

Artificial Intelligence: Assignment 3

Seung-Hoon Na


November 30, 2017

1 Sarsa와 Q-learning

1.1 Windy Gridworld

Windy gridworld는 (Sutton 교재 연습문제 6.5) 다음 그림과 같이 8×7 Grid world로, Agent는 **up**, **down**, **right**, **left**의 4가지 action을 수행하면서 시작 상태 S 에서 목표 상태 G 로 도달하는 것이 목적이다. 추가로, 중앙의 columns들에 바람(wind)이 있어서 이 영역에서는 Agent가 **up**방향으로 해당 바람의 세기(strength)만큼 이동하게 된다. 예를 들어, Agent가 G 의 바로 왼쪽에서 **right**를 수행하면 G 보다 2칸 더 위에 위치하게 된다. Agent가 G 의 바로 오른쪽에서 **left**를 수행하면 G 보다 1칸 더 위에 위치하게 된다. (즉, Agent가 이동을 시작할 때 위치의 column 상 strength만큼 위로 이동한후 해당 action을 수행하는 것과 같다).

Windy gridworld는 Undiscounted episodic task로 goal에 도달할때마다 reward가 -1 씩 주어진다.



1.2 Sarsa와 Q-learning구현

위의 Windy gridworld에 대해서 *epsilon*-greedy action를 이용한 경우 Sarsa와 Q-learning을 구현하시오 (python code). 이때, $\epsilon = 0.1$, $\alpha = 0.5$ 로 한다.

참고로, Sarsa와 Q-learning의 기본 알고리즘은 다음과 같다.

Sarsa (on-policy TD control) for estimating $Q \approx q_*$

```
Initialize  $Q(s, a)$ , for all  $s \in \mathcal{S}, a \in \mathcal{A}(s)$ , arbitrarily, and  $Q(\text{terminal-state}, \cdot) = 0$ 
Repeat (for each episode):
  Initialize  $S$ 
  Choose  $A$  from  $S$  using policy derived from  $Q$  (e.g.,  $\epsilon$ -greedy)
  Repeat (for each step of episode):
    Take action  $A$ , observe  $R, S'$ 
    Choose  $A'$  from  $S'$  using policy derived from  $Q$  (e.g.,  $\epsilon$ -greedy)
     $Q(S, A) \leftarrow Q(S, A) + \alpha [R + \gamma Q(S', A') - Q(S, A)]$ 
     $S \leftarrow S'; A \leftarrow A'$ 
  until  $S$  is terminal
```

Q-learning (off-policy TD control) for estimating $\pi \approx \pi_*$

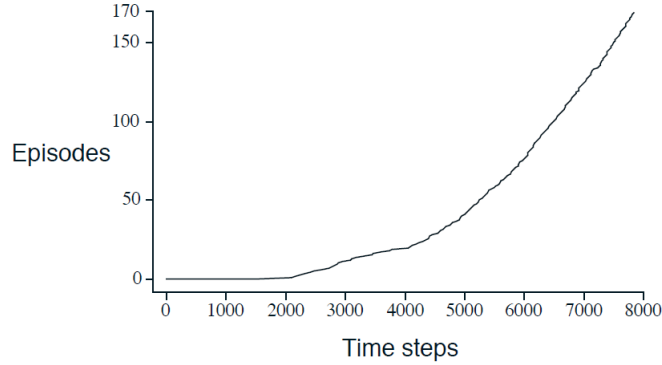
```
Initialize  $Q(s, a)$ , for all  $s \in \mathcal{S}, a \in \mathcal{A}(s)$ , arbitrarily, and  $Q(\text{terminal-state}, \cdot) = 0$ 
Repeat (for each episode):
  Initialize  $S$ 
  Repeat (for each step of episode):
    Choose  $A$  from  $S$  using policy derived from  $Q$  (e.g.,  $\epsilon$ -greedy)
    Take action  $A$ , observe  $R, S'$ 
     $Q(S, A) \leftarrow Q(S, A) + \alpha [R + \gamma \max_a Q(S', a) - Q(S, A)]$ 
     $S \leftarrow S'$ 
  until  $S$  is terminal
```

1.3 Sarsa와 Q-learning 학습 결과 확인

Sarsa와 Q-learning 각각에 대해서 학습한 결과의 Q values와 optimal policy는 별도의 파일로 저장하고 이를 출력하는 python code를 작성하시오.
출력결과도 report하라.

1.4 Sarsa와 Q-learning 시뮬레이션

Sarsa와 Q-learning을 시뮬레이션하여 다음과 같이 time steps별로 수행된 episodes수에 대한 curves를 비교하시오. (하나의 그래프에서 Sarsa와 Q-learning 곡선이 비교되도록 하면 된다.)



2 Policy Gradient Theorem

Episodic 경우에 대해 다음 policy gradient theorem 을 증명하시오 (Sutton 교재 13.2절 참조).

Theorem 1 (Policy gradient theorem)

$$\nabla J(\theta) = \mathbb{E}_{\pi} \left[\sum_a q_{\pi}(S_t, a) \nabla_{\theta} \log \pi(a|S_t, \theta) \right]$$

위의 증명을 위해 다음의 단계를 거치시오 (Sutton 교재 9.2절 및 13.2절 참조).

1. 모든 episode는 공통 START 상태인 s_0 에서 시작한다고 가정하여, 목적함수 (policy objective function) $J(\theta)$ 는 시작 상태에서 현재 policy π_{θ} 를 따랐을 때의 value로 다음과 같이 정의한다.

$$J(\theta) = v_{\pi_{\theta}}(s_0)$$

2. $\nabla J(\theta) = \nabla v_{\pi_{\theta}}(s_0)$ 를 전개하기 위해, state-value function의 정의에 따라, $v_{\pi_{\theta}}(s)$ 를 다시 다음과 같이 기술한다.

$$\nabla v_{\pi}(s) = \nabla \left[\sum_a \pi(a|s) q_{\pi}(s, a) \right]$$

3. $\nabla v_{\pi}(s)$ 를 정의에 따라 unfolding하여 다음을 유도한다 (이 과정을 상세히 정리할 것).

$$\nabla v_{\pi}(s_0) = \sum_s \eta(s) \sum_a \nabla \pi(a|s) q_{\pi}(s, a)$$

이때 $\eta(s)$ 는 한 episode내에서 상태 s 에 평균적으로 머무르는 time steps의 수로 다음과 같이 정의된다 (Sutton 교재 9.2절 참조).

$$\eta(s) = h(s) + \sum_{s'} \eta(s') \sum_a \pi(a|s') p(s|s', a)$$

4. stationary 분포 $d^{\pi}(s) = \frac{\eta(s)}{\sum_{s'} \eta(s')}$ 의 형태로, 위의 식을 다시 기술한다.

$$\nabla J(\theta) = \nabla v_{\pi}(s_0) \propto \sum_s d^{\pi}(s) \sum_a \nabla \pi(a|s) q_{\pi}(s, a)$$

5. Expectation의 정의에 따라 Policy gradient theorem을 최종 유도한다 (이 과정을 구체적으로 정리할 것).

3 Tensorflow 사용

Tensorflow를 설치 (<https://www.tensorflow.org/>) 하여 다음의 과정을 수행해보고 Convolutional network의 기본 구조 및 학습 및 구현 방법을 이해하시오. (이 문제에 대한 보고서는 1페이지 이내로 간략히 정리할 것)

3.1 MNIST dataset에서 실행

다음 MNIST을 위한 분류기 Tutorial을 참조하여 해당 code `mnist_softmax.py`를 이해하고 실행한 결과를 보이라.

https://www.tensorflow.org/get_started/mnist/beginners

Tensorflow구동방식과 `mnist_softmax.py`의 핵심 함수에 대해 요약적으로 설명하라. 또한, 다음에 대해서 간략히 설명하라.

1. loss function - squared error
2. loss function - negative cross entropy
3. model parameter
4. stochastic gradient decent
5. minibatch training
6. regularization
7. computational graph
8. `tf.Variable`
9. `tf.placeholder`

3.2 CIFAR dataset에서 실행

다음은 각각 참조하여 CIFAR dataset에서 학습을 수행하고, 실행한 결과를 보이라.

https://www.tensorflow.org/tutorials/deep_cnn

<https://github.com/tensorflow/models/tree/master/tutorials/image/cifar10/>


4 Deep reinforcement learning

본 문제에서는 Tetris게임의 action을 학습하기 위해 Convolutional network을 이용한 deep reinforcement learning을 구현한다.

다음은 이를 위해 확장해야 하는 pygame 코드이다.

<https://github.com/SmartViking/MaTris>

참고로 위의 코드를 설치하여 실행한 게임 화면은 아래와 같다.



4.1 DQN (Deep Q-network) 구현

DQN은 Experience replay로 (s, a, r, s') 로 구성된 replay memory \mathcal{D} 를 만들고, 이로부터 random mini-batch \mathcal{D}_i 를 샘플링하여 \mathcal{D}_i 에 대한 다음 loss function (squared error)를 줄이도록 network의 parameter를 학습하는 것이다.

$$L_i = \mathbb{E}_{s,a,r,s' \sim \mathcal{D}_i} [r + \gamma \max_{a'} Q(s', a'; \mathbf{w}_{old}) - Q(s, a, \mathbf{w})]$$

다음은 DeepMind의 DQN 논문에서 기술된 학습 algorithm이다.
(<https://www.cs.toronto.edu/~vmnih/docs/dqn.pdf>)

Algorithm 1 Deep Q-learning with Experience Replay

```

Initialize replay memory  $\mathcal{D}$  to capacity  $N$ 
Initialize action-value function  $Q$  with random weights
for episode = 1,  $M$  do
  Initialise sequence  $s_1 = \{x_1\}$  and preprocessed sequenced  $\phi_1 = \phi(s_1)$ 
  for  $t = 1, T$  do
    With probability  $\epsilon$  select a random action  $a_t$ 
    otherwise select  $a_t = \max_a Q^*(\phi(s_t), a; \theta)$ 
    Execute action  $a_t$  in emulator and observe reward  $r_t$  and image  $x_{t+1}$ 
    Set  $s_{t+1} = s_t, a_t, x_{t+1}$  and preprocess  $\phi_{t+1} = \phi(s_{t+1})$ 
    Store transition  $(\phi_t, a_t, r_t, \phi_{t+1})$  in  $\mathcal{D}$ 
    Sample random minibatch of transitions  $(\phi_j, a_j, r_j, \phi_{j+1})$  from  $\mathcal{D}$ 
    Set  $y_j = \begin{cases} r_j & \text{for terminal } \phi_{j+1} \\ r_j + \gamma \max_{a'} Q(\phi_{j+1}, a'; \theta) & \text{for non-terminal } \phi_{j+1} \end{cases}$ 
    Perform a gradient descent step on  $(y_j - Q(\phi_j, a_j; \theta))^2$  according to equation 3
  end for
end for

```

$Q(s, a, \mathbf{w})$ 을 위해 convolutional networks으로 구성하여 \mathbf{w} 학습을 위한 일반적인 DQN 알고리즘을 구현하고 이를 MaTris 학습에 적용하시오.

단, DQN은 어느 게임에도 적용될 수 있도록 modularity를 유지하도록 하고, MaTris code는 state image 및 reward를 추출하기 위해 적절히 수정 및 확장하시오.


다음은 추가 comments이다.

1. tensorflow 1.0버전이상 호환되도록 작성하라 (linux ubuntu 플랫폼)
2. convolutional networks의 딥 모델 구조는 3-4개 층 정도로 적절히 구성하면 된다.
3. Discount factor는 γ 는 [0.7, 0.95]사이의 값으로 적절히 설정하라.
4. code실행을 위한 간단한 README

4.2 DQN (Deep Q-network) 적용

DQN을 적용하면서 Training epochs이 진행됨에 따라 Average reward curves를 그리시오.

다음은 DeepMind 논문의 해당 curves의 예이다.



4.3 DQN (Deep Q-network) 적용: Tetris 시뮬레이션

DQN을 통해 학습된 결과를 저장한 후, 이를 로딩하여 학습된 Agent가 수행한 action에 따라 MaTris가 play되도록 시뮬레이션 code를 작성하시오. (실행하면 Agent의 action에 따라 MaTris가 자동으로 play되어야 함)

4.4 Actor-Critic model 구현

Actor-critic model은 value network $v(S, \mathbf{w})$ 와 policy network $\pi(S, \theta)$ 두고 value network의 parameter를 갱신할 때는 TD-learning을, policy network의 parameter를 갱신할 때는 policy gradient의 q 함수대신 advantage function $A^{\pi_\theta}(s, a)$ 를 사용한 다음의 policy gradient를 사용한다.

$$\nabla J(\theta) = \mathbb{E}_{\pi_\theta} [\nabla \log \pi(a|S_t, \theta) A^{\pi_\theta}(S, a)]$$

Actor-critic model의 학습 algorithm은 다음과 같다 (Sutton 교재 13.5절 참조)

One-step Actor-Critic (episodic)

Input: a differentiable policy parameterization $\pi(a|s, \theta)$

Input: a differentiable state-value parameterization $\hat{v}(s, \mathbf{w})$

Parameters: step sizes $\alpha^\theta > 0, \alpha^\mathbf{w} > 0$

Initialize policy parameter $\theta \in \mathbb{R}^{d'}$ and state-value weights $\mathbf{w} \in \mathbb{R}^d$

Repeat forever:

 Initialize S (first state of episode)

$I \leftarrow 1$

 While S is not terminal:

$A \sim \pi(\cdot|S, \theta)$

 Take action A , observe S', R

$\delta \leftarrow R + \gamma \hat{v}(S', \mathbf{w}) - \hat{v}(S, \mathbf{w})$ (if S' is terminal, then $\hat{v}(S', \mathbf{w}) \doteq 0$)

$\mathbf{w} \leftarrow \mathbf{w} + \alpha^\mathbf{w} I \delta \nabla_{\mathbf{w}} \hat{v}(S, \mathbf{w})$

$\theta \leftarrow \theta + \alpha^\theta I \delta \nabla_{\theta} \ln \pi(A|S, \theta)$

$I \leftarrow \gamma I$

$S \leftarrow S'$

$v(S, \mathbf{w})$ 및 $Q(s, a, \theta)$ 을 위해 convolutional networks으로 구성하여 \mathbf{w}, θ 파라미터를 위한 일반적인 Actor-Critic 알고리즘을 구현하고 이를 MaTris 학습에 적용하시오.

단, 마찬가지로 Actor-critic model은 어느 게임에도 적용될 수 있도록 modularity를 유지하도록 하고, MaTris code는 state image 및 reward를 추출하기 위해 적절히 수정 및 확장하시오.

다른 조건은 DQN과 유사하게 설정할 것.

4.5 Actor-Critic model 적용 및 시뮬레이션

마찬가지로, Actor-Critic model을 적용하면서 Training epochs이 진행됨에 따라 Average reward curvs를 그리고, 이를 DQN과 비교하시오.

또한, Actor-Critic model을 통해 학습된 결과를 저장한 후, 이를 로딩하여 학습된 Agent가 수행한 action에 따라 MaTris가 play되도록 시뮬레이션 code를 작성하시오. (실행하면 Agent의 action에 따라 MaTris가 자동으로 play되어야 함)

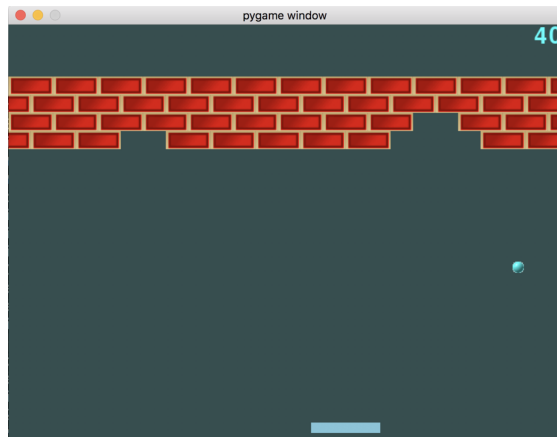
5 Deep reinforcement learning: Breakout

추가로 앞에서 구현된 DQN, Actor-critic model을 확장하여 Breakout 게임에 적용하라.


다음은 이를 위해 확장해야 하는 pygame 코드이다.

<https://github.com/johncheetham/breakout>

참고로 위의 코드를 설치하여 실행한 게임 화면은 아래와 같다.



또는, 다음의 atari breakout 코드를 확장해도 된다.
<https://github.com/aknuck/Atari-Breakout>
위의 Atari breakout 게임 화면은 다음과 같다.



제출해야 하는 코드는 다음과 같다.

1. DQN을 이용한 Breakout 학습기 (학습 결과 저장)
2. DQN을 이용한 Breakout 테스트: performance curve 도출
3. DQN을 이용한 Breakout 테스트: simulation (자동 실행)
4. Actor-critic model을 이용한 Breakout 학습기 (학습 결과 저장)
5. Actor-critic model을 이용한 Breakout 테스트: performance curve 도출
6. Actor-critic model을 이용한 Breakout 테스트: simulation (자동 실행)