



Q-러닝

Off-policy TD Control



Q-러닝(Q-Learning)

- Q-러닝 (Q-learning) 개요

- 가치 반복(value iteration)을 기반으로 한 방법
- SARSA와 달리 매번 다음 상태에서 행동은 행동가치함수를 극 대화하는 행동을 선택

$$Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha \left(r_t + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t, a_t) \right)$$

* SARSA: $Q(s_t, a_t) \leftarrow Q(s_t, a_t) + \alpha(r_t + \gamma Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t))$

Q-러닝(Q-Learning)

- Q-함수
 - 벨만 최적 방정식

$$v^*(s) = \max_a \left\{ r(s, a) + \gamma \sum_{s'} P(s'|s, a) v^*(s') \right\} = \max_a Q^*(s, a)$$


$$Q^*(s, a) = r(s, a) + \gamma \sum_{s'} P(s'|s, a) v^*(s')$$

$$Q^*(s, a) = r(s, a) + \gamma \sum_{s'} P(s'|s, a) \max_{a'} Q^*(s', a')$$
$$\delta^*(s) = \operatorname{argmax}_a Q^*(s, a)$$


Q-러닝(Q-Learning)

$$Q^*(s, a) = r(s, a) + \gamma \sum_{s'} P(s'|s, a) \max_{a'} Q^*(s', a')$$

- r 과 P 에 대한 정보는 미지

- **Q-러닝**

- 모든 s 와 a 에 대해 Q -함수 초기화
- 초기상태 s_0 및 $t \leftarrow 0$ 설정
- 각 단계 t 별,
 - (s_t, a_t, r_t, s_{t+1}) 를 관찰
 - 다음의 식에 따라 Q -값 업데이트



$$Q(s_t, a_t) \leftarrow (1 - \alpha) Q(s_t, a_t) + \alpha \left[r_t + \gamma \max_{a'} Q(s_{t+1}, a') \right]$$

|| *Old value* *Learned value*
Learning rate *Estimate of optimal future value*

$Q(s, a) + \alpha \left[\left(r + \gamma \max_{a'} Q(s', a') \right) - Q(s, a) \right]$

- $t \leftarrow t + 1$