

## Общие понятия статистики

Семинар был посвящен введению в теорию проверки гипотез.

**Определение 1.** Пусть  $\mathbf{X} = (X_1, X_2, \dots, X_n)$  — выборка размера  $n$  из некоторого распределения  $F$ . Гипотезой  $H$  называется любое предположение о природе распределения  $F$

Рассмотрим случай, когда гипотезы всего две — основная

$$H_0 = \{F \in \mathcal{F}_0\}$$

и альтернативная:

$$H_a = \{F \in \mathcal{F}_a\},$$

где  $\mathcal{F}_0$  и  $\mathcal{F}_a$  — некоторые непересекающиеся семейства распределений.

**Определение 2.** Статистическим критерием, различающим основную гипотезу  $H_0$  и альтернативную гипотезу  $H_a$ , называется функция

$$\delta : \mathcal{X}^n \rightarrow \{H_0, H_a\},$$

которая задается следующим образом:

$$\delta(\vec{X}) = \begin{cases} H_0, & \text{если } \mathbf{X} \in \mathbb{R}^n / K; \\ H_a, & \text{если } \mathbf{X} \in K. \end{cases}$$

Здесь  $\mathcal{X}^n$  — выборочное пространство, а множество  $K$  называется критической областью критерия  $\delta(\mathbf{X})$ .

**Определение 3.** Ошибкой  $i$ -го рода называется вероятность при верной  $i$ -ой гипотезе принять другую.

Ошибка первого рода, в случае если гипотез две, называется *размером или уровнем значимости* критерия. Единица минус ошибка второго рода — *мощностью* критерия.

**Определение 4.** Фактически достигаемым уровнем значимости ( $p$ -значением) семейства критериев  $\{\delta_\varepsilon(\mathbf{X})\}$ ,  $\varepsilon \in (0, 1)$  с критическими областями  $K(\varepsilon)$  и размерами  $\varepsilon$ , на выборке  $\mathbf{X}$  называется случайная величина

$$\varepsilon(\mathbf{X}) = \inf \{\varepsilon : \mathbf{X} \in K(\varepsilon)\}.$$

## Тесты на случайность. Тесты, основанные на общем количестве серий.

Как понять, что последовательность символов двух типов является случайной?

Серия — это подпоследовательность символов одного типа, за которой следует и которой предшествует другой тип символа или нет символа вообще. Пусть, например, имеется последовательность символов  $aabbbbbaaaabbbabbabbbbbaa$ . Здесь 5 серий символов типа  $a$  и 4 серии символов типа  $b$ .

Ключ к отсутствию случайности дает любая тенденция символов демонстрировать определенный шаблон в последовательности (чередование, кластеризация и т.д.)

Мы соиим критерий, различающий основную гипотезу

$$H_0 = \{\text{последовательность случайна}\},$$

и альтернативу

$$H_a = \{\text{последовательность не случайна}\}.$$

Пусть у нас имеется упорядоченная последовательность  $n$  элементов двух типов, причём

$n_1$  — количество элементов типа 1,  $R_1$  — количество серий элементов типа 1,  
 $n_2$  — количество элементов типа 2,  $R_2$  — количество серий элементов типа 2,

где, с необходимостью,  $n = n_1 + n_2$ .

Пусть  $R = R_1 + R_2$  — общее число серий в последовательности. Мы построим тест, основанный на этой величине.

### Распределение $R$

Распределение  $R$  ищется в предположении, что верна  $H_0$ . Сначала мы нашли совместное распределение  $R_1, R_2$ , доказав следующую

**Лемма 1.** *Число различных размещений  $n$  объектов в  $r$  различных ячеек, при которых не остается пустых ячеек, равно  $\binom{n-1}{r-1}$ ,  $n \geq r$ ,  $r \geq 1$ .*

Основываясь на лемме, можно получить совместное распределение вероятностей  $R_1, R_2$ .

**Теорема 1.** *Совместное распределение  $R_1$  и  $R_2$  задаётся правилом:*

$$f_{R_1, R_2}(r_1, r_2) \equiv \mathbf{P}(R_1 = r_1, R_2 = r_2) = \frac{c \binom{n_1-1}{r_1-1} \binom{n_2-1}{r_2-1}}{\binom{n_1+n_2}{n_1}}, \quad r_i = 1, \dots, n_i, \quad i = 1, 2,$$

где  $c = 2$ , если  $r_1 = r_2$ , и  $c = 1$ , если  $r_1 = r_2 \pm 1$  ( $r_1$  и  $r_2$  могут принимать только такие значения).

Просуммировав по всем возможным значениям  $R_2$ , получим распределение  $R_1$

$$f_{R_1}(r_1) = \frac{\binom{n_1-1}{r_1-1} \binom{n_2+1}{r_1}}{\binom{n_1+n_2}{n_1}}, \quad r_1 = 1, \dots, n_1.$$

Аналогично получается распределение для  $R_2$ .

Из вышесказанного можно получить распределение для  $R$

**Теорема 2.**

$$f_R(r) = \begin{cases} \frac{2 \binom{n_1-1}{r/2-1} \binom{n_2-1}{r/2-1}}{\binom{n_1+n_2}{n_1}} =: f_1(r), & \text{если } r \text{ четное,} \\ \frac{\binom{n_1-1}{(r-1)/2-1} \binom{n_2-1}{(r-3)/2-1} + \binom{n_1-1}{(r-3)/2-1} \binom{n_2-1}{(r-1)/2-1}}{\binom{n_1+n_2}{n_1}} =: f_2(r), & \text{если } r \text{ нечетное.} \end{cases}$$