

학습 기반 상태 전이 함수를 사용한 Kinodynamic 플래닝

*장진혁, **윤성의

*한국과학기술원 로봇공학학제

**한국과학기술원 전산학부

e-mail : mrjohd@kaist.ac.kr, sungeui@kaist.edu

Learning-based State Propagator for Kinodynamic Planning

*Jin-Hyeok Jang, **Sung-Eui Yoon

*Robotics Program

Korea Advanced Institute of Science and Technology

**School of Computer Science

Korea Advanced Institute of Science and Technology

Abstract

Kinodynamic planning deals with the physical effects of systems while conducting motion planning. Depending on problems, it is hard to model the state equations of the system under the study. To solve such a problem, physics engine has been considered as one of the valid methods. In this paper, we present a learning-based state propagator for kinodynamic planning, which approximates the system's state response. Our state propagator learns the pairs of states, controls, duration, and corresponding states of the system using neural networks. This state propagator makes a planner consider state response of the system whose state equation is unknown. We compare the performance of the learning-based state propagator with the one using a physics engine. We show that our method finds a path faster with more samples.

I. 서론

Kinodynamic 플래너는 장애물 회피뿐 아니라 최대 속도, 가속도와 같은 주어진 시스템의 기구학적, 동역학적 제약조건(kinodynamic constraint)을 함께 고려하여 경로를 생성한다[1]. 그 과정에서 시스템의 상태를 묘사하기 위한 상태 벡터 X 가 고차원화 되기 때문에 주로 샘플링 기반 플래너를 채택한다. 샘플링 기반 플래너는 탐색 트리에 새로운 상태들을 추가하여 경로탐색을 진행하는데 상태를 예측하기 위해서 상태함수 $\dot{X} = f(X, u)$ 가 필요하다. 그러나 [2]에서 볼 수 있는 chain robot과 같이 자유도가 높은 시스템의 상태함수를 수식적으로 구하는 것이 어려운 경우가 있어 물리엔진이 사용되어 왔다. 그러나 물리엔진은 반복적 계산을 통하여 상태를 예측하므로 상태 전이 계산이 느리다는 단점이 있다[3].

본 연구에서는 물리 엔진을 사용하던 부분을 학습기반의 상태 전이 함수로 대체하는 방법을 제안하였으며, 이를 통하여 물리엔진을 사용했을




그림 1. 학습 기반 상태 전이 함수 신경망 구조

때보다 많은 샘플 수로 빠르게 경로를 찾을 수 있는 kinodynamic 플래너를 제안한다.

II. 본론

2.1 학습 기반 상태 전이 함수

본 연구는 인공 신경망 구조를 사용하여 물리엔진의 반복적 계산법보다 빠르게 상태 전이를 계산할 수 있는 함수 $X_{new} = F(X, u)$ 를 근사적으로 구했다(X 는 현재 상태, X_{new} 는 새로 얻어진 상태, u 는 제어입력을 의미한다.). 학습 모델은 3개층의 multi layered perceptron으로 구성된 인공 신경망 모델이며, 내부의 비선형 활성화 함수(ReLU)를 통해 비선형의 상태 전이 함수를 학습한다(그림 1).

데이터는 differential drive vehicle 모델을 물리엔진에 적용하여 얻은 입력, 출력 쌍을 사용하며 입력은 6차원 벡터, 출력은 3차원 벡터로 구성되어 있다. 입력 데이터는 현재 상태(x, y, Φ (yaw))와 양쪽 바퀴의 속도(제어입력, ω_l, ω_r) 그리고 상태 전이 시간(t)로 이루어진 6차원 벡터이다. 출력 데이터는 다음 상태(x, y, Φ)의 3차원 벡터로 구성되며 학습에 총 300,000개의 데이터가 사용되었다.

그림 2는 500개의 랜덤 입력 데이터에 대한 물리엔진과 제안 모델의 차이를 보여준다. 붉은 색은 물리엔진의 계산 결과이며, 청록색은 제안 모델의 계산 결과이다. 제안 모델의 결과가 물리엔진의 결과와 대부분 일치하며, 이들의 mean square error는 대략 0.14로, 40m x 40m 크기의 환경에서 10cm 정도의 차이가 나는 정도이다.

2.2 Kinodynamic 플래닝

본 연구에서는 샘플링 기반의 kinodynamic 플래너로서 RRT[4]를 기초로 하였다.




그림 2. 제안모델과 물리엔진의 계산 결과 비교

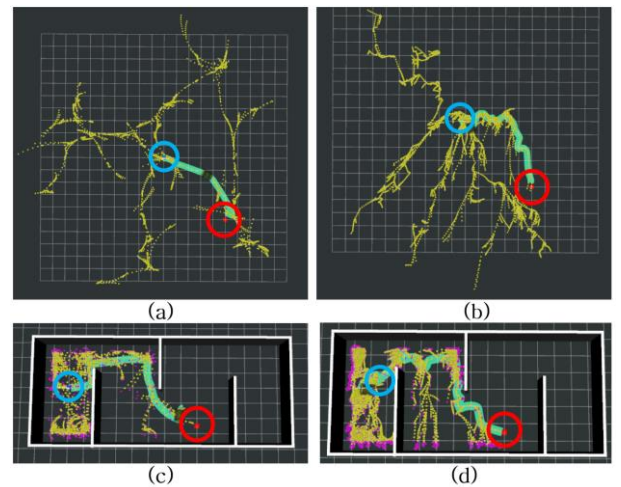


그림 3. 물리엔진과 제안 모델을 상태 전이 함수로 썼을 경우의 탐색 트리와 경로.

	물리엔진	제안 모델
평균 샘플 수(개)	4,163	27,148

(A)

장애물 없는 경우	물리엔진	제안 모델
플래닝 시간(초)	190.8	32.83
성공률(%)	70	100

(B)

장애물 있는 경우	물리엔진	제안 모델
플래닝 시간(초)	134.6	76.61
성공률(%)	70	90

(C)

표 1. (A) 평균 샘플 수, (B) 장애물이 없는 경우, (C) 장애물이 있는 경우의 10회 실험 평균값.

탐색 트리 $T = (V, E)$ 를 확장하기 위하여 먼저 탐색 트리에서 현재 샘플 X_{rand} 로부터 거리가 가장 가까운 노드 X_{near} 를 찾는다. 그 후 해당 노드에서 현재 샘플까지 제어입력 u 에 대하여 상태 전이 함수 $X_{new} = F(X_{near}, u)$ 를 계산해 새로운 상태들을

얻는다. 이러한 과정을 통하여 얻은 상태들로 만들어진 탐색 트리를 통하여 기구학적, 동역학적 제약조건을 만족하는 경로를 생성한다.

본 연구에서는 제안된 학습기반의 상태 전이 함수를 kinodynamic 플래너에 적용하였을 때 물리엔진에 비해서 빠르게 경로를 찾을 수 있음을 보인다. 이를 위해 물리엔진을 상태 전이 함수로 사용한 경우와 학습기반 상태 전이 함수를 사용한 경우를 비교하였다. 사용된 지표는 주어진 시간동안 취득된 총 샘플의 숫자 및 플래닝 시간, 성공률이다.

그림 3(a)(b)는 20m X 20m 크기의 장애물이 있는 환경, 그림 3(c)(d)는 15m X 5m 크기의 장애물이 없는 환경이며 (a)와 (c)는 물리엔진을 사용한 경우, (b)와 (d)는 제안 모델을 사용한 경우 탐색 트리와 path를 보여준다. 파란 원은 시작지점, 붉은 원은 목표지점을 나타낸다. 실험은 각각 10회씩 진행하였으며 사용된 각 바퀴의 최대 속도(최대 제어입력)는 10m/s이다.

표 1의 (A)항목에서는 그림 3 (a)(b)와 같은 장애물이 없는 환경에서 주어진 시간 300초 동안 각 방식의 평균 샘플 수를 표기하였다. (B), (C)는 각각 장애물이 없는 환경과 장애물이 있는 환경에서 플래닝 시간과 성공률의 평균값을 비교하였다(성공률은 환경의 크기 차이로, 장애물 없는 환경은 300초, 장애물이 있는 환경은 150초 이내에 경로를 생성하지 못한 경우를 기준으로 측정하였다). 평균 샘플개수는 많을수록 좋으며, 플래닝 시간은 짧을수록, 성공률은 높을수록 좋다. 이를 통해서 학습기반의 상태 전이 함수가 장애물이 없는 경우 1.88배, 장애물이 있는 경우 3.03배 가량 더 많은 샘플을 확보할 수 있으며 동시에 장애물이 없는 경우 5.81배, 장애물이 있는 경우 1.76배 더 빠르게 경로를 찾을 수 있음을 확인할 수 있다. (A)항목을 통하여 학습기반의 상태전이 함수를 사용한 경우 동일 시간대비 더 많은 수의 샘플을 얻을 수 있음을 알 수 있다. 즉 샘플링 기반 플래너의 특성상 제안한 모델을 사용할 경우 빠르게 경로를 찾을 수 있다. 특히 장애물이 있는 경우에도, 많은 샘플 수를 바탕으로 보다 빠르게 경로를 찾을 수 있다(그림 3(c)(d), 표 1(C)).

III. 결론 및 향후 연구 방향

본 논문에서는 인공 신경망 구조를 사용하여 시스템의 상태 전이를 계산할 수 있는 함수를 적용한 kinodynamic 플래너를 제안하였다. 이를 통하여

물리엔진을 사용했을 경우보다 빠르게 많은 수의 샘플을 확보하여 주어진 시간 내에 높은 성공률로 경로를 찾는 성능을 보였다. 향후 연구로는 이전과 이후 상태들을 독립적으로 학습하는 것이 아닌 연속적인 데이터의 연관성을 학습할 수 있는 네트워크 구조를 적용할 수 있을 것이다. 이를 통하여 실제 시스템의 물리적 특성을 반영한 상태 전이 함수를 학습할 수 있을 것으로 예상된다.

참고문헌

- [1] S. M. LaValle and J. J. Kuffner, "Randomized kinodynamic planning," *The International Journal of Robotics Research*, vol. 20, no. 5, pp. 378-400, 2001.
- [2] I. Sucas and L. E. Kavraki, "A sampling-based tree planner for systems with complex dynamics," *Robotics, IEEE Transactions on*, vol. 28, no. 1, pp. 116-131, 2012.
- [3] Junghwan Lee et al., "Data-driven kinodynamic RRT", *International Conference on Advanced Robotics (ICAR)*, 2017
- [4] S.M. LaValle "Rapidly-exploring random trees: a new tool for path planning", *Technical Report. Computer Science Department, Iowa State University (TR 98-11)*