


# Методы решения задач обучения с подкреплением

---

Следы преемственности

# Методы временных разностей и методы Монте-Карло

---



# Возвраты методов временных разностей и Монте-Карло

---

- Монте-Карло, полный возврат

$$R_t^{(n)} = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots + \gamma^{T-t-1} r_T.$$

---

- TD(0), одношаговый возврат

$$R_t^{(n)} = r_{t+1} + \gamma V_t(s_{t+1}).$$

- Двухшаговый возврат

$$R_t^{(n)} = r_{t+1} + \gamma r_{t+2} + \gamma^2 V_t(s_{t+2}).$$

- N-шаговый возврат

$$R_t^{(n)} = r_{t+1} + \gamma r_{t+2} + \gamma^2 r_{t+3} + \dots + \gamma^{n-1} r_{t+n} + \gamma^n V_t(s_{t+n}).$$

---

# Многошаговые методы временных разностей

---

- N-шаговое обновление

$$\Delta V_t(s_t) = \alpha \left[ R_t^{(n)} - V_t(s_t) \right],$$

- Онлайн обновление

$$V_{t+1}(s) = V_t(s) + \Delta V_t(s)$$

- Пакетное обновление


$$V(s) + \sum_{t=0}^{T-1} \Delta V_t(s)$$

- Свойство сокращения ошибки


$$\max_s \left| E_\pi \left\{ R_t^{(n)} \mid s_t = s \right\} - V^\pi(s) \right| \leq \gamma^n \max_s |V(s) - V^\pi(s)|.$$

---


# Многошаговые методы временных разностей. Пример.



Онлайн  
обновление




Пакетное  
обновление



# Сложные обновления

---

$$R_t^{ave} = \frac{1}{2}R_t^{(2)} + \frac{1}{2}R_t^{(4)}$$




# λ-возврат

$$R_t^\lambda = (1 - \lambda) \sum_{n=1}^{\infty} \lambda^{n-1} R_t^{(n)}.$$

$$R_t^\lambda = (1 - \lambda) \sum_{n=1}^{T-t-1} \lambda^{n-1} R_t^{(n)} + \lambda^{T-t-1} R_t.$$


Если  $\lambda=1$ , то получаем  $R_t^\lambda=R_t$ .

Если  $\lambda=0$ , то получаем  $R_t^\lambda=R_t^{(1)}$ .



# λ-возврат

$$R_t^\lambda = (1 - \lambda) \sum_{n=1}^{\infty} \lambda^{n-1} R_t^{(n)}.$$




# Алгоритм $\lambda$ -возврата


---

- Используем обновление

$$\Delta V_t(s_t) = \alpha [R_t^\lambda - V_t(s_t)].$$



# Алгоритм $\lambda$ -возврата



# Следы преемственности


---

- Вводим для каждого состояния параметр, называемый след преемственности:

$$e_t(s) = \begin{cases} \gamma \lambda e_{t-1}(s) & \text{if } s \neq s_t; \\ \gamma \lambda e_{t-1}(s) + 1 & \text{if } s = s_t, \end{cases}$$

След преемственности

Моменты посещения



# Алгоритм TD( $\lambda$ )

---

- След преемственности показывает, «как давно» мы были в состоянии  $s$ , и, соответственно, насколько оно ответственно за дальнейшее:

$$e_t(s) = \begin{cases} \gamma \lambda e_{t-1}(s) & \text{if } s \neq s_t; \\ \gamma \lambda e_{t-1}(s) + 1 & \text{if } s = s_t, \end{cases}$$

- «Отвечаем» мы согласно ошибке временных разностей

$$\delta_t = r_{t+1} + \gamma V_t(s_{t+1}) - V_t(s_t).$$

- Получаем следующее обновление

$$\Delta V_t(s) = \alpha \delta_t e_t(s), \quad \text{for all } s \in \mathcal{S}.$$

---

# Алгоритм TD( $\lambda$ )

---

Инициализация:

$V(s) \leftarrow$  произвольно,  
 $e(s) \leftarrow 0$ , для всех  $s \in S$ .

Повторять (для всех эпизодов)

$s \leftarrow$  начальное состояние

Повторять (для всех шагов эпизода)

$a \leftarrow$  действие для  $s$  согласно  $\pi$ .

Выполнить  $a$ , узнать  $r$  и  $s'$ .

$\delta \leftarrow r + \gamma V(s') - V(s)$

$e(s) \leftarrow e(s) + 1$

Для всех  $s$ :

$V(s) \leftarrow V(s) + a \delta e(s)$


$e(s) \leftarrow \gamma \lambda e(s)$

$s \leftarrow s'$

---

# Алгоритм TD( $\lambda$ )

---




Если  $\lambda=0$ , то все  $e(s)=0$ , кроме  $s=s_t \Rightarrow$  получаем эквивалент TD(0)

Если  $\lambda=1$ , то все  $e$  затухает только по  $\gamma \Rightarrow$  получаем эквивалент метода Монте-Карло.

---

# Алгоритм TD( $\lambda$ ). Пример



# Sarsa( $\lambda$ )


- Для управления нам нужно вычислять  $Q$ . Введём след преемственности для пары (состояние, действие):

$$e_t(s, a) = \begin{cases} \gamma \lambda e_{t-1}(s, a) + 1 & \text{if } s = s_t \text{ and } a = a_t; \\ \gamma \lambda e_{t-1}(s, a) & \text{otherwise.} \end{cases}$$

- Тогда

$$Q_{t+1}(s, a) = Q_t(s, a) + \alpha \delta_t e_t(s, a),$$

$$\delta_t = r_{t+1} + \gamma Q_t(s_{t+1}, a_{t+1}) - Q_t(s_t, a_t)$$



# Алгоритм Sarsa( $\lambda$ )

---

Инициализация:

$Q(s,a) \leftarrow$  произвольно,  
 $e(s,a) \leftarrow 0$ , для всех  $s \in S, a \in A(s)$ .

Повторять (для всех эпизодов)

$(s,a) \leftarrow$  начальное состояние и действие

Повторять (для всех шагов эпизода)

Выполнить  $a$ , узнать  $r$  и  $s'$ .

$a' \leftarrow$  действие для  $s'$  согласно  $\varepsilon$ -жадной по  $Q$  стратегии

$\delta \leftarrow r + \gamma Q(s'.a') - Q(s,a)$

$e(s,a) \leftarrow e(s,a) + 1$

Для всех  $s,a$ :

$Q(s,a) \leftarrow Q(s,a) + \alpha \delta e(s,a)$

$e(s,a) \leftarrow \gamma \lambda e(s,a)$

$s \leftarrow s', a \leftarrow a'$

---



# Следы преемственности и алгоритмы управляющие и оценивающие по разным стратегиям

---

- Алгоритм Sarsa( $\lambda$ ) неизбежно ограничивается  $\varepsilon$ -мягкими стратегиями
  - Чтобы находить оптимальную стратегию, необходимо оценивать одну стратегию, а управлять по другой. Как совместить Q-learning и следы преемственности?
    - Watkins's Q( $\lambda$ )
    - Peng's Q( $\lambda$ )
-

# Watkins's $Q(\lambda)$

---

- Допустим, что в момент времени  $t$  мы хотим обновить  $Q$  для пары  $(s_t, a_t)$ . Пусть два ближайших действия были жадными, а в момент  $t+3$  агент совершит не жадное действие.
  - Изучая жадную стратегию, мы тогда можем использовать одношаговый и двухшаговый возврат, но не трех- и более шаговые.
-


# Watkins's $Q(\lambda)$

---

- Допустим, в момент времени  $t$  мы хотим обновить  $Q$  для пары  $(s_t, a_t)$ . Пусть два ближайших действия были жадными, а в момент  $t+3$  агент совершит не жадное действие.
  - Изучая жадную стратегию, мы тогда можем использовать одношаговый и двухшаговый возврат, но не трех- и более шаговые.
  - Алгоритм Watkins's  $Q(\lambda)$  смотрит на один шаг за исследовательское действие, используя знание функции ценности, делая обновление в направлении  $r_{t+1} + \gamma \max_a Q_t(s_{t+1}, a)$
-

# Watkins's $Q(\lambda)$

Watkins's  $Q(\lambda)$



# Алгоритм Watkins's $Q(\lambda)$

---

Инициализация:

$Q(s,a) \leftarrow$  произвольно,  
 $e(s,a) \leftarrow 0$ , для всех  $s \in S, a \in A(s)$ .

Повторять (для всех эпизодов)

$(s,a) \leftarrow$  начальное состояние и действие

Повторять (для всех шагов эпизода)

Выполнить  $a$ , узнать  $r$  и  $s'$ .

$a' \leftarrow$  действие для  $s'$  согласно  $\varepsilon$ -жадной по  $Q$  стратегии

$a^* \leftarrow \arg \max_b Q(s',b)$

$\delta \leftarrow r + \gamma Q(s',a^*) - Q(s,a)$

$e(s,a) \leftarrow e(s,a) + 1$

Для всех  $s,a$ :

$Q(s,a) \leftarrow Q(s,a) + \alpha \delta e(s,a)$


Если  $a' = a^*$  то  $e(s,a) \leftarrow \gamma e(s,a)$

иначе  $e(s,a) \leftarrow 0$

$s \leftarrow s', a \leftarrow a'$

---

# Peng's $Q(\lambda)$



# Следы преемственности в методах деятеля-критика

---

□ Критик оценивает  $V$ , ему нужны следы для каждого состояния. Затем просто используем TD( $\lambda$ ).

□ Деятелю нужны следы для пары состояние-действие.

■ Простой метод обновлял предпочтения по правилу

$$p_{t+1}(s, a) = \begin{cases} p_t(s, a) + \alpha \delta_t & \text{if } a = a_t \text{ and } s = s_t \\ p_t(s, a) & \text{otherwise,} \end{cases}$$

■ Используем обновление

$$p_{t+1}(s, a) = p_t(s, a) + \alpha \delta_t e_t(s, a),$$

---

# Следы преемственности в методах деятеля-критика

---

- Более хитрый деятель действовал по правилу

$$p_{t+1}(s, a) = \begin{cases} p_t(s, a) + \alpha \delta_t [1 - \pi_t(s, a)] & \text{if } a = a_t \text{ and } s = s_t \\ p_t(s, a) & \text{otherwise.} \end{cases}$$

- Для создания эквивалента этого метода используем следующий способ вычисления следа преемственности

$$e_t(s, a) = \begin{cases} \gamma \lambda e_{t-1}(s, a) + 1 - \pi_t(s_t, a_t) & \text{if } s = s_t \text{ and } a = a_t \\ \gamma \lambda e_{t-1}(s, a) & \text{otherwise,} \end{cases}$$

$$p_{t+1}(s, a) = p_t(s, a) + \alpha \delta_t e_t(s, a),$$

---

# Виды следов преемственности


---

- Аккумулирующие следы преемственности

$$e_t(s) = \begin{cases} \gamma \lambda e_{t-1}(s) & \text{if } s \neq s_t; \\ \gamma \lambda e_{t-1}(s) + 1 & \text{if } s = s_t, \end{cases}$$

- Замещающие следы преемственности


$$e_t(s) = \begin{cases} \gamma \lambda e_{t-1}(s) & \text{if } s \neq s_t; \\ 1 & \text{if } s = s_t. \end{cases}$$



# Виды следов преемственности

---

- Замещающие следы преемственности для действий



$$e_t(s, a) = \begin{cases} 1 + \gamma \lambda e_{t-1}(s, a) & \text{if } s = s_t \text{ and } a = a_t; \\ 0 & \text{if } s = s_t \text{ and } a \neq a_t; \\ \gamma \lambda e_{t-1}(s, a) & \text{if } s \neq s_t. \end{cases} \quad \text{for all } s, a$$

# Переменные следы преемственности

---

$$e_t(s) = \begin{cases} \gamma \lambda_t e_{t-1}(s) & \text{if } s \neq s_t; \\ \gamma \lambda_t e_{t-1}(s) + 1 & \text{if } s = s_t, \end{cases}$$

$$\begin{aligned} R_t^\lambda &= \sum_{n=1}^{\infty} R_t^{(n)} (1 - \lambda_{t+n}) \prod_{i=t+1}^{t+n-1} \lambda_i \\ &= \sum_{k=t+1}^{T-1} R_t^{(k-t)} (1 - \lambda_k) \prod_{i=t+1}^{k-1} \lambda_i + R_t \prod_{i=t+1}^{T-1} \lambda_i \end{aligned}$$

- Например  $\lambda_t = \lambda(s_t)$ 
    - Если мы имеем хорошую оценку для состояния, то можем брать её, игнорируя последующее ( $\lambda$  около 0).
    - Если мы не уверены в оценке состояния, то делая  $\lambda$  близким к 1 мы даём малый вес оценке состояния и большой – тому, что произойдёт позднее.
-