Обучение с подкреплением (Reinforcement Learning)

К. В. Воронцов
vokov@forecsys.ru

Этот курс доступен на странице вики-ресурса
http://www.MachineLearning.ru/wiki
«Машинное обучение (курс лекций, К.В.Воронцов)»

ноябрь 2012

Содержание

Задача о многоруком бандите

A — множество возможных *действий*
$p_a(r)$ — неизвестное распределение *премии* $r \in \mathbb{R}$ за $\forall a \in A$
$\pi_t(a)$ — *стратегия* агента в момент t, распределение на A

Игра агента со средой:

1: инициализация стратегии $\pi_1(a)$
2: **для всех** $t = 1, \dots T, \dots$
3: агент выбирает действие $a_t \sim \pi_t(a)$;
4: среда генерирует премию $r_t \sim p_{a_t}(r)$;
5: агент корректирует стратегию $\pi_{t+1}(a)$;

$$Q_t(a) = \frac{\sum_{i=1}^t r_i [a_i = a]}{\sum_{i=1}^t [a_i = a]} \to \max \quad \text{— средняя премия в } t \text{ играх}$$

$$Q^*(a) = \lim_{t\to\infty} Q_t(a) \to \max \quad \text{— ценность действия } a$$

Примеры прикладных задач

- Управление технологическими процессами
- Управление роботами
- Персонализация показов рекламы в Интернете
- Управление ценами и ассортиментом в сетях продаж
- Игра на бирже
- Маршрутизация в телекоммуникационных сетях
- Маршрутизация в беспроводных сенсорных сетях
- Логические игры (шашки, нарды, и т.д.)

Жадная стратегия

Множество действий с максимальной текущей оценкой ценности:

$$A_t = \operatorname{Arg}\max_{a \in A} Q_t(a)$$

Жадная стратегия — выбирать любое действие из A_t:

$$\pi_{t+1}(a) = \frac{1}{|A_t|}[a \in A_t]$$

Недостаток жадной стратегии — по некоторым действиям a можем так и не набрать статистику для оценки $Q_t(a)$.

ε-жадная стратегия (компромисс «изучение—применение»):

$$\pi_{t+1}(a) = \frac{1-\varepsilon}{|A_t|}[a \in A_t] + \frac{\varepsilon}{|A \backslash A_t|}$$

Эвристика: параметр ε имеет смысл уменьшать со временем.

Стратегия softmax (распределение Гиббса)

Мягкий вариант компромисса «изучение—применение»:
чем больше $Q_t(a)$, тем больше вероятность выбора a:

$$\pi_{t+1}(a) = \frac{\exp\bigl(Q_t(a)/\tau\bigr)}{\sum\limits_{b\in A} \exp\bigl(Q_t(b)/\tau\bigr)}$$

где τ — параметр *температуры*,
при $\tau \to 0$ стратегия стремится к жадной,
при $\tau \to \infty$ — к равномерной, т.е. чисто исследовательской

Эвристика: параметр τ имеет смысл уменьшать со временем.

Какая из стратегий лучше?
— зависит от конкретной задачи,
— решается в эксперименте

Модельные эксперименты в обучении с подкреплением

«10-рукая испытательная среда»:
Генерируется 2000 задач, в каждой задаче

$$|A| = 10,$$
$$p_a(r) = \mathcal{N}(r; Q^*(a), 1),$$
$$Q^*(a) \sim \mathcal{N}(0, 1).$$

Строятся графики зависимости
— среднего вознаграждения (average reward),
— доли оптимальных действий (% optimal action),
от числа действий (сыгранных игр),
усреднённые по 2000 задачам.

Richard Sutton, Andrew Barto. Reinforcement Learning: An Introduction. The MIT Press. 1998, 2004.
http://webdocs.cs.ualberta.ca/ sutton/book/ebook/the-book.html
Русский перевод:
Р. Саттон, Э. Барто. Обучение с подкреплением. Изд-во «Бином». 2011.

Сравнение жадных и ε-жадных стратегий

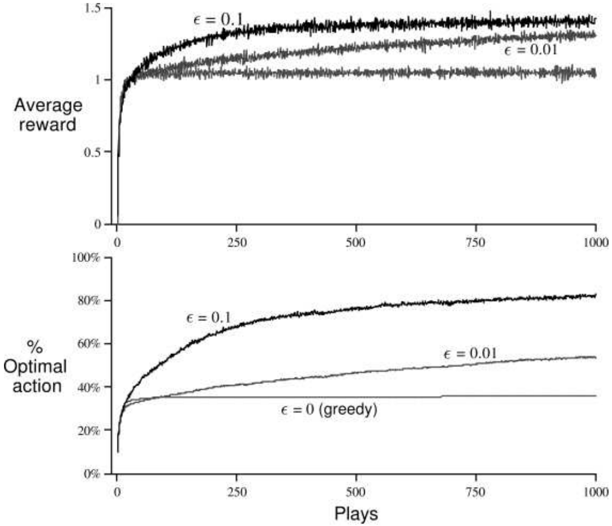

Рекуррентная формула для эффективного вычисления средних

Общая формула вычисления Q_t для корректировки стратегии:

$$Q_{t+1}(a) = (1 - \alpha_t)Q_t(a) + \alpha_t r_{t+1} = Q_t(a) + \alpha_t \bigl(r_{t+1} - Q_t(a)\bigr)$$

При $\alpha_t = \frac{1}{k_t(a)+1}$ это среднее арифметическое, $k_t(a) = \sum\limits_{i=1}^{t} [a_i = a]$

При $\alpha_t = \text{const}$ это экспоненциальное скользящее среднее

Условие сходимости к среднему:

$$\sum_{t=1}^{\infty} \alpha_t = \infty, \qquad \sum_{t=1}^{\infty} \alpha_t^2 < \infty$$

Среднее арифметическое — для стационарных задач

Экспоненциальное скользящее среднее — для нестационарных (в этом случае сходимости нет, но она и не нужна)

Экспоненциальное скользящее среднее (напоминание)

Задача прогнозирования временного ряда $y_0, \dots, y_t, \dots$:
— простейшая регрессионная модель — константа $y_t = c$,
— наблюдения учитываются с весами, убывающими в прошлое,
— прогноз $\hat{y}_{t+1}$ методом наименьших квадратов:

$$\sum_{i=0}^{t} w_{t-i}(y_i - c)^2 \to \min_c, \quad w_i = \beta^i, \quad \beta \in (0,1)$$

Аналитическое решение — формула Надарая-Ватсона:

$$c \equiv \hat{y}_{t+1} = \frac{\sum_{i=0}^{t} \beta^i y_{t-i}}{\sum_{i=0}^{t} \beta^i}$$

Запишем аналогично $\hat{y}_t$, оценим $\sum_{i=0}^{t} \beta^i \approx \sum_{i=0}^{\infty} \beta^i = \frac{1}{1-\beta}$,

получим $\hat{y}_{t+1} = \hat{y}_t \beta + (1-\beta) y_t$, заменим $\alpha = 1 - \beta$:

$$\hat{y}_{t+1} = (1-\alpha)\hat{y}_t + \alpha y_t = \hat{y}_t + \alpha(y_t - \hat{y}_t)$$

Метод сравнения с подкреплением (reinforcement comparison)

Идея: использовать не сами значения премий, а их разности со средней (эталонной) премией:

$\bar{r}_{t+1} = \bar{r}_t + \alpha(r_t - \bar{r}_t)$ — *средняя премия*

$p_{t+1}(a_t) = p_t(a_t) + \beta(r_t - \bar{r}_t - p_t(a_t))$ — *предпочтения* действий

$$\pi_{t+1}(a) = \frac{\exp\bigl(p_{t+1}(a)/\tau\bigr)}{\sum\limits_{b\in A} \exp\bigl(p_{t+1}(b)/\tau\bigr)}$$ — softmax-стратегия агента

Начальное приближение r_0**:** оптимистично завышенное стимулирует изучающие действия в начале

Экспериментальный факт:
метод сравнения с подкреплением обычно сходится быстрее.

Сравнение с подкреплением лучше ε-жадных стратегий

Эксперимент с 10-рукой испытательной средой:

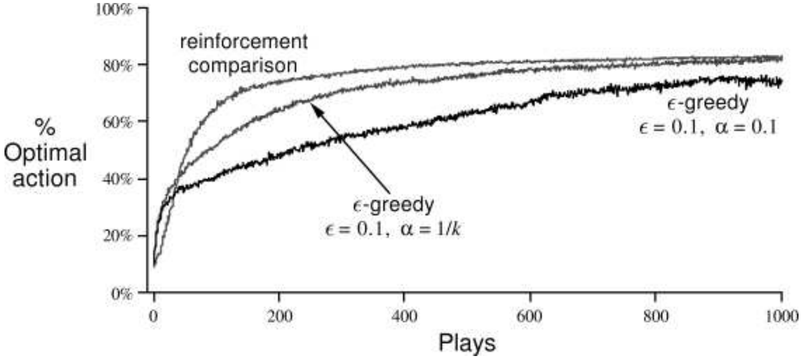

Метод преследования (pursuit) жадной стратегии

Вместо собственно *жадной стратегии*

$$\pi_{t+1}(a) = \frac{[a \in A_t]}{|A_t|}$$

предлагается *преследование* (сглаживание) жадной стратегии:

$$\pi_{t+1}(a) = \pi_t(a) + \beta\left(\frac{[a \in A_t]}{|A_t|} - \pi_t(a)\right)$$

Стратегия преследования ещё лучше

Эксперимент с 10-рукой испытательной средой:

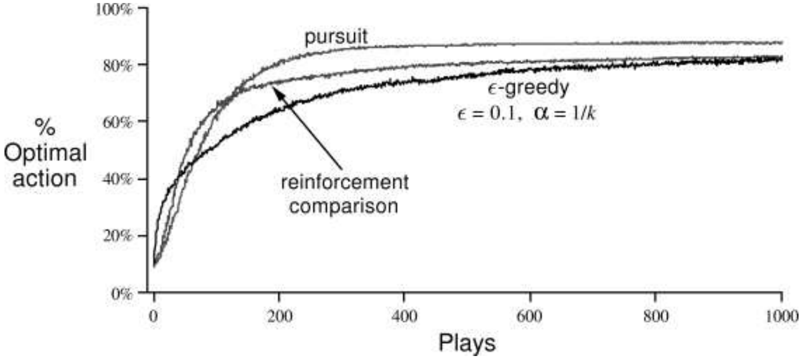

Полная постановка задачи обучения с подкреплением

S — множество состояний среды

Игра агента со средой:

1: инициализация стратегии $\pi_1(a|s)$ и состояния среды s_1
2: **для всех** $t = 1, \dots T, \dots$
3: агент выбирает действие $a_t \sim \pi_t(a|s_t)$;
4: среда генерирует премию $r_{t+1} \sim p(r|a_t, s_t)$
и новое состояние $s_{t+1} \sim p(s|a_t, s_t)$;
5: агент корректирует стратегию $\pi_{t+1}(a|s)$;

Это *марковский процесс принятия решений* (МППР), если

$$\mathsf{P}\bigl(s_{t+1} = s', r_{t+1} = r \bigm| s_t, a_t, r_t,\ s_{t-1}, a_{t-1}, r_{t-1}, \dots, s_1, a_1\bigr) = \\ = \mathsf{P}\bigl(s_{t+1} = s', r_{t+1} = r \bigm| s_t, a_t\bigr)$$

МППР называется финитным, если $|A| < \infty$, $|S| < \infty$.

Выгода. Ценность состояния. Ценность действия

$R_t = r_{t+1} + r_{t+2} + \cdots + r_{t+k} + \cdots$ — *суммарная выгода*

Обобщение — *дисконтированная выгода*:

$R_t = r_{t+1} + \gamma r_{t+2} + \cdots + \gamma^{k-1} r_{t+k} + \cdots$

$\gamma \in [0, 1]$ — коэффициент дисконтирования:

чем выше γ, тем более агент дальновидный

Функция ценности состояния s при стратегии π:

$$V^\pi(s) = \mathsf{E}_\pi(R_t | s_t = s) = \mathsf{E}_\pi\left(\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \;\middle|\; s_t = s\right)$$

Функция ценности действия a в состоянии s при стратегии π:

$$Q^\pi(s, a) = \mathsf{E}_\pi(R_t | s_t = s,\ a_t = a) = \mathsf{E}_\pi\left(\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \;\middle|\; s_t = s,\ a_t = a\right)$$

E_π — мат.ожидание при условии, что агент следует стратегии π

Уравнения Беллмана для V^π

Пусть имеется полная информация о среде (что не реально):
$\mathcal{P}^a_{ss'} = p(s_{t+1}=s' | s_t=s,\ a_t=a)$ — вероятности переходов $s \xrightarrow{a} s'$
$\mathcal{R}^a_{ss'} = \mathsf{E}(r_{t+1} | s_t=s,\ a_t=a,\ s_{t+1}=s')$ — ожидаемые премии

$$V^\pi(s) = \mathsf{E}_\pi\Bigl(r_{t+1} + \gamma \textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+2} \bigm| s_t=s\Bigr) =$$

$$= \underbrace{\mathsf{E}_\pi\bigl(r_{t+1} \bigm| s_t=s\bigr)}_{(1)} + \gamma\, \underbrace{\mathsf{E}_\pi\bigl(\textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+2} \bigm| s_t=s\bigr)}_{(2)}$$

$$(1) = \sum_a \sum_{s'} \mathcal{R}^a_{ss'} \mathcal{P}^a_{ss'} \pi(a|s)$$

$$(2) = \sum_a \sum_{s'} \mathsf{E}_\pi\bigl(\textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+2} \bigm| s_{t+1}=s'\bigr) \mathcal{P}^a_{ss'} \pi(a|s)$$

Отсюда *уравнение Беллмана* для ценности состояний V^π:

$$V^\pi(s) = \sum_a \pi(a|s) \sum_{s'} \mathcal{P}^a_{ss'} \bigl(\mathcal{R}^a_{ss'} + \gamma V^\pi(s')\bigr)$$

это система $|S|$ уравнений с $|S|$ неизвестными

Уравнения Беллмана для Q^π

Пусть имеется полная информация о среде (что не реально):
$\mathcal{P}^a_{ss'} = p(s_{t+1}=s' | s_t=s,\ a_t=a)$ — вероятности переходов $s \xrightarrow{a} s'$
$\mathcal{R}^a_{ss'} = \mathsf{E}(r_{t+1} | s_t=s,\ a_t=a,\ s_{t+1}=s')$ — ожидаемые премии

$$Q^\pi(s,a) = \mathsf{E}_\pi\Big(r_{t+1} + \gamma \textstyle\sum_k \gamma^k r_{t+k+2} \;\Big|\; s_t=s,\ a_t=a\Big) =$$

$$= \underbrace{\mathsf{E}_\pi\big(r_{t+1} \;\big|\; s_t=s, a_t=a\big)}_{(1)} + \gamma\, \underbrace{\mathsf{E}_\pi\Big(\textstyle\sum_k \gamma^k r_{t+k+2} \;\Big|\; s_t=s, a_t=a\Big)}_{(2)}$$

$$(1) = \sum_{s'} \mathcal{R}^a_{ss'} \mathcal{P}^a_{ss'}$$

$$(2) = \sum_{s'} \mathsf{E}_\pi\Big(\textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+2} \;\Big|\; s_{t+1}=s',\ a_t=a\Big) \mathcal{P}^a_{ss'}.$$

Отсюда *уравнение Беллмана* для ценности действий Q^π:

$$Q^\pi(s,a) = \sum_{s'} \mathcal{P}^a_{ss'} \big(\mathcal{R}^a_{ss'} + \gamma Q^\pi(s',a)\big)$$

это также система $|S|$ уравнений с $|S|$ неизвестными

Уравнения оптимальности Беллмана

Вводится отношение частичного порядка на стратегиях:
$\pi \leqslant \pi' \;\Leftrightarrow\; \forall s \in S \;\; V^{\pi}(s) \leqslant V^{\pi'}(s)$
$\forall \pi \;\; \pi^* \nleqslant \pi$ — оптимальная стратегия π^*

$V^*(s) = V^{\pi^*}(s)$ — оптимальная функция ценности состояния
$Q^*(s,a) = Q^{\pi^*}(s,a)$ — оптимальная функция ценности действия

Уравнения оптимальности Беллмана (две формы записи):

$$\begin{cases} V^*(s) = \max\limits_{a\in A} \mathsf{E}\bigl(r_{t+1} + \gamma V^*(s_{t+1}) \bigm| s_t = s,\; a_t = a\bigr) \\ Q^*(s,a) = \mathsf{E}\bigl(r_{t+1} + \gamma \max\limits_{a'\in A} Q^*(s_{t+1}, a') \bigm| s_t = s,\; a_t = a\bigr) \end{cases}$$

$$\begin{cases} V^*(s) = \max\limits_{a\in A} \sum\limits_{s'\in S} \mathcal{P}^a_{ss'} \bigl(\mathcal{R}^a_{ss'} + \gamma V^*(s')\bigr) \\ Q^*(s,a) = \sum\limits_{s'\in S} \mathcal{P}^a_{ss'} \bigl(\mathcal{R}^a_{ss'} + \gamma \max\limits_{a'\in A} Q^*(s', a)\bigr) \end{cases}$$

Свойства оптимальных стратегий

Утв. 1. Для финитного МППР оптимальное решение $V^*(s)$, $Q^*(s,a)$ единственно.

Жадная по отношению к $V^*(s)$, $Q^*(s,a)$ стратегия π: выбирать то действие, на котором достигается максимум в уравнениях оптимальности Беллмана:

$$\pi(a|s) > 0 \;\Leftrightarrow\; V^*(s) = \mathsf{E}\bigl(r_{t+1} + \gamma V^*(s_{t+1}) \bigm| s_t = s,\; a_t = a\bigr)$$

$$\pi(a|s) > 0 \;\Leftrightarrow\; Q^*(s,a) = \max_{a'} Q^*(s,a')$$

Утв. 2. Жадная стратегия является оптимальной $(\pi = \pi^*)$

Проблема 1: как одновременно и решить систему, и определить оптимальную стратегию?

Проблема 2: как оценить правые части в условиях игры, когда $\mathcal{P}^a_{ss'}$, $\mathcal{R}^a_{ss'}$ не известны?

Динамическое программирование

Рассматриваем детерминированные стратегии $\pi\colon S \to A$

Теорема об улучшении стратегии.
Если π, π' таковы, что $\forall s \in S \;\; Q^\pi(s, \pi'(s)) \geqslant V^\pi(s)$,
то $\pi \leqslant \pi'$, т.е. $\forall s \in S \;\; V^\pi(s) \leqslant V^{\pi'}(s)$;

Если в состоянии s выбрать a, затем следовать стратегии π, то

$$
\begin{aligned}
Q^\pi(s, a) &= \mathsf{E}_\pi\bigl(r_{t+1} + \gamma V^\pi(s_{t+1}) \bigm| s_t = s,\ a_t = a\bigr) \\
&= \sum_{s' \in S} \mathcal{P}^a_{ss'} \bigl(\mathcal{R}^a_{ss'} + \gamma V^\pi(s')\bigr)
\end{aligned}
$$

Жадное улучшение стратегии:

$$
\pi(s) = \arg\max_a \sum_{s' \in S} \mathcal{P}^a_{ss'} \bigl(\mathcal{R}^a_{ss'} + \gamma V^\pi(s')\bigr)
$$

Утв. Жадная стратегия сходится к оптимальной

Метод итераций по ценностям и стратегиям

Есть два вида шагов, которые можно по-разному сочетать:

1. **Улучшение стратегии π**
   при фиксированной функции ценности V, в состоянии s:
   $$\pi(s) := \arg\max_a \sum_{s' \in S} \mathcal{P}^a_{ss'} \bigl(\mathcal{R}^a_{ss'} + \gamma V(s')\bigr)$$
2. **Один шаг метода простых итераций**
   для системы уравнений оптимальности Беллмана
   при фиксированной стратегии π, в состоянии s:
   $$V(s) := \sum_{s' \in S} \mathcal{P}^{\pi(s)}_{ss'} \bigl(\mathcal{R}^{\pi(s)}_{ss'} + \gamma V(s')\bigr)$$

Эти шаги можно чередовать в произвольном порядке,
(сходимость к оптимальной стратегии гарантируется)
например, выполнять после каждого попадания в состояние s

Метод временных разностей TD(0)

Проблема 2: $\mathcal{P}^a_{ss'}$, $\mathcal{R}^a_{ss'}$ не известны, их надо оценивать из предшествующего опыта игры

$$\begin{aligned} V^\pi(s) &= \mathsf{E}_\pi\left(\textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+1} \;\middle|\; s_t = s\right) = \\ &= \mathsf{E}_\pi\left(r_{t+1} + \gamma \textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+2} \;\middle|\; s_t = s\right) = \\ &= \mathsf{E}_\pi\left(r_{t+1} + \gamma V^\pi(s_{t+1}) \;\middle|\; s_t = s\right) \end{aligned}$$

Метод временных разностей TD (temporal difference)
После того, как выбрано a_t и стали известны r_{t+1}, s_{t+1}, оцениваем $V^\pi(s)$ экспоненциальным скользящим средним:

$$V(s_t) := V(s_t) + \alpha_t\bigl(r_{t+1} + \gamma V(s_{t+1}) - V(s_t)\bigr)$$

Утв. Если α_t уменьшается ($\sum_t \alpha_t = \infty$, $\sum_t \alpha_t^2 < \infty$), и все s посещаются бесконечное число раз, то $V(s) \xrightarrow{\text{пн}} V^\pi(s)$, $t \to \infty$

Метод SARSA (state–action–reward–state–action)

Аналогично TD(0), но для функции ценности действий:

$$Q^\pi(s,a) = \mathsf{E}_\pi\bigl(\textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+1} \bigm| s_t = s,\ a_t = a\bigr) =$$
$$= \mathsf{E}_\pi\bigl(r_{t+1} + \gamma Q^\pi(s_{t+1}, a_{t+1}) \bigm| s_t = s,\ a_t = a\bigr)$$

Игра агента со средой:

1: инициализация стратегии $\pi_1(a|s)$ и состояния среды s_1
2: **для всех** $t = 1, \dots T, \dots$
3: агент выбирает действие $a_t \sim \pi_t(a|s_t)$:
$a_t = \arg\max_a Q(s_t, a)$ — жадная стратегия
(но возможны и другие: ε-жадная, по Гиббсу, ...)
4: среда генерирует $r_{t+1} \sim p(r|a_t, s_t)$ и $s_{t+1} \sim p(s|a_t, s_t)$;
5: агент разыгрывает ещё один шаг: $a' \sim \pi_t(a|s_{t+1})$;
6: $Q(s_t, a_t) := Q(s_t, a_t) + \alpha_t\bigl(r_{t+1} + \gamma Q(s_{t+1}, a') - Q(s_t, a_t)\bigr)$;

Метод Q-обучения

Аппроксимируем оптимальную функцию ценности действия:

$$Q^*(s,a) = \mathsf{E}\Big(r_{t+1} + \gamma \max_{a'} Q^*(s_{t+1}, a') \;\Big|\; s_t = s,\ a_t = a\Big)$$

Оценка $Q^*(s,a)$ экспоненциальным скользящим средним:

$$Q(s_t,a_t) := Q(s_t,a_t) + \alpha_t\Big(r_{t+1} + \gamma \max_{a'} Q(s_{t+1}, a') - Q(s_t,a_t)\Big)$$

Утв. Если α_t уменьшается $(\sum_t \alpha_t = \infty,\ \sum_t \alpha_t^2 < \infty)$, и все s посещаются бесконечное число раз, то $Q \xrightarrow{\text{пн}} Q^*$, $t \to \infty$

В игре выбрасывается шаг 5 и меняется шаг 6.

Многошаговое TD-прогнозирование

Хотелось бы иметь более надёжную оценку $V(s)$ или $Q(s,a)$, приближающуюся к дисконтированной выгоде R_t

$$\begin{aligned}
R_t^{(1)} &= r_{t+1} + \gamma V(s_{t+1})\\
R_t^{(2)} &= r_{t+1} + \gamma r_{t+2} + \gamma^2 V(s_{t+2})\\
&\dots\\
R_t^{(n)} &= r_{t+1} + \gamma r_{t+2} + \dots + \gamma^{n-1} r_{t+n} + \gamma^n V(s_{t+n})\\
R_t &= r_{t+1} + \gamma r_{t+2} + \dots + \gamma^{n-1} r_{t+n} + \dots
\end{aligned}$$

Премии $r_{t+2}, r_{t+3}, \dots$ в момент t неизвестны, но, оказывается, можно усреднять прошлые, а не будущие наблюдения, и асимптотически это приводит к тому же результату!

Метод временных разностей TD(λ)

Идея «следов приемлемости» $e(s)$:
будем корректировать $V(s)$ не только текущего s_t, но и недавно пройденных состояний, с коэффициентом затухания $\lambda \in [0, 1]$

Раньше делали так:
$V(s_t) := V(s_t) + \alpha_t\bigl(r_{t+1} + \gamma V(s_{t+1}) - V(s_t)\bigr);$

Теперь делаем так:
$e(s_t) := e(s_t) + 1;$
$V(s) := V(s) + \alpha_t\bigl(r_{t+1} + \gamma V(s_{t+1}) - V(s)\bigr)e(s), \ \forall s \in S\colon e(s) \neq 0;$
$e(s) := \gamma\lambda e(s), \ \forall s \in S\colon e(s) \neq 0;$

Возможны варианты обновления следов приемлемости:
$e(s) := \min\{\gamma\lambda e(s), 1\}$ — «заметающий след»
$e(s) := \bigl(e(s) < \varepsilon\bigr)\ ?\ 0 : e(s)$ — обнуление слишком старых следов

При $\lambda = 0$ имеем TD(0), при $\lambda = 1$ приближаемся к оценке R_t

Метод SARSA(λ)

Идея следов приемлемости легко переносится на метод SARSA:

Раньше делали так:

$Q(s_t, a_t) := Q(s_t, a_t) + \alpha_t \big(r_{t+1} + \gamma Q(s_{t+1}, a') - Q(s_t, a_t) \big);$

Теперь делаем так:

$e(s_t, a_t) := e(s_t, a_t) + 1;$

для всех $s \in S$, $a \in A$: $e(s, a) \neq 0$

$\quad Q(s, a) := Q(s, a) + \alpha_t \big(r_{t+1} + \gamma Q(s_{t+1}, a') - Q(s, a) \big) e(s, a);$

$\quad e(s, a) := \gamma \lambda e(s, a);$

Метод $Q(\lambda)$

Идея следов приемлемости легко переносится на Q-обучение:

Раньше делали так:

$$Q(s_t, a_t) := Q(s_t, a_t) + \alpha_t \bigl(r_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s_t, a_t)\bigr);$$

Теперь делаем так:

$e(s_t, a_t) := e(s_t, a_t) + 1;$

для всех $s \in S$, $a \in A$: $e(s, a) \neq 0$

$$Q(s, a) := Q(s, a) + \alpha_t \bigl(r_{t+1} + \gamma \max_a Q(s_{t+1}, a) - Q(s, a)\bigr) e(s, a);$$

$$e(s, a) := \gamma\lambda e(s, a);$$

Важная деталь: исследовательские действия должны прерывать следы приемлемости, иначе будут строиться неверные оценки оптимальной стратегии.

Адаптивный ε-жадный метод временных разностей

Идея: чем сильнее колебания (дисперсия) $Q_t(s,a)$, тем больше должна быть вероятность ε_t исследовательских действий.

$$f(s,a) = \left|\frac{\exp(Q_t(s,a)/\sigma) - \exp(Q_{t+1}(s,a)/\sigma)}{\exp(Q_t(s,a)/\sigma) + \exp(Q_{t+1}(s,a)/\sigma)}\right|$$

$$\varepsilon_{t+1}(s) = \varepsilon_t(s) + \delta\bigl(f(s_t,a_t) - \varepsilon_t(s)\bigr)$$

Рекомендации:

$\delta = 1/|A(s)|$, $A(s)$ — число возможных действий в состоянии s

σ — *обратная чувствительность* (inverse sensitivity),

при $\sigma \to 0$ — чисто исследовательская стратегия

Инициализация: $\varepsilon_1(s) \equiv 1$ — чисто исследовательская стратегия

Michel Tokic. Adaptive ε-greedy exploration in reinforcement learning based on value differences // 33rd German conference on Advances in artificial intelligence. 2010. Pp. 203–210.

ε-жадные стратегии и softmax

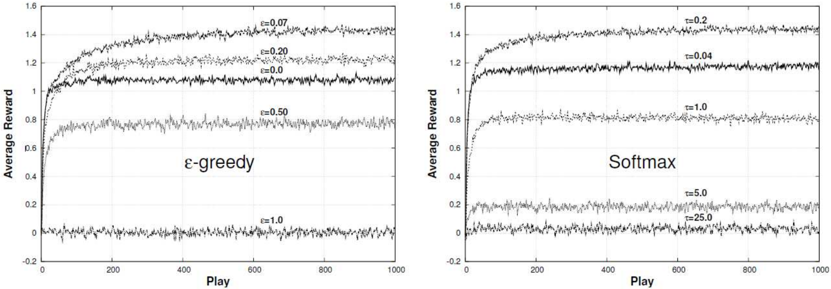

ε-жадные стратегии чувствительны к выбору параметра ε
стратегия softmax чувствительна к выбору температуры τ

Адаптивный ε-жадный метод VDBE

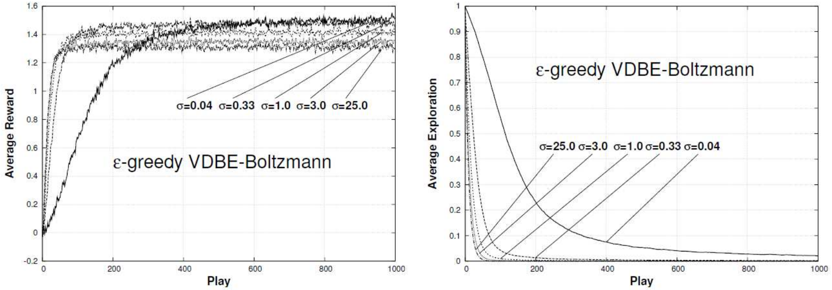

Метод VDBE (value differences based exploration)
— обгоняет ε-жадные стратегии и softmax;
— постепенно уменьшает долю исследований ε;
— может легко сочетаться с другими методами

Резюме в конце лекции

- В обучении с подкреплением нет ответов учителя, есть только ответная реакция среды
- Задача о многоруком бандите — это простой случай среды с одним состоянием
- Методы динамического программирования хорошо обоснованы, но требуют полного знания среды $\mathcal{P}^a_{ss'}$, $\mathcal{R}^a_{ss'}$
- Методы временны́х разностей лишь косвенно опираются на уравнения Беллмана (Q-метод) и основаны на оценках экспоненциальных скользящих средних