

Temporal-difference metódy

(Strojové učenie II)

M. Mach

Katedra kybernetiky a umelej inteligencie, FEI, TUKE

február 2021 - marec 2025




Temporal-difference učenie posilňovaním

- Cieľom je odhad hodnotových funkcií
- Kombinácia dvoch princípov
 - bootstrapping - odhad na základe iného odhadu
(DP: $v_\pi(s) = E[R_{t+1} + \gamma v_\pi(S_{t+1}) | S_t = s]$)
 - model-free - stačí skúsenosť s prostredím (MC: netreba úplnú znalosť prostredia v zmysle modelu)
(MC: $v_\pi(s) = E[R_{t+1} + \gamma R_{t+2} + \gamma^2 R_{t+3} + \dots | S_t = s]$)
- Interakcia s prostredím
 - skutočná
 - simulovaná
- Schopný pracovať s
 - neúplnými epizódami
 - kontinuálnymi úlohami
- Inkrementálny v zmysle krok po kroku - online

Dávkový vs. iteratívny update

$$\bar{x} \leftarrow \frac{1}{N} \sum_{i=1}^N x_i \quad \bar{x} \leftarrow \bar{x} + \alpha [x_i - \bar{x}] \quad i = 1, \dots, N$$



$$\begin{aligned}\bar{x}_{1..5} &= \frac{x_1 + x_2 + x_3 + x_4 + x_5}{5} \\&= \frac{\frac{x_1+x_2+x_3+x_4}{4}4 + x_5}{5} \\&= \frac{\bar{x}_{1..4}4 + \bar{x}_{1..4} - \bar{x}_{1..4} + x_5}{5} \\&= \frac{\bar{x}_{1..4}5 + x_5 - \bar{x}_{1..4}}{5} \\&= \bar{x}_{1..4} + \frac{1}{5}(x_5 - \bar{x}_{1..4})\end{aligned}$$

Rozdiel v princípoch odhadu

$$\begin{aligned}v_{\pi}(s) &= E_{\pi}[G_t | S_t = s] \\&= E_{\pi}[R_{t+1} + \gamma G_{t+1} | S_t = s] \\&= E_{\pi}[R_{t+1} + \gamma v_{\pi}(S_{t+1}) | S_t = s]\end{aligned}$$

- MC

- cieľ na skutočnú kumulatívnu odmenu
- $V(S_t) \leftarrow V(S_t) + \alpha[G_t - V(S_t)]$
 $\alpha = 1/N$ (MC), $\alpha = \text{const}$ (constant- α MC)
- odhad iba na základe skúsenosti
- čaká na znalosť G_t (epizóda musí dobehnúť')

- TD

- cieľ na odhad kumulatívnej odmeny
- $V(S_t) \leftarrow V(S_t) + \alpha[R_{t+1} + \gamma V(S_{t+1}) - V(S_t)]$
- odhad na základe skúsenosti a iného odhadu (G_{t+1})
- čaká iba jeden krok

TD chyba

- Člen v zátvorke: $\delta_t = R_{t+1} + \gamma V(S_{t+1}) - V(S_t)$
 - chyba - rozdiel medzi aktuálnym odhadom hodnoty pre stav S_t ($V(S_t)$) a lepším odhadom pomocou okamžitej skúsenosti (R_{t+1}) a odhadu pre nasledujúci stav ($V(S_{t+1})$)
- Ak by sa hodnoty odhadov V nemenili počas epizódy ale iba po nej

$$\begin{aligned} G_t - V(S_t) &= R_{t+1} + \gamma G_{t+1} - V(S_t) + \gamma V(S_{t+1}) - \gamma V(S_{t+1}) \\ &= \delta_t + \gamma(G_{t+1} - V(S_{t+1})) \\ &= \delta_t + \gamma(R_{t+2} + \gamma G_{t+2} - V(S_{t+1}) + \gamma V(S_{t+2}) - \gamma V(S_{t+2})) \\ &= \delta_t + \gamma\delta_{t+1} + \gamma^2(G_{t+2} - V(S_{t+2})) \\ &= \sum_{k=t}^{T-1} \gamma^{k-t} \delta_k \end{aligned}$$

- TD robí korekciu voči menšej chybe než MC

Algoritmus TD odhadu v_π

Tabular TD(0) for estimating v_π

Input: the policy π to be evaluated

Algorithm parameter: step size $\alpha \in (0, 1]$

Initialize $V(s)$, for all $s \in \mathcal{S}^+$, arbitrarily except that $V(\text{terminal}) = 0$

Loop for each episode:

 Initialize S

 Loop for each step of episode:

$A \leftarrow$ action given by π for S


 Take action A , observe R, S'

$V(S) \leftarrow V(S) + \alpha [R + \gamma V(S') - V(S)]$

$S \leftarrow S'$

 until S is terminal

Ilustračný príklad: cesta domov



©Sutton-Barto: Reinforcement Learning, 2nd ed., 2018

- Aktualizované hodnoty - odhad po prvom dni (pre $\alpha = 1$)
 - TD - bezprostredne môže updatovať ako reakciu na aktuálnu situáciu (zmeny obomi smermi)
 - MC - musí čakať až na príchod domov (zmeny na rovnakú hodnotu)

Konvergencia

$$V(S_t) \leftarrow V(S_t) + \alpha [Target - V(S_t)]$$

- Podmienky pre konvergenciu V k v_π
 - $\sum_{n=1}^{\infty} \alpha_n = \infty$
 - $\sum_{n=1}^{\infty} \alpha_n^2 < \infty$
- TD - konverguje iba približne (v priemere)
 - α je konštantné a "dostatočne" malé
(nesplnená druhá podmienka)
- MC - konverguje (s pravdepodobnosťou 1)
 - $\alpha = 1/N$ sa postupne zmenšuje
(splnené sú obe podmienky)
- Asymtotická konvergencia môže byť v praxi pomalá
 - čo konverguje rýchlejšie (lepšie využije dát)?
 - TD (offline - dávkový update) < constant- α MC
 - TD (online) ? MC




CIT

Centrum inteligentnej
techniky

Učenie politiky

$\dots, S_t, A_t, R_{t+1}, S_{t+1}, A_{t+1}, R_{t+2}, \dots$



- Založené na všeobecnej iterácii politiky
- Použitie $Q(s, a)$ ako odhadu $q_\pi(s, a)$
 - neznalosť modelu
 - nestáčí poznáť v_π
- Problém explorácie
 - pokrytie párov (s, a)
 - ϵ -mäkká politika
- On-policy ($\pi = b$) vs off-policy ($\pi \neq b$)

Aktualizácia odhadu Q

- Spôsoby odhadu G_{t+1} v

$$q_\pi(s, a) = E_\pi[R_{t+1} + \gamma G_{t+1} | S_t = s, A_t = a]$$

$$\begin{aligned} Q(S_t, A_t) &\leftarrow \\ Q(S_t, A_t) &+ \alpha [R_{t+1} + \gamma Q(S_{t+1}, A_{t+1}) - Q(S_t, A_t)] \end{aligned}$$

$$\begin{aligned} Q(S_t, A_t) &\leftarrow \\ Q(S_t, A_t) &+ \alpha [R_{t+1} + \gamma \max_a Q(S_{t+1}, a) - Q(S_t, A_t)] \end{aligned}$$

$$\begin{aligned} Q(S_t, A_t) &\leftarrow \\ Q(S_t, A_t) &+ \alpha [R_{t+1} + \gamma E[Q(S_{t+1}, A_{t+1}) | S_{t+1}] - Q(S_t, A_t)] = \\ Q(S_t, A_t) &+ \alpha [R_{t+1} + \gamma \sum_a \pi(a | S_{t+1}) Q(S_{t+1}, a) - Q(S_t, A_t)] \end{aligned}$$

Aktualizácia: $\dots + \gamma Q(S_{t+1}, A_{t+1}) - \dots$

$\dots, R_t, S_t, A_t, R_{t+1}, S_{t+1}, A_{t+1}, R_{t+2}, \dots$



- $Q(S_t, A_t)$ je
 - pre neterminálny stav aktualizované podľa **päťice** vybranej zo sekvencie
 - nulové pre terminálny stav
- On-policy odhad
- Konvergencia (ku q_* a π_*)
 - všetky páry (s, a) navštívené nekonečnekrát
 - politika konverguje ku **greedy** politike ($\epsilon = 1/t$)
- **Sarsa** algoritmus

Algoritmus Sarsa

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

Algorithm parameters: step size $\alpha \in (0, 1]$, small $\varepsilon > 0$

Initialize $Q(s, a)$, for all $s \in \mathcal{S}^+$, $a \in \mathcal{A}(s)$, arbitrarily except that $Q(\text{terminal}, \cdot) = 0$

Loop for each episode:

 Initialize S

 Choose A from S using policy derived from Q (e.g., ε -greedy)

 Loop for each step of episode:

 Take action A , observe R, S'

 Choose A' from S' using policy derived from Q (e.g., ε -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

Aktualizácia: $\dots + \gamma \max_a Q(S_{t+1}, A_{t+1}) - \dots$

$\dots, R_t, S_t, A_t, R_{t+1}, S_{t+1}, A_{t+1}, R_{t+2}, \dots$

- $Q(S_t, A_t)$ je
 - pre neterminálny stav aktualizované podľa **štvorice** vybranej zo sekvencie
 - nulové pre terminálny stav
- Off-policy odhad
- Konvergencia (ku q_* a π_*)
 - potrebné je zabezpečiť aktualizáciu všetkých párov (s, a)
- **Q-learning** algoritmus



Algorithmus Q-Learning

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

Algorithm parameters: step size $\alpha \in (0, 1]$, small $\varepsilon > 0$

Initialize $Q(s, a)$, for all $s \in \mathcal{S}^+$, $a \in \mathcal{A}(s)$, arbitrarily except that $Q(\text{terminal}, \cdot) = 0$

Loop for each episode:

 Initialize S

 Loop for each step of episode:

 Choose A from S using policy derived from Q (e.g., ε -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

©Sutton-Barto: Reinforcement Learning, 2nd ed., 2018



Aktualizácia: $\dots + \gamma E[Q(S_{t+1}, A_{t+1})|S_{t+1}] - \dots$

$\dots, R_t, S_t, A_t, R_{t+1}, S_{t+1}, A_{t+1}, R_{t+2}, \dots$




- $Q(S_t, A_t)$ je
 - pre neterminálny stav aktualizované podľa **štvorice** vybranej zo sekvencie
 - nulové pre terminálny stav
- Spriemerňovanie akcií v S_{t+1}
 $E[Q(S_{t+1}, A_{t+1})|S_{t+1}] = \sum_a \pi(a|S_{t+1})Q(S_{t+1}, a)$
- On-policy/Off-policy odhad
 - π sa môže lišiť od exploračnej politiky
 - ak π je greedy, tak je Q-learning
- **Expected Sarsa** algoritmus


(algoritmus podobný ako pre Q-Learning, zmena iba v jednom riadku)

Porovnanie algoritmov

- Koniec epizódy: krík, pravé dolné poličko
- Odmena: -100 (krík), -1 (ostatné polička)
- Parametre: 500 epizód, $\alpha = 0.2$, $\gamma = 0.9$, $\epsilon = 0.1$



Dvojité učenie



- Maximalizačná odchýlka
 - $E[R \in N(-0.1, 1)] < 0$
 - $\max[R \in N(-0.1, 1)] > 0$
- Použitie jedného odhadu Q
 - pre určenie najlepšej akcie A_{t+1} v stave S_{t+1}
 - pre odhad hodnoty $q(S_{t+1}, A_{t+1})$
 - rozhodnutia sú **závislé**
- Použitie dvoch nezávislých odhadov Q_1 a Q_2
 - $Q_2(S_{t+1}, \arg \max_a Q_1(S_{t+1}, a))$
 - $Q_1(S_{t+1}, \arg \max_a Q_2(S_{t+1}, a))$
 - update iba Q_1 alebo Q_2
 - striedanie rolí Q_1 a Q_2

Algoritmus Dvojité Q-Learning

Double Q-learning, for estimating $Q_1 \approx Q_2 \approx q_*$

Algorithm parameters: step size $\alpha \in (0, 1]$, small $\varepsilon > 0$

Initialize $Q_1(s, a)$ and $Q_2(s, a)$, for all $s \in \mathcal{S}^+$, $a \in \mathcal{A}(s)$, such that $Q(\text{terminal}, \cdot) = 0$

Loop for each episode:

 Initialize S

 Loop for each step of episode:

 Choose A from S using the policy ε -greedy in $Q_1 + Q_2$

 Take action A , observe R, S'

 With 0.5 probability:

$$Q_1(S, A) \leftarrow Q_1(S, A) + \alpha \left(R + \gamma Q_2(S', \arg \max_a Q_1(S', a)) - Q_1(S, A) \right)$$

 else:

$$Q_2(S, A) \leftarrow Q_2(S, A) + \alpha \left(R + \gamma Q_1(S', \arg \max_a Q_2(S', a)) - Q_2(S, A) \right)$$

$S \leftarrow S'$

until S is terminal

Dvojitá (Expected) Sarsa

$$\pi(a|s) = \begin{cases} 1 - \epsilon + \frac{\epsilon}{|A(s)|} & a = \arg \max_a (Q_1(s, a) + Q_2(s, a)) \\ \frac{\epsilon}{|A(s)|} & \text{inak} \end{cases}$$

Sarsa

$$Q_1(S_t, A_t) \leftarrow Q_1(S_t, A_t) + \alpha [R_{t+1} + \gamma Q_2(S_{t+1}, A_{t+1}) - Q_1(S_t, A_t)]$$
$$Q_2(S_t, A_t) \leftarrow Q_2(S_t, A_t) + \alpha [R_{t+1} + \gamma Q_1(S_{t+1}, A_{t+1}) - Q_2(S_t, A_t)]$$

Expected Sarsa

$$Q_1(S_t, A_t) \leftarrow$$
$$Q_1(S_t, A_t) + \alpha [R_{t+1} + \gamma \sum_a \pi(a|S_{t+1}) Q_2(S_{t+1}, a) - Q_1(S_t, A_t)]$$
$$Q_2(S_t, A_t) \leftarrow$$
$$Q_2(S_t, A_t) + \alpha [R_{t+1} + \gamma \sum_a \pi(a|S_{t+1}) Q_1(S_{t+1}, a) - Q_2(S_t, A_t)]$$

Greedy exploračná politika

- Princíp - monotónny update odhadu Q
 - všetky $Q(s, a)$ inicializovať na vysoké hodnoty
 - update iba v tvare **zníženia** odhadu
 - explorácia
 - greedy politika v stave S_t vyberie akciu A_t
 - aktualizuje sa (zníži) hodnota $Q(S_t, A_t)$
 - hodnota pre nejakú inú akciu v S_t ostane vyššou ako pre akciu A_t
 - pri ďalšej návštive stavu S_t greedy politika vyberie inú akciu a nie A_t
- Podmienky realizácie
 - odmena $R_i \in [0, 1]$ pre $i = 1, 2, \dots$
 - maximálne možná kumulatívna odmena

$$\begin{aligned}G_t &= \sum_{k=t+1}^{\infty} \gamma^{k-t-1} R_k \leq \sum_{k=t+1}^{\infty} \gamma^{k-t-1} R_{max} \\&= \sum_{k=t+1}^{\infty} \gamma^{k-t-1} = \sum_{k=1}^{\infty} \gamma^{k-1} = \frac{1}{1-\gamma}\end{aligned}$$

Oneskorený Q-Learning

- Hodnoty Q inicializované na $1/(1 - \gamma)$
- Update $Q(s, a)$ sa deje na základe väčšieho množstva dát
 - nech v čase t v stave $S_t = s$ bola akcia $A_t = a$
 - ak pre (s, a) je už k dispozícii zozbieraný dostatok dát z aktuálnej a minulých návštev $(r_1, s'_1, \dots, r_m, s'_m)$, tak
 - určí sa nová **možná** hodnota pre $Q_{t+1}(s, a)$

$$U(s, a) = \frac{1}{m} \sum_{i=1}^m (r_i + \gamma \max_{a'} Q_t(s'_i, a')) + \epsilon_1$$

kde úlohou ϵ_1 je napomôcť $Q(s, a) \geq Q_*(s, a)$

- ak $Q_t(s, a) - U(s, a) \geq \epsilon_1$ tak sa update realizuje $Q_{t+1}(s, a) = U(s, a)$, inak nie
- zozbierané dáta pre (s, a) sa zahodia
- ak dát pre (s, a) nie je dostatok, pokračuje sa v ich zbieraní

Q-Learnig vs Oneskorený Q-Learnig

- Q-Learning: $Q_{t+1} = (1 - \alpha)Q_t + \alpha(r + \gamma \max_a Q(s', a))$
- Pre (s, a) bolo získané r_1 a s_1 ($\alpha = 1$)

$$Q_{t+1}(s, a) = (1 - 1)Q_t + (r_1 + \gamma \max_{a'} Q(s_1, a')) = (r_1 + \gamma \max_{a'} Q(s_1, a'))$$

- Pre (s, a) bolo získané r_2 a s_2 ($\alpha = 1/2$)

$$Q_{t+2}(s, a) = (1 - 1/2)Q_{t+1}(s, a) + 1/2(r_2 + \gamma \max_{a'} Q(s_2, a'))$$

$$= 1/2(r_1 + \gamma \max_{a'} Q(s_1, a')) + 1/2(r_2 + \gamma \max_{a'} Q(s_2, a'))$$

$$= 1/2 \sum_{i=1}^2 (r_i + \gamma \max_{a'} Q(s_i, a'))$$

- Pre (s, a) bolo získané r_3 a s_3 ($\alpha = 1/3$)

$$Q_{t+3}(s, a) = (1 - 1/3)Q_{t+2}(s, a) + 1/3(r_3 + \gamma \max_{a'} Q(s_3, a'))$$

$$= 2/3(1/2 \sum_{i=1}^2 (r_i + \gamma \max_{a'} Q(s_i, a'))) + 1/3(r_3 + \gamma \max_{a'} Q(s_3, a'))$$

$$= 1/3 \sum_{i=1}^3 (r_i + \gamma \max_{a'} Q(s_i, a'))$$

- Oneskorený Q-Learning = Q-Learning so zmenšujúcou sa hodnotou α (s dávkovým updatom)

Backup diagram

