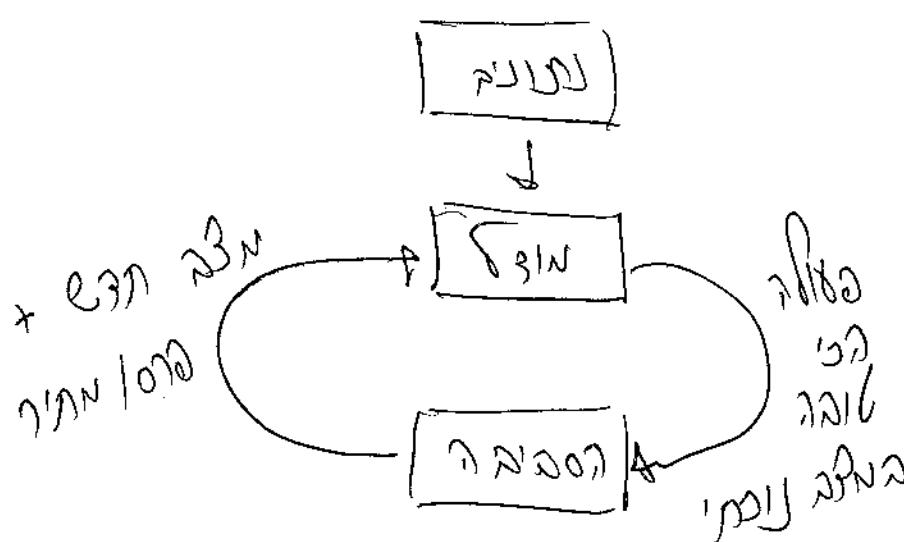


①

Reinforcement Learning



לעתות קיימות:



תפקידו של ה-

? מילוי מהו סעיפים שנקראים כרך ומי יממן?

Markov Decision Process

t מעתה נסמן S_t - סט א'זן פוק -

t מעתה נסמן A_t - פעולה פוק -

מיטריאלי נסמן $p(s'|s, a)$ -

מיטריאלי נסמן R_t - ערך מילוי פוק -

נסמן $R(s, a)$

פונקציית $P(R, B | s, a)$

②

מיצג נייח

('לוסטו פון') $\pi(s) \rightarrow A$ (policy) תפקיד נציג
כל פעולה כפולה $R_t + R_{t+1} + R_{t+2} + \dots$

האם מטרת החקלאות היא?
האם מטרת החקלאות היא

$$\pi^* = \arg \max_{\pi} E \left[\sum R_t \gamma^t \right]$$

$\pi_\theta(a|s) = f(a, s; \theta)$ י'ע : Policy Gradient

$$L(\theta) = E \left[\sum_{t=0}^T \gamma^t R(s_t, a_t) \right]$$

המטרה היא

המטרה היא $f(a, s; \theta)$ היא מטרה
המטרה היא, ו המטרה היא.
המטרה היא $\pi(a|s)$, $\pi(a|s)$ המטרה היא

$$V_\pi(s) = E_\pi \left[\sum_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = s \right]$$

$$Q_\pi(s, a) = E_\pi \left[\sum_{k=0}^{\infty} \gamma^k R_{t+k+1} | S_t = s, A_t = a \right]$$

③

$$V^\pi(s) = r(s, \pi(s)) + \gamma \sum_{s'} p(s'|s, \pi(s)) V^\pi(s') \quad : \text{defn}$$

$$V^\pi(s) = E \left[\sum_t \gamma^t R_t | S_0 = s \right] \quad : \text{defn}$$

$$= E[R_0 | S_0 = s] + E \left[\sum_{t=1} \gamma^t R_t | S_0 = s \right]$$

$$= r(s, \pi(s)) + E \left[\sum_{t=1} \gamma^t R_t | S_0 = s \right]$$

$$= r(s, \pi(s)) + E \left[E \left[\sum_{t=1} \gamma^t R_t | S_0 = s, S_1 \right] \right]$$

$$= r(s, \pi(s)) + \sum_{s'} p(s'_1 | s, \pi(s)) E \left[\sum_{t=1} \gamma^t R_t | S_0 = s, S_1 = s'_1 \right]$$

$$= r(s, \pi(s)) + \sum_{s'} p(s'_1 | s, \pi(s)) E \left[\sum_{t=1} \gamma^t R_t | S_1 = s'_1 \right]$$

? (b) $\frac{\text{defn}}{\text{defn}}$

$$= r(s, \pi(s)) + \gamma \sum_{s'} p(s' | s, \pi(s)) V^\pi(s')$$

Q^* & V depend on each other $\Rightarrow Q \leftarrow \text{defn}$ iteratively

: (Policy Evaluation) π fixes Q^* - V^* iteratively : 1. V^*

$$V_{t+1}(s) = r(s, \pi(s)) + \gamma \sum_{s'} p(s' | s, \pi(s)) V_t(s') \quad \text{Hs}$$

$$V^*(s) - \text{optimal value} \quad : \text{defn}$$

④ $V_{t+1} = T(V_t)$ \rightarrow contracting \rightarrow T
 $0 \leq c \leq 1$ $\delta(T(x), T(x')) \leq c \cdot \delta(x, x')$

we get δ of x_{t+1} since T is δ -Lip. \Rightarrow Banach
 $\delta(x_{t+1}, x^*) \leq c \cdot \delta(x_t, x^*)$
 \downarrow
 $\delta(x_{t+1}, x^*) = \gamma^t \delta(x_0, x^*)$
 \Downarrow
 $t = \log \frac{\epsilon}{\delta(x_0, x^*)}$

$$\begin{aligned}
 \delta(T[V], T[\tilde{V}]) &= \|T(V) - T(\tilde{V})\|_\infty \\
 &= \max_s \left| p(s, \pi(s)) + \gamma \sum_{s'} p(s'|s, \pi(s)) V(s') - \sum_{s'} p(s'|s, \pi(s)) \tilde{V}(s') \right| \\
 &\leq \gamma \max_s \left| \sum_{s'} p(s'|s, \pi(s)) [V(s') - \tilde{V}(s')] \right| \\
 &\leq \gamma \max_s \sum_{s'} p(s'|s, \pi(s)) |V(s') - \tilde{V}(s')| \\
 &\leq \gamma \max_s \max_{s'} |V(s') - \tilde{V}(s')| = \gamma \|V - \tilde{V}\|_\infty
 \end{aligned}$$

$Q^\pi(s, a)$ \rightarrow and next step \rightarrow π^\star

$\pi^\star(s, a) = \arg \max_a Q^\pi(s, a)$

5

Optimal Policy

π گویا $V_{\pi}(s) \geq V_{\pi'}(s)$ نیز میتوان π را کارآمد نامند
 اما اگر π' نویز π را کارآمد نماید سپهان

$$Q^*(s, a) = \max_{\pi} Q_{\pi}(s, a)$$

$$V^*(s) = \max_{\pi} \pi(s)$$

که s -را بهترین آنلاین π^* را میخواهد
 $\pi^* \rightarrow \max_{\pi} \pi(s)$

$$V^*(s) = \max_a Q^*(s, a)$$

بنابراین π را کارآمد بگویی $Q^*(s, a)$ بزرگ باشد

(A) $\boxed{\pi^*(s) = \arg \max_a Q^*(s, a)}$

$$Q^*(s, a) = \max_{\pi} E \left[\sum_{t=0}^{\infty} \gamma^t R_t | S_0 = s, A_0 = a \right] \quad : \text{پسوندینگ}$$

$$= \max_{\pi} r(s, a) + \sum_{s'} p(s' | s, a) E \left[\sum_{t=1}^{\infty} \gamma^t R_t | S_t = s' \right]$$

$$= r(s, a) + \gamma \max \underbrace{\sum_{s'} p(s' | s, a) E \left[\sum_{t=1}^{\infty} \gamma^{t-1} R_t | S_t = s' \right]}_{V^*(s')} \quad : \text{آنچه سیگنال است}$$

$$= r(s, a) + \gamma \sum_{s'} p(s' | s, a) V^*(s')$$

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

(B) $\boxed{V^*(s) = \max_a r(s, a) + \gamma \sum_{s'} p(s' | s, a) V^*(s')} \quad : \text{آنچه میخواهیم}$

$$V^*(s) = \max_a Q^*(s, a)$$

6

Value Iteration

$$V_{t+1}(s) = \max_a r(s, a) + \gamma \sum_{s'} p(s'|s, a) V_t(s')$$

היפך נון זה השגיה גורם VI: ללא
policy הו איך הו השגיה הו
השגיה הו השגיה הו

policy evaluation -> השגיה השגיה

Policy Iteration

: policy improvement השגיה השגיה ②

$$\pi_{t+1} = \arg \max_a Q^{\pi_t}(s, a)$$

$s \in S$ $V_{(s)}^{\pi_{t+1}} > V^{\pi_t}$ השגיה השגיה

$Q^{\pi_{t+1}}, V^{\pi_{t+1}}$: π_{t+1} השגיה השגיה ③

π^* השגיה השגיה השגיה השגיה השגיה השגיה

? השגיה השגיה השגיה ?
השגיה ? השגיה ? השגיה ?