

- Прикладные модели машинного обучения •

## Обучение с подкреплением (Reinforcement Learning)

Воронцов Константин Вячеславович

k.v.vorontsov@phystech.edu

<http://www.MachineLearning.ru/wiki?title=User:Vokov>

Этот курс доступен на странице вики-ресурса

<http://www.MachineLearning.ru/wiki>

«Машинное обучение (курс лекций, К.В.Воронцов)»

## 1 Задача о многоруком бандите

- Простая постановка задачи
- Жадные и полужадные стратегии
- Адаптивные стратегии

## 2 Среда с состояниями

- Постановка задачи
- Метод Q-обучения
- Параметризация стратегий и функций ценности

## 3 Моделирование среды

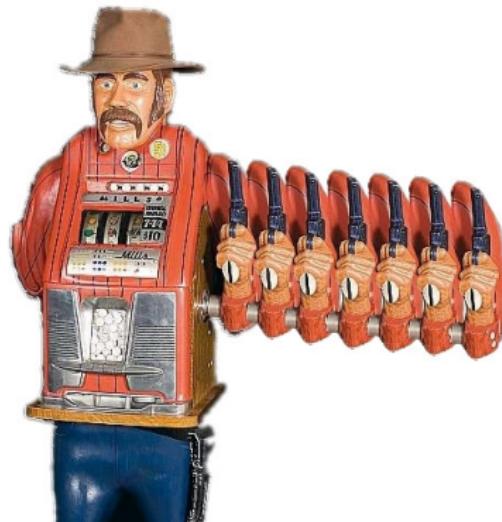
- Контекстный бандит и томпсоновское сэмплирование
- Линейная регрессионная модель премии
- Оценивание модели по историческим данным

## 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 (multi-armed bandit)

$A$  — конечное множество возможных действий

$p(r|a)$  — неизвестное распределение премии  $r \in \mathbb{R}$  для  $a \in A$

$\pi_t(a)$  — стратегия (policy) агента в раунде  $t$ , распределение на  $A$

Игра агента со средой:

инициализация стратегии  $\pi_1(a)$ ;

для всех раундов  $t = 1, \dots, T, \dots$

агент выбирает действие  $a_t \sim \pi_t(a)$ ;

среда генерирует премию  $r_t \sim p(r|a_t)$ ;

агент корректирует стратегию  $\pi_{t+1}(a)$ ;

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

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

## Примеры прикладных задач

- Управление роботами, технологическими процессами
- Генерация движений персонажей в мультипликации
- Рекомендация новостных статей пользователям
- Показ рекламы в Интернете
- Управление портфелем ценных бумаг, игра на бирже
- Управление ценами и ассортиментом в сетях продаж
- Маршрутизация в телекоммуникационных сетях
- Стратегические игры: шахматы, го, Dota2, StarCraft2, ...

Обобщения постановки задачи:

- Есть информация о состоянии среды или о контексте
- Есть параметрическая модель стратегии/ценности/среды

---

H. Robbins. Some aspects of the sequential design of experiments. 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  $A_t$ :

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

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

Компромисс «изучение–применение» (exploration–exploitation)  
 $\varepsilon$ -жадная стратегия:

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

Эвристика: параметр  $\varepsilon$  уменьшать со временем.

## Метод UCB (upper confidence bound)

Выбор действия с максимальной верхней оценкой ценности:

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

где  $k_t(a) = \sum_{i=1}^t [a_i = a]$ ,  $\varepsilon$  — параметр exr/ext-компромисса.

**Интерпретация:**

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

чем больше  $\varepsilon$ , тем стратегия более исследовательская.

**Эвристика:** параметр  $\varepsilon$  уменьшать со временем.

---

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

## Напоминание. Экспоненциальное скользящее среднее

Рекуррентная формула Moving Average для усреднения  $Q_t$ :

$$\begin{aligned} Q_t(a) &= \alpha \cdot (r_t) + (1 - \alpha) \cdot Q_{t-1}(a) \\ &= \text{EMA}_\alpha(r_t) \end{aligned}$$

При  $\alpha = \text{const}$  это экспоненциальное скользящее среднее (EMA)

При  $\alpha = \frac{1}{k_t(a)}$  это среднее арифметическое

Является приближённым рекуррентным решением задачи прогнозирования временного ряда  $r_0, \dots, r_t, \dots$ :

- простейшая регрессионная модель — константа  $\hat{r}_{t+1} = C$ ,
- наблюдения учитываются с весами, убывающими в прошлое,
- авторегрессия, метод наименьших квадратов:

$$\hat{r}_{t+1} = \arg \min_C \sum_{i=0}^t \beta^{t-i} (r_i - C)^2, \quad \beta \in (0, 1)$$

## Использование EMA для конструирования стратегий

Метод преследования (pursuit) жадной стратегии:

$$\pi_{t+1}(a) = \text{EMA}_{\alpha} \left( \frac{[a \in A_t]}{|A_t|} \right), \quad a \in A$$

Сравнение с подкреплением (reinforcement comparison):

$\bar{r}_t = \text{EMA}_{\alpha}(r_t)$  — средняя премия по всем действиям,

$p_t(a_t) = \text{EMA}_{\beta}(r_t - \bar{r}_t)$  — преимущество (advantage) действия,

$$\pi_{t+1}(a) = \frac{\exp(\frac{1}{\tau} p_t(a))}{\sum_{a'} \exp(\frac{1}{\tau} p_t(a'))},$$

при  $\tau \rightarrow 0$  стратегия стремится к жадной,

при  $\tau \rightarrow \infty$  — к равномерной, т.е. чисто исследовательской.

**Экспериментальный факт:**

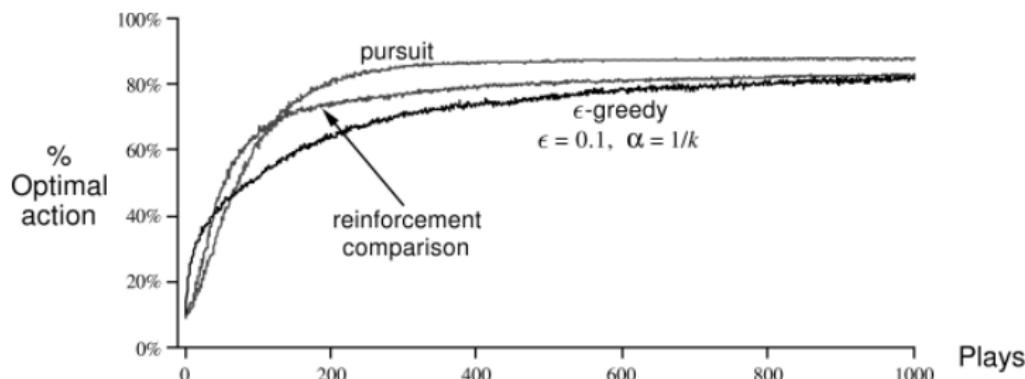
не существует метода, универсально лучшего для всех задач

## Сравнение стратегий в имитационных экспериментах

10-рукая испытательная среда. Генерируется 2000 задач:

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

Зависимость доли оптимальных действий (% optimal action) от числа шагов  $t$ , усреднённая по 2000 синтетическим задачам



Richard Sutton, Andrew Barto. Reinforcement Learning: An Introduction.

The MIT Press. 1998, 2004, 2018

R. Саттон, Э. Барто. Обучение с подкреплением. 2011, 2020

## Постановка задачи в случае, когда агент влияет на среду

$A$  — конечное множество возможных действий (action)

$S$  — конечное множество состояний среды (state)

### Игра агента со средой:

инициализация стратегии  $\pi_1(a | s)$  и состояния среды  $s_1$ ;

для всех раундов  $t = 1, \dots, T, \dots$

    агент выбирает действие  $a_t \sim \pi_t(a | s_t)$ ;

    среда генерирует премию  $r_t \sim p(r | a_t, s_t)$

    и новое состояние  $s_{t+1} \sim p(s | a_t, s_t)$ ;

    агент корректирует стратегию  $\pi_{t+1}(a | s)$ ;

### Марковский процесс принятия решений (МППР, MDP):

$$\begin{aligned} P(s_{t+1}, r_t | s_t, a_t, r_{t-1}, s_{t-1}, a_{t-1}, r_{t-2}, \dots, s_1, a_1) &= \\ &= P(s_{t+1}, r_t | s_t, a_t) \end{aligned}$$

## Понятия выгода и ценности действия

*Суммарная выгода (return) на конечном горизонте  $T$ :*

$$R_t = r_t + r_{t+1} + \cdots + r_{t+T}$$

*Дисконтированная выгода (discounted return):*

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

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

$1 + \gamma + \gamma^2 + \cdots = \frac{1}{1-\gamma}$  — горизонт дальновидности агента.

*Функции ценности состояния  $V^\pi(s)$  и ценности действия в состоянии  $Q^\pi(s, a)$  при условии, что агент следует стратегии  $\pi$ :*

$$V^\pi(s) = E_\pi(R_t \mid s_t = s) = E_\pi\left(\sum_{k=0}^{\infty} \gamma^k r_{t+k} \mid s_t = s\right)$$

$$Q^\pi(s, a) = E_\pi(R_t \mid s_t = s, a_t = a) = E_\pi\left(\sum_{k=0}^{\infty} \gamma^k r_{t+k} \mid s_t = s, a_t = a\right)$$

## Жадные стратегии максимизации ценности

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

$$\begin{aligned} Q^\pi(s, a) &= E_\pi \left( \sum_{k=0}^{\infty} \gamma^k r_{t+k} \mid s_t = s, a_t = a \right) \\ &= E_\pi \left( r_t + \gamma \sum_{k=0}^{\infty} \gamma^k r_{t+k+1} \mid s_t = s, a_t = a \right) \\ &= E_\pi \left( r_t + \gamma Q^\pi(s_{t+1}, a_{t+1}) \mid s_t = s, a_t = a \right) \end{aligned}$$

Уравнение Беллмана для оптимальной функции ценности  $Q^*$ :

$$Q^*(s, a) = E_\pi \left( r_t + \gamma \max_{a' \in A} Q^*(s_{t+1}, a') \mid s_t = s, a_t = a \right)$$

**Утв.** Жадная стратегия «выбирать то действие, на котором достигается максимум в уравнениях Беллмана» оптимальна:

$$\pi_{t+1}(a) = \frac{1}{|A_t|} [a \in A_t], \quad A_t = \operatorname{Arg} \max_{a \in A} Q^*(s_t, a)$$

## Метод Q-обучения

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

$$Q(s_t, a_t) = \text{EMA}_\alpha(r_t + \gamma \max_a Q(s_{t+1}, a))$$

инициализация стратегии  $\pi_1(a | s)$  и состояния среды  $s_1$ ;  
**для всех** раундов  $t = 1, \dots, T, \dots$

агент выбирает действие  $a_t \sim \pi_t(a | s_t)$ ;

среда генерирует  $r_t \sim p(r | a_t, s_t)$  и  $s_{t+1} \sim p(s | a_t, s_t)$ ;

$$Q(s_t, a_t) := \alpha(r_t + \gamma \max_a Q(s_{t+1}, a)) + (1 - \alpha)Q(s_t, a_t);$$

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

Возможны два способа выбора действий:

- **on-policy:**  $a_t \sim \pi_t(a | s_t) \Leftrightarrow a_t \in \text{Arg} \max_a Q(s_t, a)$

- **off-policy:**  $a_t \sim \pi_t(a | s_t)$  — другая стратегия на основе  $Q$

## Отличия от обычных задач машинного обучения

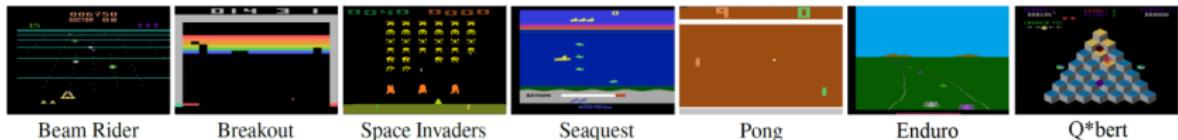
- выборка  $(s_t, a_t, r_t)$  не является независимой
- распределение  $p(s_t, a_t, r_t)$  может меняться во времени и зависеть от стратегии агента  $\pi$
- премии могут быть
  - отложенными (оценивать действия с задержкой)
  - разреженными (почти всё время  $r_t = 0$ )
  - зашумлёнными (не ясно, за что именно премия)

Какие параметрические модели можно обучать:

- функцию ценности действия в состоянии  $Q(s, a; \theta)$
- функцию ценности состояния  $V(s; \theta)$
- стратегию  $\pi_{t+1}(a|s; \theta)$
- модель среды  $(r_t, s_{t+1}) = \mu(s_t, a_t; \theta)$

## Q-параметризация на примере обучения играм Atari

Среда — эмулятор 7 игр Atari, каждый кадр  $210 \times 160 \text{pix}$   $128\text{col}$

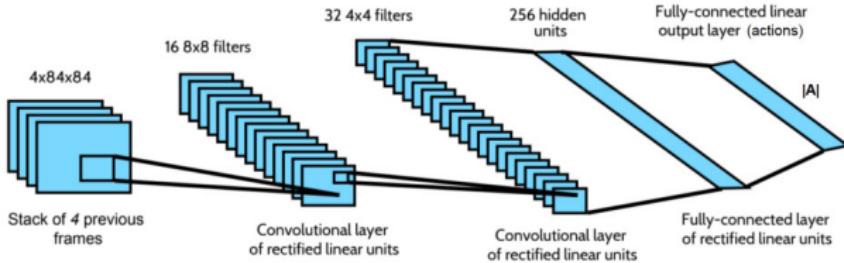


Состояния  $s$  — 4 последовательных кадра, сжатых до  $84 \times 84$

Действия  $a$  — от 4 до 18, в зависимости от игры

Премии  $r$  — текущий SCORE согласно правилам игры

Функция ценности  $Q(s, a; w)$  — CNN со входом  $s$  и  $|A|$  выходами



V.Mnih et al. (DeepMind). Playing Atari with deep reinforcement learning. 2013

## Метод DQN (Deep Q-Learning Network)

Сохранение траекторий  $(s_t, a_t, r_t)_{t=1}^T$  в памяти (reply memory) для многократного воспроизведения опыта (experience replay)

Аппроксимация оптимальной функции ценности  $Q(s_t, a_t)$  при фиксированных текущих параметрах сети  $w_t$ :

$$y_t = \begin{cases} r_t, & \text{если состояние } s_{t+1} \text{ терминальное} \\ r_t + \gamma \max_a Q(s_{t+1}, a; w_t), & \text{иначе} \end{cases}$$

Функция потерь для обучения нейросетевой модели  $Q(s, a; w)$ :

$$\mathcal{L}_t(w) = (Q(s_t, a_t; w) - y_t)^2$$

Стохастический градиент SGD (по мини-батчам длины 32):

$$w_{t+1} = w_t - \eta(Q(s_t, a_t; w_t) - y_t) \nabla_w Q(s_t, a_t; w_t)$$

## Метод DQN: собираем всё воедино

инициализация reply-памяти и параметров сети  $w$ ;

**для всех** эпизодов  $m = 1, \dots, M$

инициализация состояния среды  $s_1$ ;

**для всех**  $t = 1, \dots, T_m$  (длина  $m$ -го эпизода)

$$a_t = \begin{cases} \text{случайное действие,} & \text{с вероятностью } \varepsilon; \\ \arg \max_a Q(s_t, a, w), & \text{с вероятностью } 1 - \varepsilon; \end{cases}$$

среда генерирует  $r_t \sim p(r | a_t, s_t)$  и  $s_{t+1} \sim p(s | a_t, s_t)$ ;  
запомнить  $(s_t, a_t, r_t)$  в reply-памяти;

выбрать случайный фрагмент траектории из памяти;

**для всех**  $j = 1, \dots, J$  (длина мини-батчей)

оценить  $y_j$ ;

сделать градиентный шаг, обновить  $w$ ;

## Градиентная оптимизация стратегии (policy gradient)

$\pi(a|s, \theta)$  — стратегия агента с параметром  $\theta$

$F(s_t, a_t)$  — функция ценности или её оценка (например,  $R_t$ )

**Задача** максимизации  $E_{\pi} F$  по вектору параметров стратегии  $\theta$ :

$$E_{\pi} F(s, a) \equiv E_{a \sim \pi(a|s, \theta)} F(s, a) \rightarrow \max_{\theta}$$

**Градиентный метод:**  $\theta^{(t+1)} := \theta^{(t)} + \eta \nabla_{\theta} E_{a \sim \pi} F(s, a)$

$$\begin{aligned} \nabla_{\theta} E_{a \sim \pi} F(s, a) &= \nabla_{\theta} \sum_{a \in A} F(s, a) \pi(a|s, \theta) = \sum_{a \in A} F(s, a) \nabla_{\theta} \pi(a|s, \theta) = \\ &= \sum_{a \in A} F(s, a) \pi(a|s, \theta) \frac{\nabla_{\theta} \pi(a|s, \theta)}{\pi(a|s, \theta)} = \\ &= E_{a \sim \pi} [F(s, a) \nabla_{\theta} \ln \pi(a|s, \theta)] \end{aligned}$$

---

R.Sutton et al. Policy gradient methods for reinforcement learning with function approximation. NIPS 1999.

## Градиентная оптимизация стратегии (policy gradient)

Замена  $E_\pi$  эмпирической оценкой EMA градиента:

$$\theta^{(t+1)} := \theta^{(t)} + \eta \text{EMA}_\alpha(F(s_t, a_t) \nabla_\theta \ln \pi(a_t | s_t, \theta^{(t)}))$$

Фактически, это стохастический градиент SGD с методом инерции Б.Т.Поляка для максимизации log-правдоподобия:

$$\sum_t F(s_t, a_t) \ln \pi(a_t | s_t, \theta) \rightarrow \max_{\theta}$$

Основные отличия от максимизации log-правдоподобия:

- вместо предсказания меток классов  $y_t$  — действия  $a_t$
- вместо бинарных  $y_t$  — вещественные  $F(s_t, a_t)$

Что можно использовать в качестве  $F(s_t, a_t)$ :

- функцию *выгоды*  $R_t$ ,
- функцию *ценности*  $Q(s_t, a_t)$ ,
- функцию *преимущества* (advantage)  $Q(s_t, a_t) - V(s_t)$

## Алгоритм REINFORCE

$F(s_t, a_t) = R_t$  — выгода, становится известна в конце эпизода

инициализация стратегии  $\pi_1(a | s)$  и состояния среды  $s_1$ ;

**для всех** эпизодов  $m = 1, \dots, M$

**для всех** раундов  $t = 1, \dots, T_m$

агент выбирает действие  $a_t \sim \pi_t(a | s_t, \theta)$ ;

среда генерирует  $r_t \sim p(r | a_t, s_t)$  и  $s_{t+1} \sim p(s | a_t, s_t)$ ;

$\theta := \theta + \eta \sum_{t=1}^{T_m} \textcolor{red}{R_t} \nabla_\theta \ln \pi(a_t | s_t, \theta);$

Преимущество policy gradient и алгоритма REINFORCE:

- легко обобщается на задачи с непрерывным множеством  $A$

Недостаток:

- медленная сходимость, надо дожидаться конца эпизода

## Алгоритм «Актёр–Критик» (Advantage Actor–Critic, A2C)

- Актёр корректирует стратегию под воздействием Критика
- Вместо  $R_t$  используем преимущество  $A_t = Q(s_t, a_t) - V(s_t)$  (уменьшается дисперсия, улучшается сходимость)
- Из уравнения Беллмана:  $Q(s_t, a_t) \approx \mathbb{E}_\pi(r_t + \gamma V(s_{t+1}))$
- Параметр  $\theta$  обновляется на каждом шаге

инициализация стратегии  $\pi_1(a | s)$  и состояния среды  $s_1$ ;

для всех эпизодов  $m = 1, \dots, M$ , раундов  $t = 1, \dots, T_m$

агент выбирает действие  $a_t \sim \pi_t(a | s_t, \theta)$ ;

среда генерирует  $r_t \sim p(r | a_t, s_t)$  и  $s_{t+1} \sim p(s | a_t, s_t)$ ;

$V(s_t) := EMA_\beta(r_t + \gamma V(s_{t+1}))$ ;

$A_t := r_t + \gamma V(s_{t+1}) - V(s_t)$ ;

$\theta := \theta + \eta EMA_\alpha(A_t \nabla_\theta \ln \pi(a_t | s_t, \theta))$ ;

Следующий шаг: параметризовать оценку преимущества  $A_t$

## Алгоритм «Актёр–Критик» с двойной параметризацией

$\pi(a | s, \theta)$  — стратегия агента (*Актёра*) с параметром  $\theta$

$A(s_t, a_t; w)$  — модель преимущества с параметром  $w$ , делает Критику дальновиднее в средах с большим или сложным  $S$ :

$$\sum_t (A(s_t, a_t; w) - \mathcal{A}_t)^2 \rightarrow \min_w$$

инициализация стратегии  $\pi_1(a | s)$  и состояния среды  $s_1$ ;

для всех эпизодов  $m = 1, \dots, M$

для всех раундов  $t = 1, \dots, T_m$

агент выбирает действие  $a_t \sim \pi_t(a | s_t, \theta)$ ;

среда генерирует  $r_t \sim p(r | a_t, s_t)$  и  $s_{t+1} \sim p(s | a_t, s_t)$ ;

$\theta := \theta + \eta EMA_\alpha(A(s_t, a_t; w) \nabla_\theta \ln \pi(a_t | s_t, \theta))$ ;

$\mathcal{A}_t = Q(s_t, a_t) - V(s_t)$  для всех  $t = 1, \dots, T_m$ ;

$w := w - \eta_2 \sum_{t=1}^{T_m} (A(s_t, a_t; w) - \mathcal{A}_t) \nabla_w A(s_t, a_t; w_t)$ ;

## Моделирование среды в обучении с подкреплением

Отличие Model-Based подходов от Model-Free:

- моделируется поведение среды  $(r_t, s_{t+1}) = \mu(s_t, a_t; w)$
- возможно долгосрочное планирование действий
- возможна непрерывная параметризация как  $A$ , так и  $S$
- в несложных технических системах управления адекватная параметрическая модель среды может быть известна

Трудность задачи:

- сложные среды требуют больших выборок для обучения моделей большой размерности
- RL может хорошо функционировать в смоделированной среде, и гораздо хуже — в настоящей

## Томпсоновское сэмплирование (Thompson sampling)

$x_{ta} \in \mathbb{R}^n$  — контекст, вектор признаков действия  $a \in A$  на шаге  $t$

$x_{ta}$  содержит также информацию о текущем состоянии среды

$p(r_t|x, w)$  — вероятностная модель премии,  $w \in \mathbb{R}^n$

### Игра агента и среды:

инициализация априорного распределения  $p_1(w)$ ;

для всех раундов  $t = 1, \dots, T$

среда сообщает агенту контексты  $x_{ta}$  для всех  $a \in A$ ;

агент сэмплирует вектор модели премии  $w_t \sim p_t(w)$ ;

агент выбирает действие  $a_t = \arg \max_{a \in A} \langle x_{ta}, w_t \rangle$ ;

среда генерирует премию  $r_t$ ;

агент корректирует распределение по формуле Байеса:

$p_{t+1}(w) \propto p(r_t|x_{tat}, w) p_t(w)$ ;

## Томпсоновское сэмплирование с гауссовскими распределениями

$$p(r|x, w) = \mathcal{N}(r; \langle x, w \rangle, \sigma^2), \quad p(w_t) = \mathcal{N}(w_t; w, \sigma^2 B^{-1})$$

### Игра агента и среды (contextual bandit with linear payoff)

инициализация:  $B = I_{n \times n}$ ;  $w = 0_n$ ;  $f = 0_n$ ;

для всех раундов  $t = 1, \dots, T$

среда сообщает агенту контексты  $x_{ta}$  для всех  $a \in A$ ;

агент сэмплирует вектор линейной модели премии

$$w_t \sim \mathcal{N}(w, \sigma^2 B^{-1});$$

агент выбирает действие  $a_t = \arg \max_{a \in A} \langle x_{ta}, w_t \rangle$ ;

среда генерирует премию  $r_t$ ;

агент корректирует параметры распределения:

$$B := B + x_{ta_t} x_{ta_t}^\top; \quad f := f + x_{ta_t} r_t; \quad w := B^{-1} f;$$

## Регрессия с инкрементным обучением и доверительной оценкой

$\hat{r}(s, a; w)$  — регрессионная модель премии с параметром  $w$

$UCB(s, a)$  — верхняя оценка отклонения  $\hat{r} - r$

$\delta$  — параметр (чем больше, тем больше exploration)

стратегия — максимизировать оценку премии за  $a_t$  в  $s_t$

### Игра агента со средой:

инициализация параметров  $w$  модели премии;

для всех раундов  $t = 1, \dots, T, \dots$

агент выбирает действие

$$a_t = \arg \max_{a \in A} \left( \hat{r}(s_t, a; w) + \delta UCB(s_t, a) \right);$$

среда генерирует  $r_t \sim p(r | a_t, s_t)$  и  $s_{t+1} \sim p(s | a_t, s_t)$ ;

регрессия  $\hat{r}(s, a; w)$  дообучается на точке  $(s_t, a_t, r_t)$ ;

---

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

## Пример. Рекомендация новостных статей пользователям



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

F1..F4 — позиции для показа заголовков новостей.

$A$  — новостные статьи, действия системы

$s_t$  — состояние = пользователь, которому даём рекомендацию

$x_{ta} \in \mathbb{R}^n$  — признаковое описание пары  $(s_t, a)$

$r_{ta} \in \{0, 1\}$  — премия = [пользователь  $s_t$  кликнул на статью  $a$ ]

$Q_t(a)$  — 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  $x_{ta} \in \mathbb{R}^n$ ,  $w_a \in \mathbb{R}^n$ .

Линейная модель премий для действия  $a \in A$  в состоянии  $s_t$ :

$$\mathbb{E}[r_{ta} | x_{ta}] = \langle x_{ta}, w_a \rangle.$$

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

$$\sum_{i=1}^t [a_i = a] (\langle x_{ia}, w_a \rangle - r_{ia})^2 + \frac{\tau}{2} \|w_a\|^2 \rightarrow \min_{w_a}.$$

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

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

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

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

## LinUCB: линейная модель с верхней доверительной оценкой

Доверительный интервал с коэффициентом доверия  $1 - \alpha$  для линейной модели регрессии  $w$ :  $\|Fw - y\| \rightarrow \min_w$ :

$$y = \langle x, w \rangle \pm \hat{\sigma} Z_\alpha \sqrt{x^\top (F^\top F)^{-1} x},$$

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

Стратегия  $\pi_t(a, x) = \frac{1}{|A_t|}[a \in A_t]$  — действие с максимальной верхней оценкой ценности UCB (upper confidence bound):

$$A_t = \operatorname{Arg} \max_{a \in A} \left( \langle x_{ta}, w_a \rangle + \delta \hat{\sigma} Z_\alpha \sqrt{x_{ta}^\top (F_a^\top F_a + \tau I_n)^{-1} x_{ta}} \right).$$

Чем больше параметр  $\delta$ , тем больше исследования.

## LinUCB: особенности реализации и обобщения

- Инкрементный алгоритм пересчёта  $w_a$  и матрицы  $(F_a^T F_a + \tau I_n)^{-1}$  при добавлении каждой строки в  $F_a$ .
- Гибридная линейная модель  $Q^*(a) = \langle \tilde{x}_t, v \rangle + \langle x_{ta}, w_a \rangle$ , где  $\tilde{x}_t$  — 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  $\pi$ :**  
исторические данные накоплены при использовании  
другой стратегии (logging policy)  $\pi_0(a)$ , отличной от  $\pi$

**Идея:**

для оценивания  $Q_t(a)$  отбираются только те события  $(x_{ta}, a, r_{ta})$ ,  
для которых стратегии  $\pi$  и  $\pi_0$  выбирали одинаковое действие:

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

(нужны очень большие данные или сходство стратегий)

**Утв.** Если  $\pi_0(a)$  — равномерное распределение, то  
оценка  $Q_t(a)$  по отобранный выборке является несмешённой.

---

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

- В обучении с подкреплением нет ответов учителя, есть только ответная реакция среды
- Что можно обучать в Model-Free подходах:
  - функцию ценности  $Q(s, a; w)$ , например, методом SGD
  - стратегию  $\pi(a|s; w)$ , методом Policy Gradient
  - модели актора  $a(s; w_1)$  и критика  $Q(s, a; w_2)$
- Что можно обучать в Model-Based подходах:
  - только модель премии  $r(s, a; w)$
  - модель среды  $(r_t, s_{t+1}) = \mu(s_t, a_t; w)$
- Компромисс «изучение–применение» при любом обучении с подкреплением подбирается экспериментальным путём