\mathbf{x}_t^{root} - \mathbf{x}_t^{ball}\right)^2\right) + 0.3 \exp\left(-\left(\mathbf{v}_t^{tar} - \mathbf{v}_t^{ball}\right)^2\right) + 0.4 \mathbf{d}_t^{tar} \cdot \mathbf{d}_t^{ball}$$

\mathbf{x}_t^{root} 와 \mathbf{x}_t^{ball} 는 각각 캐릭터와 공의 위치이며 \mathbf{v}_t^{tar} 와 \mathbf{v}_t^{ball} 는 각각 목표 드리블 속력과 공의 목표 드리블 방향으로의 속력이다. \mathbf{d}_t^{tar} 와 \mathbf{d}_t^{ball} 는 각각 목표 드리블 방향, 공의 이동 방향을 의미한다.

4. 실험

학습환경은 Isaac Gym을 사용했고 빠른 학습을 위해 4096 개의 환경을 병렬적으로 실행시켜 데이터를 수집하고 policy 를 학습했다. 학습은 에피소드 단위로 진행되는데 에피소드 길이는 300 프레임으로 고정하고 목표 속력과 목표 방향을 랜덤으로 설정한다. 150 ~ 200 프레임 시점에 목표 방향과 목표 속력을 한 번 재설정하는데, 이를 통해 방향 및 속도 변화에 자연스럽게 대응하는 능력을 획득하게 하였다.

자연스러운 축구공 컨트롤을 위해 실제와 비슷한 공의 물리량을 설정하였다. 축구공의 크기는 공식 경기에 사용되는 크기인 22cm이고, 질량은 200g으로 설정하였으며, 반발계수는 0.8 로 설정하였다.

드리블을 잘 하기 위해서 발의 모양을 적절한 메쉬로 설정할 필요가 있었다. 저수준 정책 모델을 학습할 때 사용한 휴머노이드의 발 메쉬 부분을 축구화 메쉬로 대체하였다. 축구화 메쉬가 아닌 단순한 박스 형태의 발 메쉬로 학습하면 드리블을 전혀 학습하지 못하는 것을 확인했다.

우리가 모션 저수준 정책을 학습할 때 사용한 데이터셋은 총 n 개 모션이 x 분 분량의 축구 스킬 모션 캡처 데이터로, 걷기, 뛰기, 슈팅, 드리블 등이 포함되어 있다.

우리는 보상 설계의 차이에 따라 드리블 능력을 실험했다.

최대 목표 드리블 속력을 5m/s, 7.5m/s, 10m/s 로 설정하고 학습한 후 비교하였다. 원본 모션 캡처 데이터에 달리는 모션의 최대 속력이 초속 약 5 m/s 라서 학습할 때도 최대 속력을 5 m/s로 기본값으로 설정하였다. 학습할 때 최대 속력을 7.5 m/s 로 설정하면 드리블 능력을 유지하는 선에서 최대 약 6 m/s까지 드리블하는 모습을 보여준다. 하지만 학습할 때 최대 속력을 10 m/s 로 설정하면 드리블을 전혀 하지 못하는 것을 확인했다.

학습한 후에는 게임패드를 연결하고 고수준 정책에 유저 입력 (목표 방향, 목표 속도)으로 입력해줘서 직접 컨트롤 할 수 있다. 그림 1 은 유저 입력에 의해 드리블 스킬이 시뮬레이션 되고 있는 모습을 보여주고 있다.




그림 1: 런타임에 시뮬레이션 되고 있는 드리블 스킬

5. 결론

우리는 심층강화학습을 통해 물리기반 캐릭터의 사실적이고 민첩한 축구 드리블 정책을 학습하는 방법을 제안했다. 적절한 보상설계와 학습 환경 구성으로 유저 입력에 민첩하게 반응하는 드리블 스킬을 배우게 할 수 있음을 보였다. 추후에는 더 다양한 축구 스킬들을 학습하고 물리환경에서 플레이할 수 있는 축구게임을 위한 기반 연구를 고려할 수 있다.

참고문헌

- [1] Xue Bin Peng, Glen Berseth, Kangkang Yin, and Michiel Van De Panne. 2017. DeepLoco: dynamic locomotion skills using hierarchical deep reinforcement learning. ACM Trans. Graph. 36, 4, Article 41 (August 2017), 13 pages.
- [2] S. Liu, G. Lever, Z. Wang, J. Merel, S. M. A. Eslami, D. Hennes, W. M. Czarnecki, Y. Tassa, S. Omidshafiei, A. Abdolmaleki, N. Y. Siegel, L. Hasenclever, L. Marris, S. Tunyasuvunakool, H. F. Song, M. Wulfmeier, P. Muller, T. Haarnoja, B. D. Tracey, K. Tuyls, T. Graepel, and N. Heess, From motor control to team play in simulated humanoid football, Science Robotics, vol. 7, no. 69, 2022
- [3] Seokpyo Hong, Daseong Han, Kyungmin Cho, Joseph S. Shin, and Junyong Noh. 2019. Physics-based full-body soccer motion control for dribbling and shooting. ACM Trans. Graph. 38, 4, Article 74 (August 2019), 12 pages.
- [4] 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.