크리틱의 불확실성을 낮추는 액터 목적함수를 통해 강화학습 알고리즘 DDPG 성능 향상에 관한 연구

김형진, 이정우*
서울대학교

kevin909@snu.ac.kr, junglee@snu.ac.kr*

A Study on the Improvement of DDPG Performance by Lowering the Uncertainty of Critic through Objective Function

Kim Hyung Jin, Lee Jung Woo*
Seoul National Univ.

요 약

본 논문은 강화학습의 크리틱의 불확실성을 낮춤으로써 모델 성능 향상을 이끌어내기 위한 목적함수를 설정하였다. 이를 강화학습 알고리즘 DDPG 에 적용한 알고리즘을 Mujoco 환경에 실험해본 결과 유의미한 성능 향상을 확인할 수 있었다.

Ⅰ. 서 론

본논문에서는 액터-크리틱류의 강화학습 알고리즘에서 크리틱의 불확실성을 낮추는 것이 학습을 향상시킨다는 것을 실험적으로 보였다. 크리틱의 불확실성에 대한 패널티를 액터의 목적함수에 적용하여 크리틱의 불확실성을 줄이는 식의 업데이트 방식을 사용했다. 본논문에서는 DDPG 알고리즘에 이 아이디어를 적용하여 OpenAI gym Mujoco 의 여러 환경에서 실험을 하였고 이를 통해 강화학습 알고리즘 학습 정도를 향상시킨 것을 확인할 수 있었다.

Ⅱ. 본론

본논문에서는 크리틱의 불확실성을 줄이기 위해 액터의 목적함수에서 페널티로 추가하였다. 액터-그리틱류의 강화학습 알고리즘에서 보편적으로 적용할 수 있게 기존 알고리즘의 목적함수에 더하는 방식을 채택하였다.[1] 본논문에서는 액터-크리틱 방식 중 하나인 DDPG 에 적용하였다.[2] 본논문에서 DDPG 에 적용한 액터의 목적함수는 다음과 같다.

$$J(\theta) = E[Q_{\omega}(s_t, \mu_{\theta}(s_t)) - \alpha * \sigma]$$

θ 는 액터의 매개변수, s_t는 시간 t 에서의 상태, ω 는 크리틱의 매개변수, μ_{θ}는 θ 가 파라미터인 액터, α 는 크리틱의 불확실성을 반영하는 정도를 표현하는 초매개변수, σ 는 크리틱의 불확실성을 뜻한다. σ 는 dropout layer 가 포함된 크리틱의 신경망에서 10 번 출력한 Q function 값의 표준편차로 구한다. Q function 값의 표준편차가 클수록 크리틱의 불확실성이 크다는 뜻이다. 기존의 DDPG 알고리즘에서 $-\alpha * \sigma$ 부분만 더해주는 방식을 택했기 때문에 DDPG 가 아닌 다른 액터-크리틱 방식의 강화학습 알고리즘에서도 적용가능한 장점이 있다.

실험은 기존의 DDPG 알고리즘과 크리틱의 불확실성을 적용한 본논문의 알고리즘의 학습 정도를 OpenAI gym Mujoco 에서 직접 비교하였다. DDPG 와 본논문의 알고리즘의 초매개변수는 모두 동일하게 진행하였다.

Mujoco 환경	기존 DDPG	본논문 알고리즘
Walker2d-v2	2116	2171
Swimmer-v2	98	135
Ant-v2	1414	2000
Hopper-v2	2614	2837
HalfCheetah-v2	7541	8015

실험결과는 위의 표와 같이 나왔다. OpenAI gym Mujoco 의 5 가지 환경에 대해서 각각 5 번씩 독립적으로 실험한 후 테스트했을 때 나온 Return 값의 평균값을 적어놓았다. 5 가지 환경에 대해서 모두 기존 DDPG 알고리즘에 비해 성능이 향상되는 것을 확인할 수 있었다. 초매개변수 α 값은 학습이 진행되는 동안 고정하였다. 표에서 실행한 각 환경의 α 값은 1.0, 1.0, 0.1, 0.6, 0.06 으로 설정하였다.

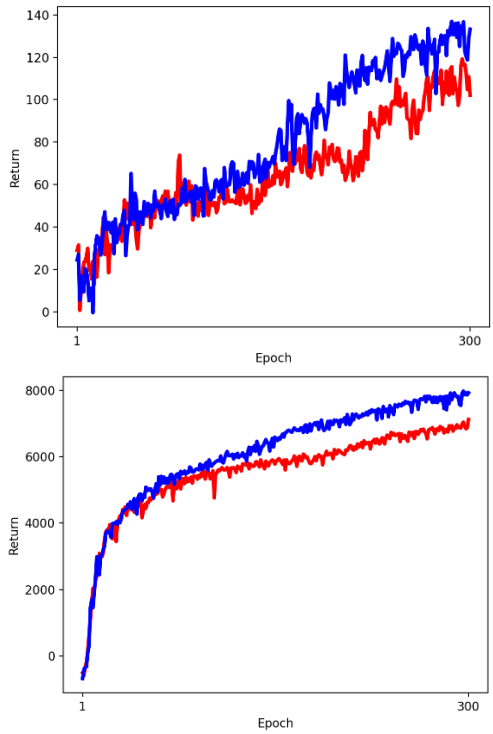

각 그래프는 Swimmer-v2 와 HalfCheetah-v2 환경에서 학습되는 정도를 Test Return 으로 표현한 것이다. 빨간 그래프가 기존 DDPG 이고 파란 그래프가 본논문의 알고리즘을 적용한 그래프이다. 이 그래프도 우연히 더 좋은 성능을 보인 것이 아니라는 것을 보여주기 위해서 5 번의 독립된 실험 결과를 평균을 냈다.

Ⅲ. 결론

본논문에서는 크리틱의 불확실성을 줄이는 것이 액터-크리틱류의 강화학습 알고리즘의 성능을 향상시킬 수 있다는 것을 보이기위해 기존 DDPG 에 적용하여 OpenAI gym Mujoco 의 5 가지 환경에서 실험을 통해 보여주었다. 각 환경에 대해서 5 번의 독립된 실험을 평균낸 결과값을 통해 본논문의 알고리즘의 효과가 있는 것을 보여주었다. DDPG 가 아닌 액터-크리틱류의 강화학습 알고리즘에 모두 적용할 수 있을 것으로 보이므로 활용도가 높을 것으로 예상된다.

ACKNOWLEDGMENT

This work is in part supported by Bio-Mimetic Robot Research Center Funded by Defense Acquisition Program Administration, and by Agency for Defense Development (UD190018ID), MSIT-IITP grant (No.2019-0-01367, BabyMind), Grant(UD190031RD) from Defense Acquisition Program Administration(DAPA) and Agency for Defense Development(ADD), INMAC, and BK21-plus.

참 고 문 헌

[1] V. R. Konda, *Actor-Critic Algorithms*. PhD thesis, Department of Electrical Engineering and Computer Science, Massachusetts Institute of Technology, 2002.

[2] Lillicrap, Timothy P, Hunt, Jonathan J, Pritzel, Alexander, Heess, Nicolas, Erez, Tom, Tassa, Yuval, Silver, David, and Wierstra, Daan. Continuous control with deep reinforcement learning. arXiv preprint arXiv:1509.02971, 2015.