

# Temporal-difference metódy

## (Strojové učenie II)

M. Mach

Katedra kybernetiky a umelej inteligencie, FEI, TUKE

február 2021 - marec 2024

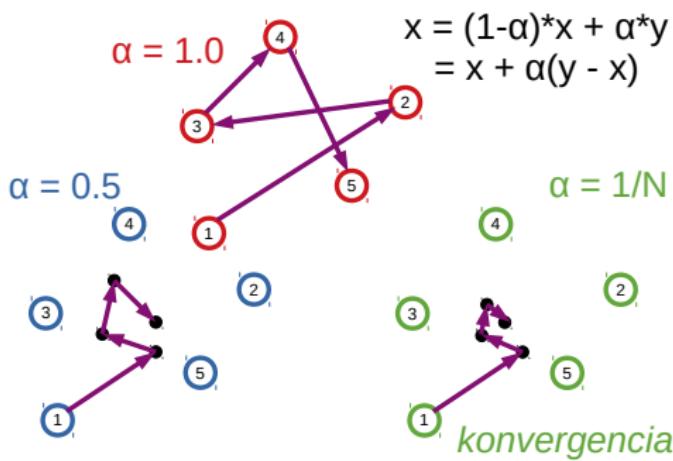


# Temporal-difference učenie posilňovaním

- 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

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



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

# 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- $\alpha$  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 $v_\pi$

## Tabular TD(0) for estimating $v_\pi$

Input: the policy  $\pi$  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  $\pi$  for  $S$

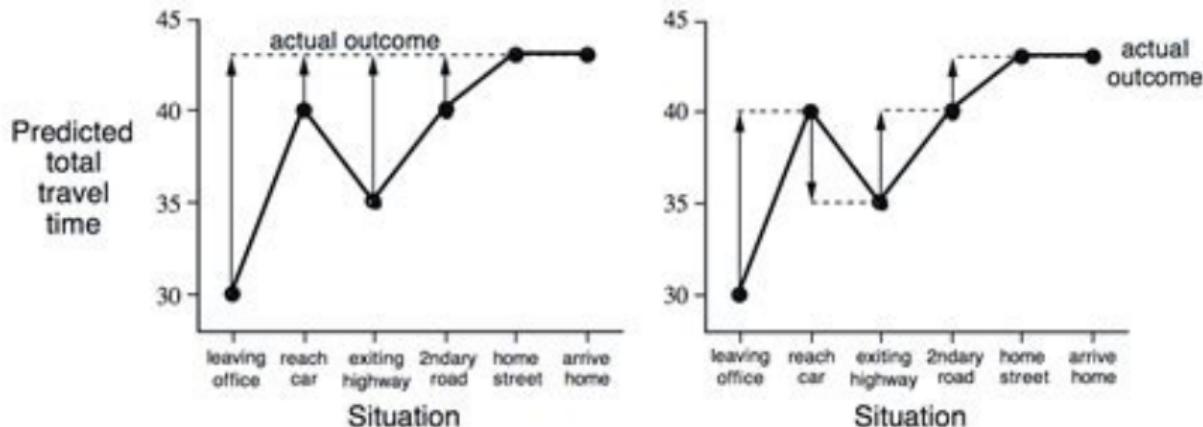
        Take action  $A$ , observe  $R, S'$

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

$S \leftarrow S'$

    until  $S$  is terminal

# Illustračný 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)

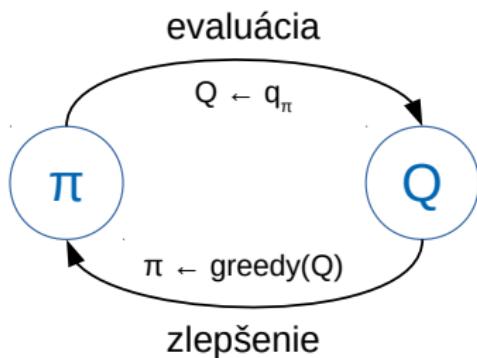
# Konvergencia

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

- Podmienky pre konvergenciu  $V$  k  $v_\pi$ 
  - $\sum_{n=1}^{\infty} \alpha_n = \infty$
  - $\sum_{n=1}^{\infty} \alpha_n^2 < \infty$
- TD - konverguje iba približne (v priemere)
  - $\alpha$  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- $\alpha$  MC
    - TD (online) ? MC

# 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 poznať  $v_\pi$
  - Problém explorácie
    - pokrytie párov  $(s, a)$
    - $\epsilon$ -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  $\pi_*$ )
  - 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.,  $\varepsilon$ -greedy)

    Loop for each step of episode:

        Take action  $A$ , observe  $R, S'$

        Choose  $A'$  from  $S'$  using policy derived from  $Q$  (e.g.,  $\varepsilon$ -greedy)

$$Q(S, A) \leftarrow Q(S, A) + \alpha [R + \gamma Q(S', A') - Q(S, A)]$$

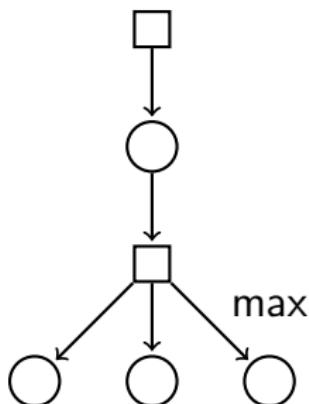
$S \leftarrow S'; A \leftarrow A'$ ;

    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  $\pi_*$ )
  - 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.,  $\varepsilon$ -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

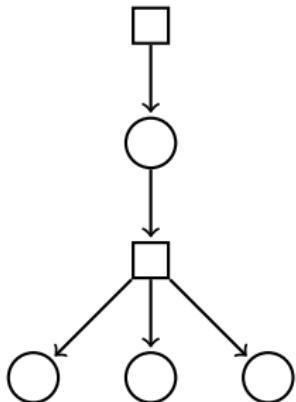
©Sutton-Barto: Reinforcement Learning, 2nd ed., 2018



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

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

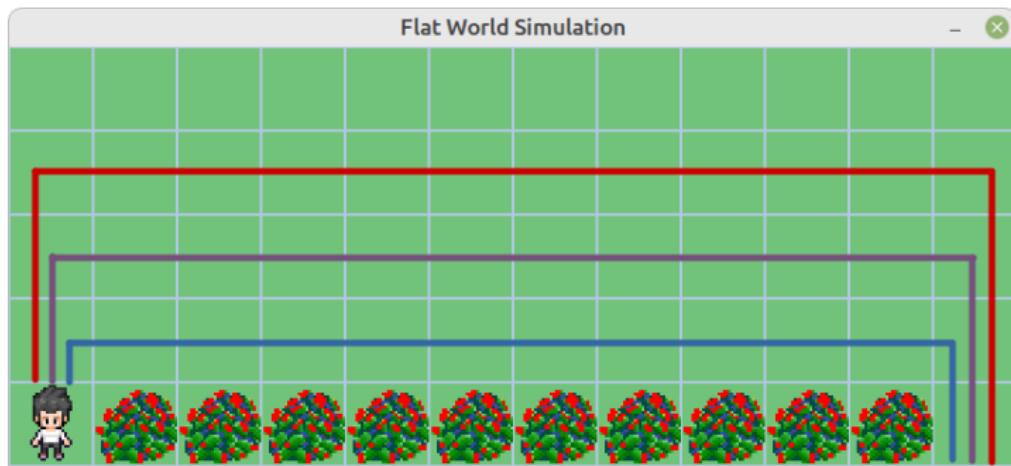
- $Q(S_t, A_t)$  je
  - pre neterminálny stav aktualizované podľa **štvorice** vybranej zo sekvencie
  - nulové pre terminálny stav
- Spriemerňovanie akcií v  $S_{t+1}$   
 $E[Q(S_{t+1}, A_{t+1})|S_{t+1}] = \sum_a \pi(a|S_{t+1})Q(S_{t+1}, a)$
- On-policy/Off-policy odhad
  - $\pi$  sa môže lišiť od exploračnej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



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

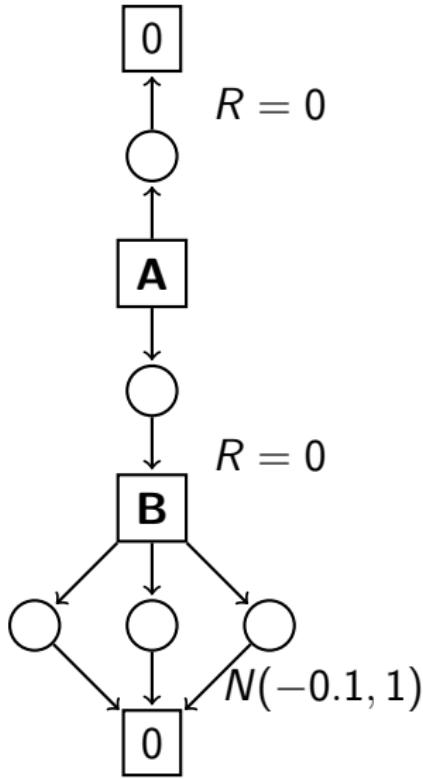
# Porovnanie algoritmov

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



Sarsa, Expected Sarsa, Q-Learning

# 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 Dvojitý 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  $\varepsilon$ -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  $\epsilon_1$  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-Learning vs Oneskorený Q-Learning

- 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  $s_2$  ( $\alpha = 1/2$ )

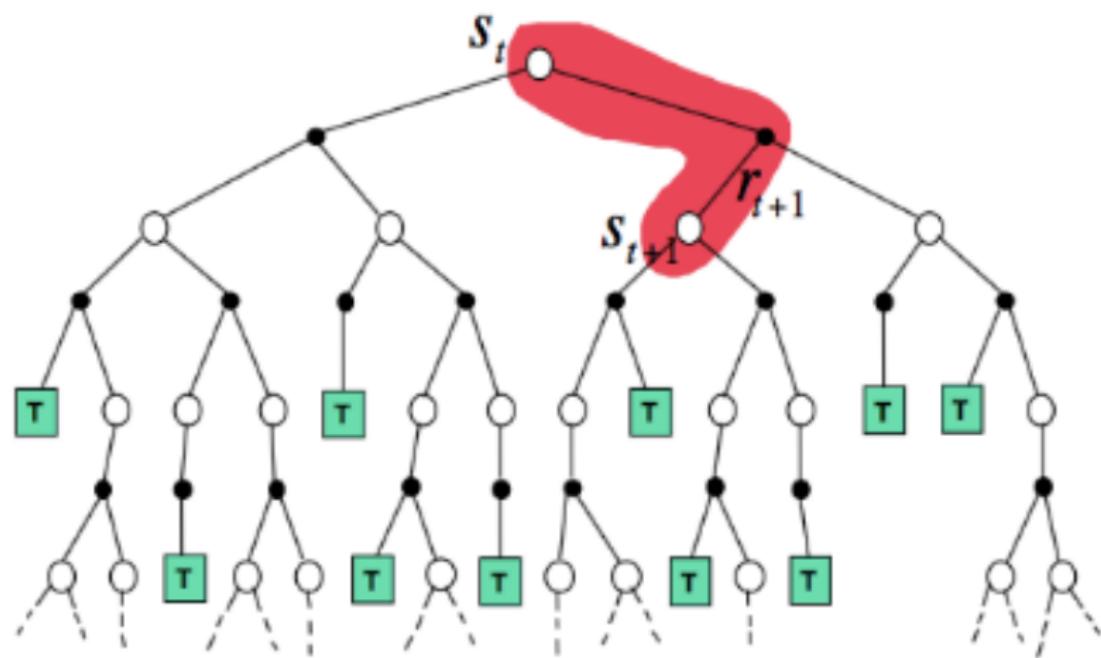
$$\begin{aligned} Q_{t+2}(s, a) &= (1 - 1/2)Q_{t+1}(s, a) + 1/2(r_2 + \gamma \max_{a'} Q(s_2, a')) \\ &= 1/2(r_1 + \gamma \max_{a'} Q(s_1, a')) + 1/2(r_2 + \gamma \max_{a'} Q(s_2, a')) \\ &= 1/2 \sum_{i=1}^2 (r_i + \gamma \max_{a'} Q(s_i, a')) \end{aligned}$$

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

$$\begin{aligned} Q_{t+3}(s, a) &= (1 - 1/3)Q_{t+2}(s, a) + 1/3(r_3 + \gamma \max_{a'} Q(s_3, a')) \\ &= 2/3(1/2 \sum_{i=1}^2 (r_i + \gamma \max_{a'} Q(s_i, a'))) + 1/3(r_3 + \gamma \max_{a'} Q(s_3, a')) \\ &= 1/3 \sum_{i=1}^3 (r_i + \gamma \max_{a'} Q(s_i, a')) \end{aligned}$$

- Oneskorený Q-Learning = Q-Learning so zmenšujúcou sa hodnotou  $\alpha$  (s dávkovým updatom)

# Backup diagram



©/lilianweng.github.io

