

# Вероятностное моделирование

лекция 1

**Артур Игнатъев**

CS Space, МКН СПбГУ, ИТМО

**Владимир Евменов**

CS Space, Huawei

# Эксперимент



Конечное число исходов  $\{\omega_1, \omega_2, \dots, \omega_N\}$

- Однократное подбрасывание монетки  
 $\Omega = \{\text{орел, решка}\}$



- Подбрасывание игральной кости  
 $\Omega = \{1, 2, 3, 4, 5, 6\}$



- $n$ -кратное подбрасывание монетки  
 $\Omega = \{\omega : \omega = (a_1, a_2, \dots, a_n)\}$

- Урна с шарами. Есть **5 красных шара** и **5 зеленых**  
 $\Omega = \{\omega : \omega = (a_1, a_2, a_3), \text{ где } a_i \in [10]\}$

- Колода из 36 карт



Пространство элементарных событий  $\Omega = \{\omega_1, \omega_2, \dots, \omega_N\}$

- $A \subset \Omega$  — событие
- 3 раза подбросили монетку
- $A$  — выпало два орла =  $\{ООР, ОРО, ООР\}$
- $B$  — не выпал орел =  $\{РРР\}$
- $A \cup B$  — выпало четное число орлов



Пространство  
элементарных событий

$$\Omega = \{\omega_1, \omega_2, \dots, \omega_N\}$$

- $p_1, p_2, \dots, p_N \geq 0$
- $p_1 + p_2 + \dots + p_N = 1$
- $P(A) = \sum_{k:\omega_k \in A} p_k$  —  
вероятность события

## Свойства.

- $P(\emptyset) = 0, P(\Omega) = 1$
- $0 \leq P(A) \leq 1$
- $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
- $P(A \cup B) \leq P(A) + P(B)$
- $P(\bar{A}) = 1 - P(A)$
- $P(\cup_i A_i) \leq \sum_i P(A_i)$

# Условная вероятность



- $$P(B|A) = \frac{P(A \cap B)}{P(A)}$$

## Свойства.

- $P(A|A) = 1$
- Если  $A \subset B$ , то  $P(B|A) = 1$
- $P(\emptyset|A) = 0$
- Если  $B_1 \cap B_2 = \emptyset$ , то  $P(B_1 \cup B_2|A) = P(B_1|A) + P(B_2|A)$
- $P(B|A) + P(\bar{B}|A) = 1$

# Формула полной вероятности



- $\Omega = A_1 \cup A_2 \cup \dots \cup A_n, A_i \cap A_j = \emptyset$  и  $P(A_i) > 0$
- $B = B \cap \cup_i A_i = \cup_i B \cap A_i$
- $P(B) = \sum_i P(B \cap A_i) = \sum_i P(B | A_i)P(A_i)$
- Если  $0 < P(A) < 1$ , то  $P(B) = P(B | A)P(A) + P(B | \bar{A})P(\bar{A})$
- **Задача.** Из полного набора костей домино взята одна кость. Найдите вероятность того, что наудачу взятую вторую кость можно приставить к первой по правилам ДОМИНО.

# Формула Байеса



- Если для событий  $A$  и  $B$  верно  $P(A) > 0$  и  $P(B) > 0$

- $$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

- $\Omega = A_1 \cup A_2 \cup \dots \cup A_n$ ,  $A_i \cap A_j = \emptyset$  и  $P(A_i) > 0$ ,  $P(B)$

- $$P(A_i|B) = \frac{P(B|A_i)P(A_i)}{\sum_j P(B|A_j)P(A_j)}$$

# Независимые события



- События  $A$  и  $B$  независимые, если  $P(A \cap B) = P(A)P(B)$

- **Пример.** Бросили кубик

- $A$  — выпало четное число,  $P(A) = \frac{1}{2}$



- $B$  — выпало число, кратное трем,  $P(B) = \frac{1}{3}$

- $C$  — выпало число не менее 4,  $P(C) = \frac{1}{2}$

- $P(A \cap B) = \frac{1}{6} = P(A)P(B)$

- $P(A \cap C) = \frac{1}{3} \neq \frac{1}{4} = P(A)P(C)$

- $P(B \cap C) = \frac{1}{6} = P(B)P(C)$



# Независимость в совокупности



- События  $A_1, A_2, \dots, A_n$  независимы в совокупности, если для любых  $1 \leq i_1 < i_2 < \dots < i_k \leq n$   
$$P(A_{i_1} \cap \dots \cap A_{i_k}) = P(A_{i_1}) \dots P(A_{i_k})$$
- Независимость дает независимость в совокупности?
- **Пример.** На гранях тетраэдра числа 1, 2, 3, 4. Бросили тетраэдр.
- $A = \{1,2\}, B = \{1,3\}, C = \{1,4\}$
- $P(A) = P(B) = P(C) = \frac{1}{2}$
- $P(A \cap B) = P(B \cap C) = P(A \cap C) = \frac{1}{4}$
- $P(A \cap B \cap C) = \frac{1}{4} \neq \frac{1}{8} = P(A)P(B)P(C)$
- В другую сторону?



# Случайная величина



- Пространство элементарных событий  $\Omega = \{\omega_1, \omega_2, \dots, \omega_N\}$
- $\xi : \Omega \rightarrow \mathbb{R}$  — случайная величина
- **Пример.** Бросили кубик два раза.  $\Omega = \{(i, j) \mid i, j \in [6]\}$
- $\xi = i + j$  — случайная величина
- Распределение случайной величины — набор вероятностей  $P(\xi = a)$
- Независимые с.в.  $P(\xi = a, \eta = b) = P(\xi = a)P(\eta = b)$  при всех  $a$  и  $b$

# Характеристики с.в.



- Математическое ожидание

$$\mathbb{E}\xi = \sum_{\omega \in \Omega} \xi(\omega)P(\omega) = \sum_{x \in \xi(\Omega)} xP(\xi = x)$$

- Медиана  $a$  с.в.  $\xi$ , если  $P(\xi \leq a) \geq \frac{1}{2}$  и  $P(\xi \geq a) \geq \frac{1}{2}$

## Свойства.

- $\xi \geq 0 \implies \mathbb{E}\xi \geq 0$
- $\mathbb{E}(a\xi + b\eta) = a\mathbb{E}\xi + b\mathbb{E}\eta$
- $\xi \geq \eta \implies \mathbb{E}\xi \geq \mathbb{E}\eta$
- $|\mathbb{E}\xi| \leq \mathbb{E}|\xi|$
- $(\mathbb{E}|\xi\eta|)^2 \leq \mathbb{E}\xi^2\mathbb{E}\eta^2$
- Если  $\xi$  и  $\eta$  независимы, то  $\mathbb{E}(\xi\eta) = \mathbb{E}\xi\mathbb{E}\eta$

# Характеристики с.в.



- Дисперсия

$$\mathbb{D}\xi = \mathbb{E}((\xi - \mathbb{E}\xi)^2)$$

## Свойства.

- $\mathbb{D}\xi \geq 0$

- $\mathbb{D}\xi = \mathbb{E}(\xi^2) - (\mathbb{E}\xi)^2$

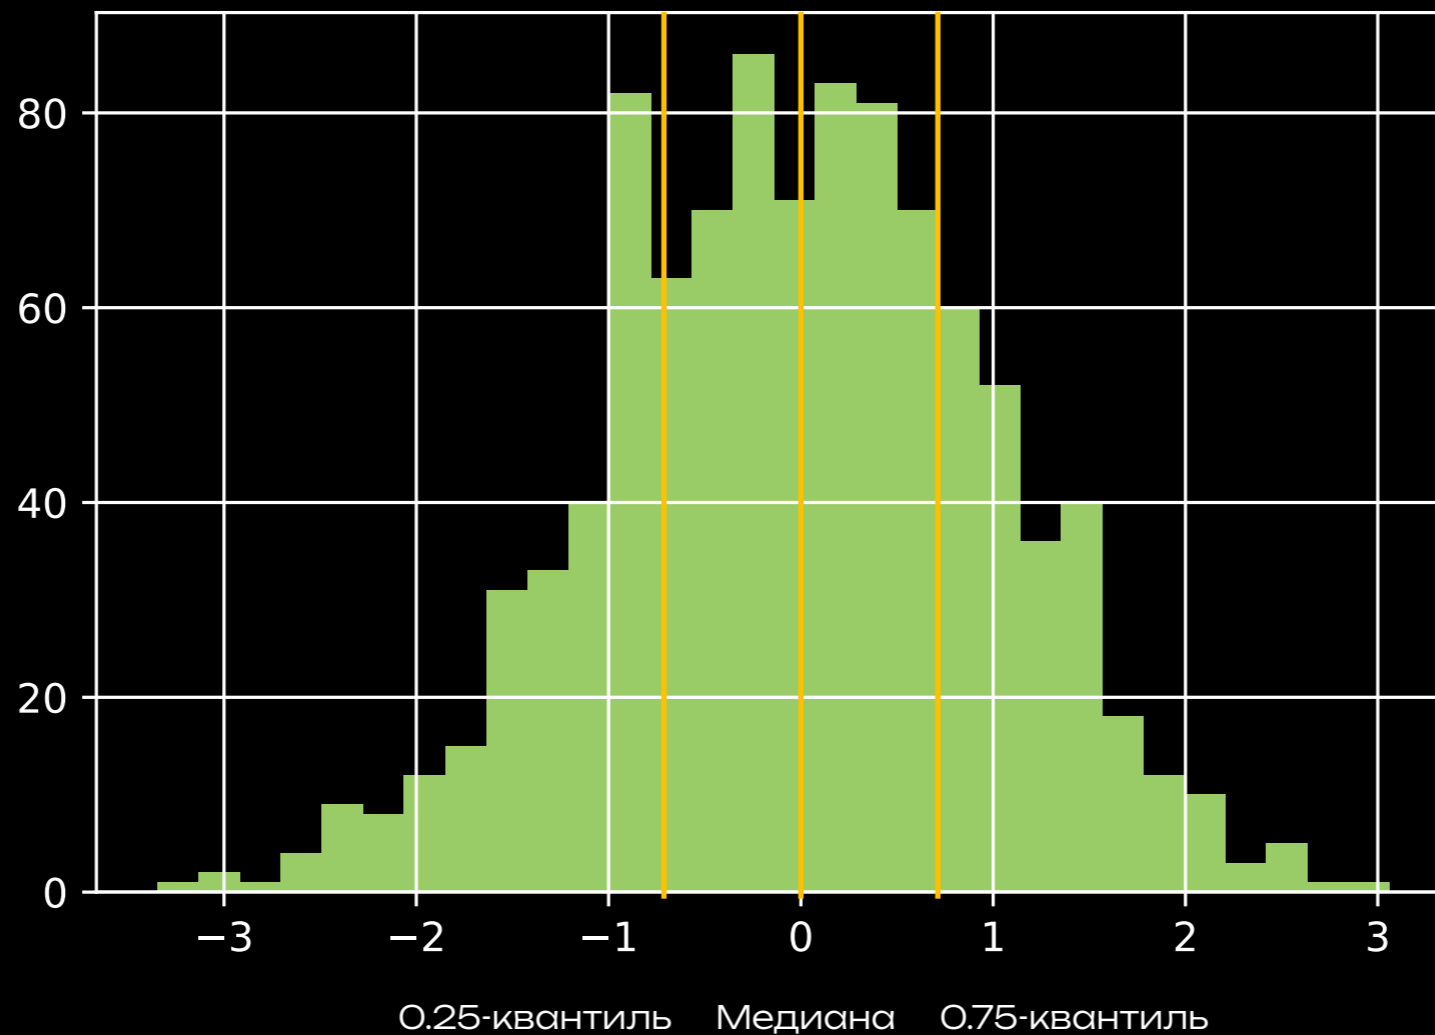
- $\mathbb{D}(\xi + a) = \mathbb{D}\xi$

- $\mathbb{D}(c\xi) = c^2\mathbb{D}\xi$

# Квантиль с.в.



- Пусть  $\alpha \in (0,1)$ ,  $\alpha$ -квантиль называется число  $x_\alpha$ :  
 $P(\xi \leq x_\alpha) \geq \alpha$  и  $P(\xi \geq x_\alpha) \geq 1 - \alpha$



# Оценка характеристик по модели



**Пример.** Барбершоп:

- 3 мастера
- первый клиент приходит в 9 часов +  $Exp(1/20)$  минут, второй приходит через  $Exp(1/20)$  минут после первого и т.п.
- если есть свободный мастер, то клиент идет к нему, иначе ждет в очереди
- мастер обслуживает клиента в течение  $U(15,45)$  минут
- в 16:00 вход закрывается, а барбершоп закрывается после обслуживания последнего уже зашедшего клиента
- Какова медианная доля клиентов, которым приходится сидеть в очереди? Каков 0.95 квантиль времени сидения в очереди? Во сколько в среднем закрывается барбершоп?

# Метод Монте-Карло



Когда теоретически оценить характеристику нелегко, можно использовать метод монтекарловских симуляций.

Вкратце идея такая:

1. с помощью модели генерируем  $N$  **независимых** реализаций данных
2. по полученным реализациям считаем нужную характеристику

В случае с барбершопом нужно будет сгенерировать  $N$  дней, для  $i$ -го дня посчитать долю ждущих  $r_i$ , среднее время сидения в очереди  $w_i$  и время закрытия  $c_i$ , после чего

- оценить медиану долей как центральный элемент в отсортированном наборе  $r_i$
- оценить 0.95 квантиль времени ожидания как 0.95 $N$ -й элемент в отсортированном наборе  $w_i$
- оценить среднее время закрытия как среднее набора  $c_i$

# Метод Монте-Карло



- Тонкости...
- Как понять, что нужно сделать с набором значений, чтобы оценить искомую характеристику?
- Какой  $N$  взять, чтобы было хорошо?
- Посчитанные значения наверняка будут неточными. Как посчитать погрешность?
- Всегда ли посчитанная оценка будет реально оценивать то, что нужно?





- Набор  $x_{[n]} = [x_1, \dots, x_n]$  из  $n$  независимых реализаций случайного элемента  $X$  называется **выборкой объема  $n$** .  
Распределение  $\mathcal{P}_X$  называется **генеральной совокупностью**.
- **Случайной выборкой** называется набор  $X_{[n]} = [X_1, \dots, X_n]$ ,  $X_i \sim X$  независимых одинаково распределенных случайных элементов. Выборка это реализация (одна) случайной выборки.
- Предположение о том, что некоторый набор данных является выборкой — **это сильное предположение**; всегда нужно подумать о том, адекватно ли оно!

# Эмпирическое распределение



- Для выборки  $x_{[n]}$  рассмотрим эмпирическое распределение  $\mathcal{P}_n^*$ :

	$x_1$	$x_2$	$\dots$	$x_n$
$P$	$\frac{1}{n}$	$\frac{1}{n}$	$\dots$	$\frac{1}{n}$

- **Дискретное распределение.** Вероятность события  $A$  равна

$$P(A) = \frac{1}{n} \sum_{i=1}^n [x_i \in A]$$

- Вообще  $P(x_i)$  не равно  $\frac{1}{n}$ , так как в выборке может быть несколько одинаковых значений


- **Эмпирическая случайная величина**  $X^*$ , имеющая распределение  $\mathcal{P}_n^*$ .  
Реализацией  $X^*$  является случайный элемент выборки.

# Эмпирическая ф.р.




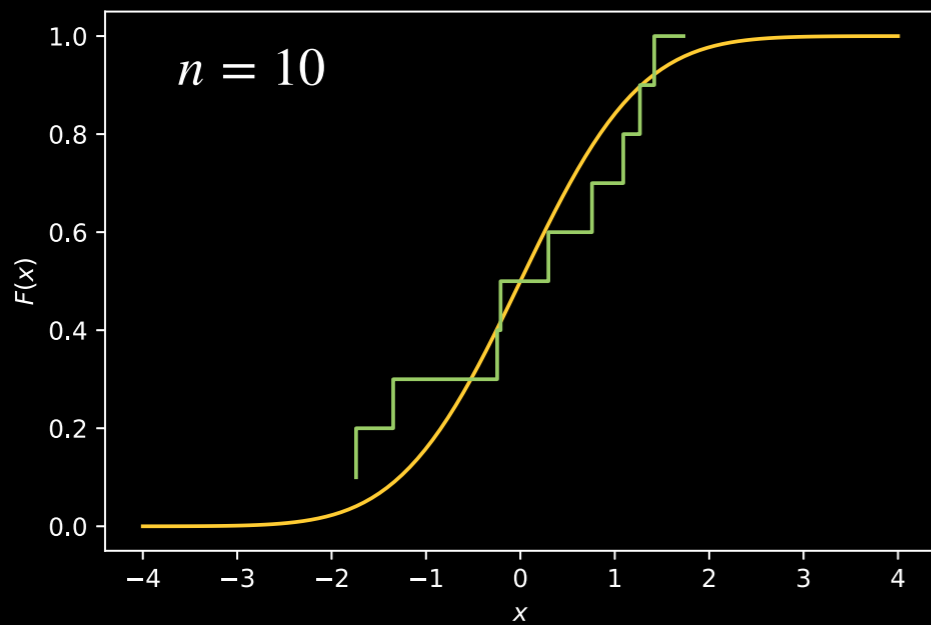


- Для выборки  $x_{[n]}$  с одномерным  $\mathcal{P}_X$  рассмотрим



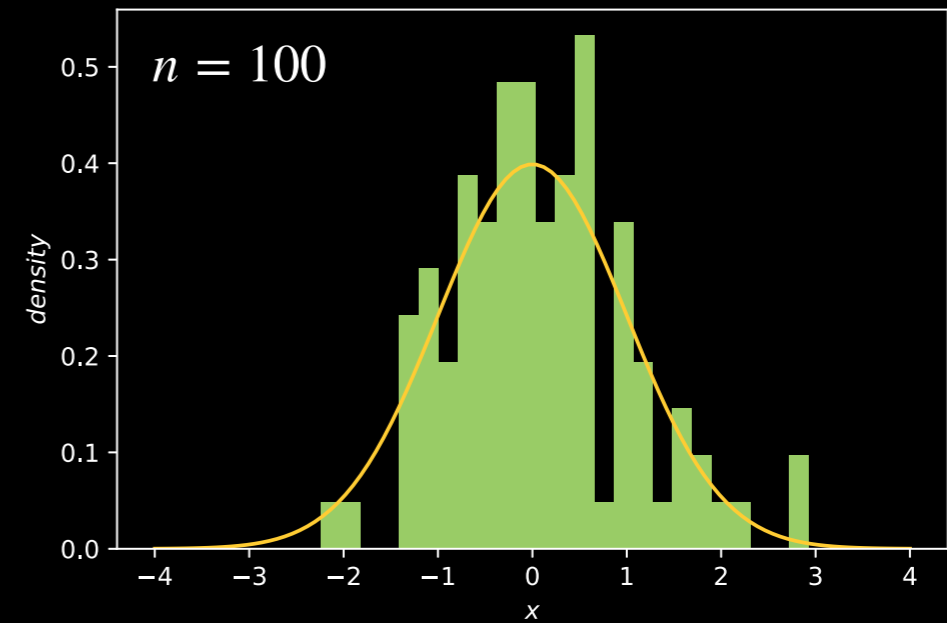

$$F_n^\star = \frac{1}{n} \sum_{i=1}^n [x_i < x] \text{ — эмпирическую функцию распределения.}$$



# Количество и качество



# Количество и качество



# Почему все работает?



- **Закон больших чисел.**

$\xi_n$  — независимые одинаково распределенные случайные величины. Тогда  $\frac{\xi_1 + \dots + \xi_n}{n} \xrightarrow[n \rightarrow \infty]{} a$  почти наверное

$\iff \mathbb{E}\xi_n = a.$

- **Теорема Гливенко-Кантелли.**

$\sup_{x \in \mathbb{R}} |F_n^*(x) - F_X(x)| \rightarrow 0$  почти наверное.