



# > Конспект > 8 урок > Многорукие бандиты и обучение с подкреплением

## > Оглавление

- > [Оглавление](#)
- > [Проблема эксплуатации динамического ценообразования](#)
  - Представим, что:
  - Нюансы:
- > [Многорукие бандиты](#)
- > [Байесовские многорукие бандиты](#)
  - Обозначения:
  - Идея:
  - Что даёт байесовский подход:
- > [Пример с монетками](#)
- > [Алгоритм семплирования Томпсона](#)
  - Идея алгоритма:
- > [Контекстуальные бандиты](#)
  - Дано:
  - Задача:
  - Решение:
- > [Семплирование Томпсона для линейной модели](#)
  - Алгоритм:
- > [Резюме](#)
- > [Дополнительные материалы](#)

## > Проблема эксплуатации динамического ценообразования

**Представим, что:**

1. Были созданы **две модели** динамического ценообразования.
2. Трафик был поделён между ними **пополам**.
3. Первая модель работает лучше (**допустим**).

**Предположение:** вывести в эксплуатацию первую модель.

**Нюансы:**

1. Трафик делили поровну: на модели, работающей хуже, **теряем деньги**, следовательно, хотим увеличивать долю трафика хорошей модели.
2. **Возможно, вторая модель может работать лучше**, если подавать ей на вход определённых покупателей в определённый период времени.

Сформулируем **проблему**:

Какую модель предсказания цены выбрать, чтобы увеличить средний доход компании, при условии, что мы не знаем точного дохода для каждой модели в определённый период времени?

Возможное решение:

А/Б тесты, но мы **будем терять прибыль** на неэффективной модели во время теста.

**Лучшее решение:**

С помощью **многоруких бандитов** выбирать модель и работать напрямую с бизнес-метрикой.

## > Многорукие бандиты

**Проблемы:**

1. N "бандитов" с неизвестным значением среднего выигрыша.
2. Какую машину/ручку выбрать в каждый момент времени?
3. Exploration/Exploitation tradeoff.

Популярные частотные подходы:

1.  $\epsilon$ -жадный алгоритм ([красивые графики](#), [формальный алгоритм](#));
2. Upper confidence bound (UCB) ([доп. источник](#)).

## > Байесовские многорукие бандиты

### Обозначения:

$r^a$  — случайная величина [вознаграждения](#) (*reward*) за [действие](#) (*action*)  $a$

$Pr_{r^a}(\theta)$  — неизвестное [распределение](#) вознаграждения ( $\theta$  — параметр).

$R(a) = E(r^a)$  — неизвестное [среднее](#) вознаграждение.

### Идея:

Выразить неопределенность относительно параметра  $\theta$  за счёт априорного представления распределения  $Pr(\theta)$ .

Затем посчитать апостериорное распределение  $Pr(\theta|r_1^a, r_2^a, \dots r_n^a)$  за счёт наблюдаемых  $r_1^a, r_2^a, \dots r_n^a$  в ответ на действие  $a$ . Для этого будем использовать [теорему Байеса](#):

$$Pr(\theta|r_1^a, r_2^a, \dots r_n^a) \propto Pr(\theta) \cdot Pr(r_1^a, r_2^a, \dots r_n^a|\theta)$$

### Что даёт байесовский подход:

Апостериорное распределение  $\theta$  позволяет рассчитать:

- Распределение вокруг следующего значения вознаграждения  $r^a$
- Распределение вокруг  $R(a)$  при условии, что  $\theta$  имеет некоторое среднее.

С точки зрения проведения экспериментов и поиска оптимальной стратегии, байесовский подход дает  $Pr(R(a)|r_1^a, r_2^a, \dots r_n^a)$ .

## > Пример с монетками

Даны две несимметричные монетки  $C_1$  и  $C_2$ .

$$R(C_1) = Pr(C_1 = head)$$

$$R(C_2) = Pr(C_2 = head)$$

**Задача:** максимизировать количество "орлов" за  $k$  бросков.

Нужно решить, какую монетку выбрать.

Так как  $r^{C_1}$  и  $r^{C_2}$  изменяются в пределах  $[0, 1]$ , то:

$$Pr(r^{C_1}|\theta_1) = \theta_1 = R(C_1)$$

$$Pr(r^{C_2}|\theta_2) = \theta_2 = R(C_2)$$

так как распределение Бернулли параметризовано относительно среднего.

Для упрощения давайте рассмотрим Бета-распределение в качестве априорного  $Pr(\theta) = Beta(\alpha, \beta)$ .

Для нас очень полезным будет тот факт, что Бета-распределение является сопряжённым к распределению Бернулли, что означает, что после применения теоремы Байеса апостериорное распределение будет также Бета-распределением, но уже с изменёнными параметрами.

Априорное распределение будет выглядеть так:

$$Pr(\theta) = Beta(\theta|\alpha, \beta) \propto \theta^{\alpha-1}(1-\theta)^{\beta-1}, \text{ где}$$


$\alpha - 1$  — количество выпавших "орлов"

$\beta - 1$  — количество выпавших "решек"

После очередного броска обновляем априорное распределение, получая апостериорное:

$$Pr(\theta|C = head) = Beta(\theta|\alpha + 1, \beta)$$

$$Pr(\theta|C = tail) = Beta(\theta|\alpha, \beta + 1)$$



При продолжительном обновлении параметров ( $\alpha = 20, \beta = 80$ ) видим, что пик распределения приходится на  $\theta = 0.2$

## > Алгоритм семплирования Томпсона

### Идея алгоритма:

1. Возьмём подвыборку средних вознаграждений для действия  $a$ :

$$R_1(a), \dots, R_k(a)$$

$R_j(a) \sim Pr(R_j(a)|r_1^a, r_2^a, \dots, r_n^a)$ , где  $n$  — количество вознаграждений, которое мы получили при  $a$

$$r_i^a \sim Pr(r^a|\theta)$$

2. Рассчитаем среднее по подвыборке:  $\hat{R}(a) = \frac{1}{k} \sum_{i=1}^k R_i(a)$ , где  $k$  — количество сэмплов

3. Найдём такое  $a^*$ , где  $\hat{R}(a^*)$  максимально:  $a^* = \arg \max_a \hat{R}(a)$

4. Выполним  $a^*$  и получим  $r'$

5. Обновим  $Pr(R(a^*))$  на основе  $r'$


6. Повторим для горизонта наблюдений

Чем больше  $n$ , тем уже полученное распределение.

Чем больше  $k$ , тем более точная оценка среднего  $\hat{R}(a)$ .

## > Контекстуальные бандиты

**Состояние** (*state*) — описание среды, которую использует агент.



В нашем случае среда состоит из множества бандитов, каждый из которых имеет несколько рук.

Состояние окружающей среды говорит, с каким бандитом мы взаимодействуем.

**Цель** — научиться выбирать руку, дающую наибольшее вознаграждение, для любого бандита. Агенту нужно будет научиться **обусловливать свои действия состоянием окружающей среды**. Если этого не сделать, со временем не будет достигнута максимально возможная награда.

**Дано:**

- $x^s = (x_1^s, x_2^s, \dots, x_n^s)$  — вектор, определяющий пространство шагов
- $x^a = (x_1^a, x_2^a, \dots, x_m^a)$  — вектор, определяющий пространство действий
- пространство вознаграждений

**Задача:**

Найти такое преобразование  $x^s \rightarrow a$ , которое максимизирует ожидаемое вознаграждение  $E(r|s, a) = E(r|x^s, x^a)$ .

**Решение:**

Найти **приближение средней** функции вознаграждения  $\tilde{R}(s, a) = \tilde{R}(x^s, x^a)$

**Подходы:**

- $\tilde{R}_w(x) = w^T x$  — линейный
- $\tilde{R}_w(x) = \text{neuralNet}(x, w)$  — нелинейный

## > Семплирование Томпсона для линейной модели

**Алгоритм:**

Возьмём шаг  $x^s$

Для каждого  $x^a$ :

1. Возьмём подвыборку средних вознаграждений для каждого действия

2. Рассчитаем среднее в подвыборке:  $\hat{R}(a) = \frac{1}{k} \sum_{i=1}^k R_i(a)$

Найдём такое  $a^*$ , где  $\hat{R}(a)$  максимально

Выполним  $a^*$  и получим  $r'$

Обновим  $Pr(R(x^s, x^a))$  на основе  $r'$

## > Резюме

1. Узнали о проблеме эксплуатации динамического образования.
2. Познакомились с байесовскими многорукими бандитами.
3. Поговорили об алгоритме семплирования Томпсона.

Знакомство с контекстуальными бандитами продолжим на практическом занятии.

## > Дополнительные материалы

1. [CS885 Lecture 8b: Bayesian and Contextual Bandits](#)
2. [Многорукие бандиты в рекомендациях](#)
3. [CS885 Lecture 8a: Multi-armed bandits](#)
4. [Optimism in the Face of Uncertainty: the UCB1 Algorithm](#)

