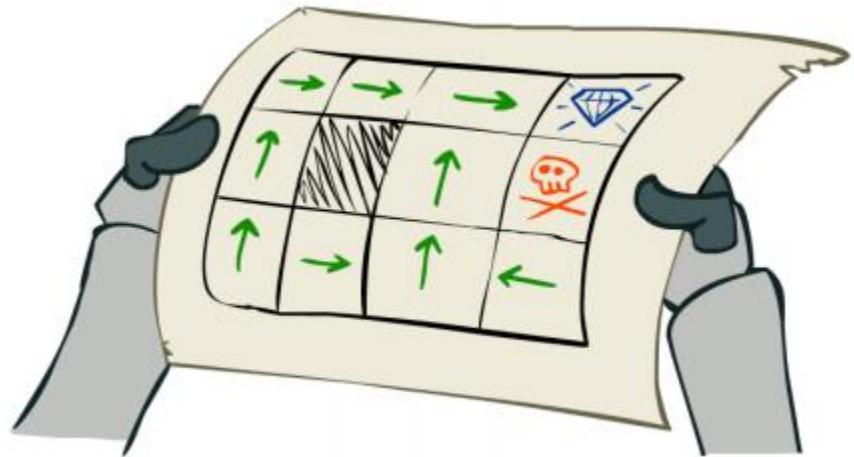
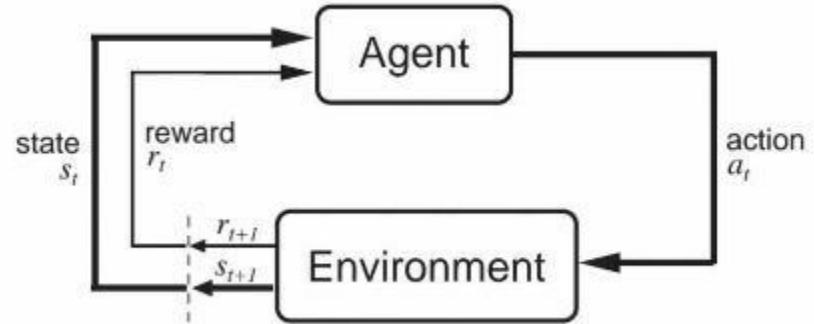
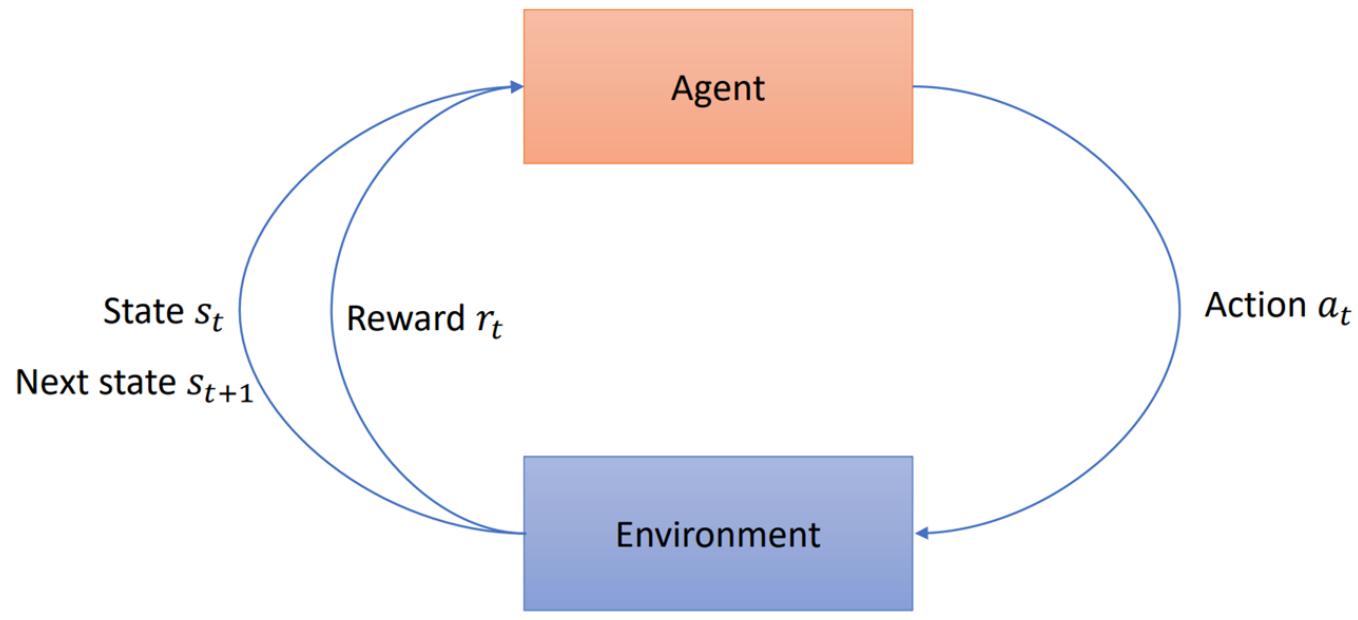


강화학습 Model-free Reinforcement Learning



강화학습



$s_0, a_0, r_0, s_1, a_1, r_1, \dots$

(Infinite-horizon) MDP

$$\{S, A_s, p(\cdot | s, a), r(s, a), \gamma: s \in S, a \in A_s\}$$

- S : 상태공간 (state space)
- A_s : 행동공간 (action space)
- $p(s'|s, a)$: 상태전이확률 (state transition probabilities)
- $r(s, a)$: 보상 (rewards)
- γ : 감가율 (discount factor)

(Infinite-horizon) MDP

- 정책 (Policy) π

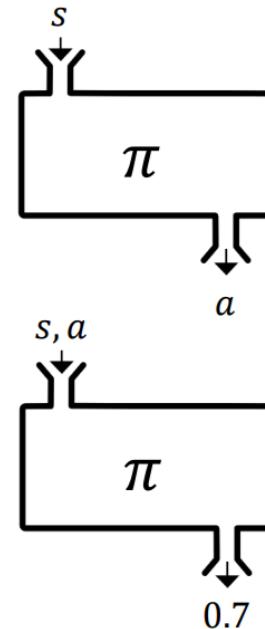
- 상태(state)를 행동(action)에 맵핑 (mapping)

- 확정적 정책 (Deterministic policy)

- $\bullet \pi(s) \rightarrow a$

- 확률적 정책 (Stochastic policy)

- $\bullet \pi(a|s) = P(A_t = a|S_t = s)$



(Infinite-horizon) MDP

- 최적 정책 (optimal policy) π^* 란?
 - 현 보상 최대화?
 - 모든 미래 보상들의 합 최대화?
 - 감가율이 반영된 모든 미래 보상합의 최대화!

$$s_0, a_0, r_0, s_1, a_1, r_1, \dots \xrightarrow{a_t \sim \pi(a|s_t)} \pi^* = \arg \max_{\pi} E \left[\sum_{t \geq 0} \gamma^t r_t | \pi \right]$$
$$s_{t+1} \sim p(\cdot | s_t, a_t)$$

(Infinite-horizon) MDP

- 정책 평가 (Policy evaluation)

- 정책 π 가 주어졌을 때 상태 s 의 가치함수 $v^\pi(s)$
- 벨만 기대 방정식

$$v^\pi(s) = E \left[\sum_{t \geq 0} \gamma^t r_t | s_0 = s, \pi \right]$$

- (확정적 정책) $v^\pi(s) = r(s, \pi(s)) + \gamma \sum_{s'} P(s' | s, \pi(s)) v^\pi(s')$

- (확률적 정책) $v^\pi(s) = \sum_{a \in A} \pi(a | s) [r(s, a) + \gamma \sum_{s'} P(s' | s, a) v^\pi(s')]$

- 벨만 최적 방정식

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

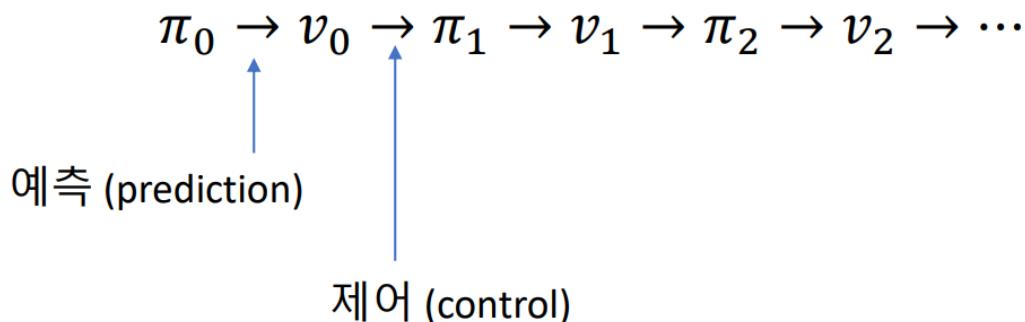
(Infinite-horizon) MDP

- 최적 가치함수와 최적 정책
 - 가치 반복 (value iteration)

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

$$v_0 \equiv 0 \rightarrow v_1 \rightarrow v_2 \rightarrow \dots$$

- 정책 반복 (policy iteration)



강화학습

- 모델(환경에 대한 가정)을 모를 때 학습하는 방법

$$\{S, A_s, p(\cdot | s, a), r(s, a), \gamma: s \in S, a \in A_s\}$$

- 즉, $p(\cdot | s, a)$ 와 $r(s, a)$ 를 모를 경우, 경험을 통한 학습
- 매우 단순한 모델기반 강화학습
 - 이러한 모델을 추정할 수 있게 되면 이전에 살펴보았던 MDP 모델을 해결함으로써 가치함수를 추정할 수 있으며 정책을 도출할 수 있게 됨

강화학습 방법론 분류

