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)»

11 ноября 2015

Содержание

Задача о многоруком бандите (multi-armed bandit)

Имеется множество допустимых *действий* (ручек, arm),
с различными распределениями размера *премии* (reward, payoff).

Как быстрее найти самое выгодное действие?
Какие возможны стратегии?

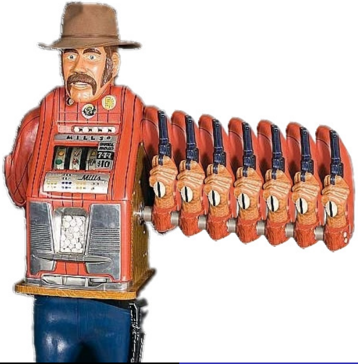

Задача о многоруком бандите

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

Игра агента со средой (multi-armed bandit):

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 $r_t \sim p(r|a_t)$;
5: агент корректирует стратегию $\pi_{t+1}(a)$;

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

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

Примеры прикладных задач

- Рекомендация новостных статей пользователям
- Показ рекламы в Интернете
- Управление технологическими процессами
- Управление роботами
- 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.)

Задача о многоруком бандите впервые рассмотрена в статье
H. Robbins. Some aspects of the sequential design of experiments. Bulletin of the American Mathematics Society, 58:527–535, 1952.

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:

$$\pi_t(a) = \frac{1}{|A_t|}[a \in A_t]$$

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

Компромисс «изучение–применение» (exploration–exploitation)
ε-*жадная стратегия*:

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

Эвристика: параметр ε уменьшать со временем.

Стратегия softmax (распределение Гиббса)

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

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

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 уменьшать со временем.

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

Метод UCB (upper confidence bound)

Выбор действия с максимальной верхней оценкой ценности:

$$A_t = \operatorname*{Arg\,max}_{a \in A} \left(Q_t(a) + \delta \sqrt{\frac{2 \ln t}{k_t(a)}} \right),$$

где $k_t(a) = \sum\limits_{i=1}^{t} [a_i = a]$, $\quad\delta$ — параметр exr/exp-компромисса.

Интерпретация:
чем меньше $k_t(a)$, тем менее исследована стратегия,
тем выше должна быть вероятность выбрать a;

чем больше δ, тем стратегия более исследовательская.

Эвристика: параметр δ уменьшать со временем.

P. Auer, N. Cesa-Bianchi, P. Fischer. Finite-time analysis of the multiarmed bandit problem, Machine Learning, 2002.

Модельные эксперименты в обучении с подкреплением

«10-рукая испытательная среда»:
Генерируется 2000 задач, в каждой задаче
$|A| = 10$,
$p(r|a) = \mathcal{N}(r; Q^*(a), 1)$,
$Q^*(a) \sim \mathcal{N}(0, 1)$.

Строятся графики зависимости
— средней премии (average reward),
— доли оптимальных действий (% optimal action),
от числа шагов t, 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

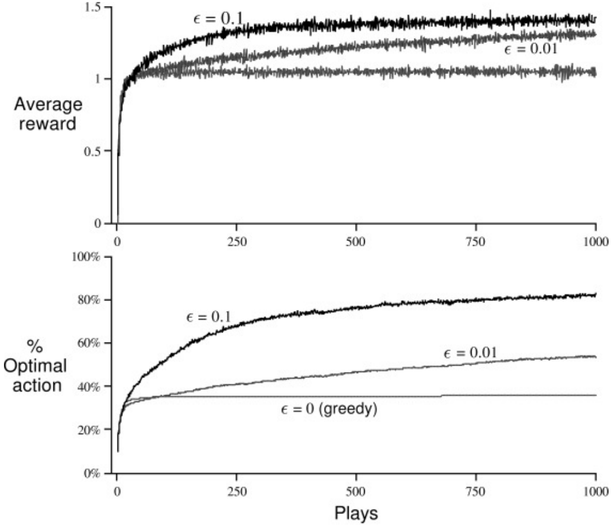

Рекуррентная формула для эффективного вычисления средних

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 $\alpha_t = \mathrm{const}$ 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* по всем действиям

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

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

Эвристика: оптимистично завышенное начальное $\bar{r}_0$ стимулирует изучающие действия в начале

Экспериментальный факт: сравнение с подкреплением сходится быстрее ε-жадных стратегий.

Сравнение с подкреплением лучше ε-жадных стратегий

Эксперимент с 10-рукой испытательной средой:

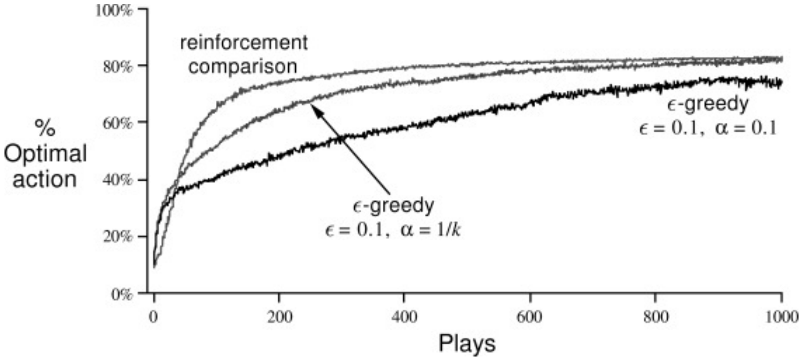

Richard Sutton, Andrew Barto. Reinforcement Learning: An Introduction. The MIT Press. 1998, 2004.
Р. Саттон, Э. Барто. Обучение с подкреплением. Изд-во «Бином». 2011.

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:

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

Эвристика: начальное $\pi_0(a)$ можно взять равномерным.

Экспериментальный факт: метод преследования, сравнение с подкреплением и ε-жадные стратегии имеют каждый свою область применения.

Стратегия преследования ещё лучше

Эксперимент с 10-рукой испытательной средой:

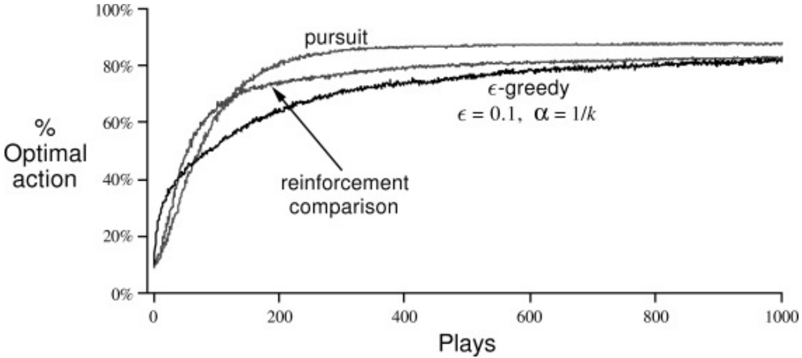

Richard Sutton, Andrew Barto. Reinforcement Learning: An Introduction. The MIT Press. 1998, 2004.
Р. Саттон, Э. Барто. Обучение с подкреплением. Изд-во «Бином». 2011.

Постановка задачи в случае, когда имеется информация о среде

A — множество возможных *действий*
X — пространство контекстов, описаний состояния среды
$x_{ta} \in X$ — состояние среды в раунде t в случае выбора $a \in A$
$p(r \mid a, x)$ — неизвестное распределение *премии* $r \in \mathbb{R}$ для $a \in A$
$\pi_t(a \mid x)$ — *стратегия* агента в момент t, распределение на A

Игра агента со средой (contextual bandit):

1: инициализация стратегии $\pi_1(a)$
2: **для всех** $t = 1, \dots T, \dots$
3: агенту сообщается контекст x_{ta} для всех $a \in A$;
4: агент выбирает действие $a_t \sim \pi_t(a \mid x_{ta})$;
5: среда генерирует премию $r_t \sim p(r \mid a_t, x_{ta})$;
6: агент корректирует стратегию $\pi_{t+1}(a \mid x)$;

Context-free bandit — когда $\pi_t(a \mid x) = \pi_t(a)$, т.е. не зависит от x

Регрессия с инкрементным обучением и доверительной оценкой

$r(a, x)$ — функция премии за действие a в контексте x,
$\hat{r}(a, x)$ — регрессионная оценка этой функции,
$UCB(a, x)$ — верхняя оценка отклонения $\hat{r} - r$,
δ — параметр (чем больше, тем больше exploration).

Игра агента со средой (contextual bandit):

1: инициализация стратегии $\pi_1(a)$
2: **для всех** $t = 1, \dots T, \dots$
3: агенту сообщается контекст x_{ta} для всех $a \in A$;
4: агент выбирает действие
$$a_t = \arg\max_{a \in A} \Big(\hat{r}(a, x_{ta}) + \delta\, UCB(a, x_{ta}) \Big);$$
5: среда генерирует премию $r_t = r(a_t, x_{ta_t})$;
6: регрессия $\hat{r}(a, x)$ дообучается на точке $(a_t, x_{ta_t}; r_t)$;

Пример. Рекомендация новостных статей пользователям

Агент — рекомендательная система для персонализации показов новостных статей (пользователям Yahoo! Today).

A — новостные статьи, действия системы;
$x_{ta} \in X$ — признаковое описание пары (u_t, a);
u_t — пользователь, которому агент даёт рекомендацию;
$r_t \in \{0, 1\}$ — пользователь u_t кликнул на предложенную статью;
$Q_t(a)$ — средняя премия, CTR (click-through rate) статьи.

Цель — повышение среднего CTR и «счастья пользователя».

Lihong Li, Wei Chu, John Langford, Robert E. Schapire. A contextual-bandit approach to personalized news article recommendation. WWW-2010.

Линейная модель премий и гребневая регрессия

Пусть $x_{ta} \in X = \mathbb{R}^n$, $w \in \mathbb{R}^n$.
Линейная модель премий для действия $a \in A$:

$$Q^*(a) = \mathsf{E}\bigl[r_t \,\big|\, x_{ta}\bigr] = \langle x_{ta}, w_a \rangle.$$

Гребневая регрессия: обучение w_a для действия a в момент t:

$$\sum_{i=1}^{t} \bigl[a_i = a\bigr] \bigl(\langle x_{ia}, w\rangle - r_i\bigr)^2 + \frac{\tau}{2}\|w\|^2 \;\to\; \min_w .$$

$w_a = \bigl(F_a^{\mathsf{T}} F_a + \tau I_n\bigr)^{-1} F_a^{\mathsf{T}} y_a$ — решение задачи МНК, где

$F_a = \bigl(x_{ia}\bigr)_{i=1:\ a_i=a}^{t}$ — $\ell \times n$-матрица объекты–признаки,

$y_a = \bigl(r_i\bigr)_{i=1:\ a_i=a}^{t}$ — $\ell \times 1$-вектор ответов,

$\ell = k_t(a) = \sum\limits_{i=1}^{t} [a_i = a]$ — объём обучающей выборки.

LinUCB: линейная модель с верхней доверительной оценкой

Доверительный интервал с коэффициентом доверия $1 - \alpha$ для линейной модели регрессии:

$$y = \langle x, w \rangle \pm \hat{\sigma} t_{\ell-n, 1-\frac{\alpha}{2}} \sqrt{x^{\mathsf{T}} (F^{\mathsf{T}} F)^{-1} x},$$

$t_{\ell-n, 1-\frac{\alpha}{2}}$ — квантиль распределения Стьюдента,
$\hat{\sigma}^2 = \frac{1}{\ell-n} RSS$ — оценка дисперсии отклика y.

Стратегия выбора действия с максимальной верхней оценкой ценности UCB (upper confidence bound):

$$A_t = \operatorname*{Arg\,max}_{a \in A} \left(\langle x_{ta}, w_a \rangle + \delta \sqrt{x_{ta}^{\mathsf{T}} \left(F_a^{\mathsf{T}} F_a + \tau I_n \right)^{-1} x_{ta}} \right).$$

Чем больше параметр δ, тем больше исследования.

LinUCB: особенности реализации и обобщения

- *Инкрементный алгоритм* пересчёта w_a и матрицы $(F_a^\intercal F_a + \tau I_n)^{-1}$ при добавлении каждой строки в F_a.
- Гибридная линейная модель $Q^*(a) = \langle z_{ta}, v\rangle + \langle x_{ta}, w_a\rangle$, где v — часть контекста, не зависящая от действия a.
- «Сырые признаки»:
  пользователи: 12 соцдем, 200 география, $\sim$1000 категорий,
  статьи: $\sim$100 категорий.
- Используется кластеризация и *понижение размерности*:
  $\dim w_a = 6, \;\; \dim v = 36.$
- Можно было бы использовать любую другую модель с инкрементным обучением и доверительными оценками.

Lihong Li, Wei Chu, John Langford, Robert E. Schapire. A contextual-bandit approach to personalized news article recommendation. WWW-2010.

Оценивание модели по историческим данным

Проблема off-line оценивания стратегии π:
исторические данные накоплены при использовании
другой стратегии (logging policy) $\pi_0(a)$, отличной от π

Идея:
для оценивания $Q_t(a)$ отбираются только те события (x_{ta}, a, r_t),
для которых стратегии π и π_0 выбирали одинаковое действие:

$$a = \arg\max_a \pi(a, x_{ta}) = \arg\max_a \pi_0(a)$$

(для этого нужны очень большие данные)

Утв. Если $\pi_0(a)$ — равномерное распределение,
то оценка $Q_t(a)$ по отобранной выборке является несмещённой.

Lihong Li, Wei Chu, John Langford, Robert E. Schapire. A contextual-bandit approach to personalized news article recommendation. WWW-2010.

Постановка задачи в случае, когда агент влияет на среду

A — множество возможных *действий*
S — множество состояний среды

Игра агента со средой:

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

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

$$\mathsf{P}\big(s_{t+1}, r_{t+1} \,\big|\, s_t, a_t, r_t,\ s_{t-1}, a_{t-1}, r_{t-1}, \dots, s_1, a_1\big) = \\ = \mathsf{P}\big(s_{t+1}, r_{t+1} \,\big|\, s_t, a_t\big)$$

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:

$$V^\pi(s) = \mathsf{E}_\pi(R_t \,|\, s_t = s) = \mathsf{E}_\pi\Biggl(\sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \Biggm| s_t = s\Biggr)$$

Функция ценности действия a *в состоянии* s при стратегии π:

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

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

Рекуррентные формулы для функций ценности

Рекуррентная формула для ценности состояния $V^\pi(s)$:

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

Рекуррентная формула для ценности действия $Q^\pi(s, a)$:

$$
\begin{aligned}
Q^\pi(s, a) &= \mathsf{E}_\pi\bigl(\textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+1} \bigm| s_t = s,\ a_t = a\bigr) = \\
&= \mathsf{E}_\pi\bigl(r_{t+1} + \gamma \textstyle\sum_{k=0}^\infty \gamma^k r_{t+k+2} \bigm| s_t = s,\ a_t = a\bigr) = \\
&= \mathsf{E}_\pi\bigl(r_{t+1} + \gamma Q^\pi(s_{t+1}, a_{t+1}) \bigm| s_t = s,\ a_t = a\bigr)
\end{aligned}
$$

Жадные стратегии максимизации ценности

$V^*(s)$, $Q^*(s,a)$ — оптимальные функции ценности.

Уравнения оптимальности Беллмана:

$$V^*(s) = \max_{a\in A} \mathsf{E}_\pi \bigl(r_{t+1} + \gamma V^*(s_{t+1}) \bigm| s_t = s,\ a_t = a\bigr)$$

$$Q^*(s,a) = \mathsf{E}_\pi \bigl(r_{t+1} + \gamma \max_{a'\in A} Q^*(s_{t+1}, a') \bigm| s_t = s,\ a_t = a\bigr)$$

Жадные стратегии π относительно $V^*(s)$ или $Q^*(s,a)$: выбирать то действие, на котором достигается максимум в уравнениях оптимальности Беллмана:

$$A_t = \operatorname*{Arg\,max}_{a\in A} \mathsf{E}_\pi \bigl(r_{t+1} + \gamma V^*(s_{t+1}) \bigm| s_t,\ a\bigr)$$

$$A_t = \operatorname*{Arg\,max}_{a\in A} Q^*(s_t, a)$$

Утв. Эти стратегии являются оптимальными.

Метод временных разностей TD(0)

Рекуррентная формула для ценности состояния $V^\pi(s)$:

$$V^\pi(s) = \mathsf{E}_\pi\bigl(r_{t+1} + \gamma V^\pi(s_{t+1}) \bigm| s_t = s\bigr)$$

Нужна эмпирическая оценка математического ожидания E_π.

Метод временных разностей TD (temporal difference)
После того, как выбрано a_t и стали известны r_{t+1}, s_{t+1}, оцениваем $V^\pi(s_t)$ 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 $V(s) \overset{\text{пн}}{\to} V^\pi(s)$, $t \to \infty$

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

Рекуррентная формула для ценности действия $Q^\pi(s,a)$:

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

Игра агента со средой:

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

$$Q^*(s,a) = \mathsf{E}_\pi\Bigl(r_{t+1} + \gamma \max_{a'} Q^*(s_{t+1},a') \Bigm| s_t = s,\ a_t = a\Bigr)$$

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

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

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

Отличия от SARSA: 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» $e(s)$ (eligibility traces)
будем корректировать $V(s)$ не только текущего s_t, но и недавно пройденных состояний, с коэффициентом затухания $\lambda \in [0, 1]$

Обновление $V(s)$ теперь не только для $s = s_t$:

1: $e(s_t) := e(s_t) + 1$;
2: **для всех** $s \in S$, $e(s) \neq 0$
3: $\quad V(s) := V(s) + e(s) \cdot \alpha_t \big(r_{t+1} + \gamma V(s_{t+1}) - V(s)\big)$;
4: $\quad e(s) := \gamma\lambda e(s)$;

Возможны варианты обновления следов приемлемости:
$e(s) := [s = s_t]$ — получаем метод TD(0)
$e(s) := \min\{\gamma\lambda e(s), 1\}$ — «заметающий след»
$e(s) := \big(e(s) < \varepsilon\big)\ ?\ 0 : e(s)$ — обнуление слишком старых следов

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

Методы SARSA(λ) и $Q(\lambda)$

Идея следов приемлемости легко переносится на метод SARSA:

Обновление $Q(s,a)$ теперь не только для $s = s_t$:

1: $e(s_t, a_t) := e(s_t, a_t) + 1;$
2: **для всех** $s \in S$, $a \in A$: $e(s,a) \neq 0$
3: $\quad Q(s,a) := Q(s,a) + e(s,a) \cdot \alpha_t \big(r_{t+1} + \gamma Q(s_{t+1}, a') - Q(s,a) \big);$
4: $\quad e(s,a) := \gamma \lambda e(s,a);$

... и на Q-обучение, если положить
$a' := \arg\max\limits_a Q(s_{t+1}, a);$

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

Резюме в конце лекции

- В обучении с подкреплением нет ответов учителя, есть только ответная реакция среды
- В контекстных бандитах используются модели машинного обучения, удовлетворяющие двум требованиям:
  - существует эффективный инкрементный метод обучения
  - существуют доверительные оценки средней премии $Q^t(a)$
- В марковских процессах принятия решений накапливается информация о ценности отдельных состояний и действий
- Компромисс «изучение–применение» при любом обучении с подкреплением подбирается экспериментальным путём
- Объём исследовательских действий приходится уменьшать в случае конечного горизонта игры