

Лекция 1

Лука Yaroshevskiy

6 сентября

Содержание

1 Введение	1
2 Выборочные характеристики	1
3 Первоначальная обработка	2

1 Введение

Определение. Генеральная совокупность — множество всех исходов определенного всех эксперимента

Определение. Выборочная совокупность — множество исходов наблюдаемых экспериментов

Примечание. Выборка *репрезентативная* если ее распределение совпадает с распределением генеральной совокупности

Определение. 1 Пусть проведено n наблюдаемых независимых экспериментов в которых наблюдаемые величины приняли значения: X_1, X_2, \dots, X_n . Набор этих данных называется **выборкой объема n**

Определение. 2 **Выборкой объема n** называется набор из n независимых одинакового распределенных случайных величин

2 Выборочные характеристики

Пусть имеется выборка в смысле 1. Ее можно понимать как следующую дискретную случайную величину:

$$\begin{array}{ccccccc} X_1 & X_2 & X_3 & \dots & X_n & \sum & \\ p_i & \frac{1}{n} & \frac{1}{n} & \dots & \frac{1}{n} & 1 & \end{array}$$

$$X = \sum_{i=1}^n \frac{1}{n} X_i = \frac{1}{n} \sum_{i=1}^n X_i$$

— матожидание?

$$S^2 = \sum_{i=1}^n (X_i - X)^2 \cdot \frac{1}{n} = \frac{1}{n} \sum_{i=1}^n (X_i - X)^2$$

— дисперсия

$$F_n^*(z) = \frac{1}{n} \sum_{i=1}^n I(X_i < z)$$

— функция распределения, где $I(X < z) = \begin{cases} 1 & , X < z \\ 0 & , X_i \geq z \end{cases}$ — индикатор

Теорема 2.1. $\forall z \in \mathbb{R}$

$$F_n^*(z) \xrightarrow[n \rightarrow \infty]{P} F(z)$$

Доказательство.

$$EI(X_1 < z) = 1 \cdot p(X < z) + 0 \cdot p(X_1 \geq z) = p(X_1 < z) = F(z)$$

— функция распределения X_1

По ЗБЧ Хнчина:

$$F_n^*(z) = \frac{\sum I(X_i < z)}{n} \xrightarrow{p} EI(X_1 < z) = F(z)$$

□

Примечание. На самом деле имеется даже равномерная сходимость по вероятности: *теорема Гливенко-Кантеля*:

$$\sup_{z \in \mathbb{R}} |F_n^*(z) - F(z)| \xrightarrow{p} [n \rightarrow \infty] 0$$

3 Первоначальная обработка

Определение. Если упорядочить выборку по возрастанию (ранжирование) то получим **вариационный ряд**:

$$X_{(1)} \leq X_{(2)} \leq \dots \leq X_{(n)}$$

Если учесть повторяющиеся экземпляры, получим **частотный вариационный ряд**

$$\begin{array}{cccccc} X_{(1)} & X_{(2)} & \dots & X_{(k)} & \sum & \\ \hline n_1 & n_2 & \dots & n_k & n & \\ \hline p_1 & \frac{n_1}{n} & \dots & \frac{n_k}{n} & 1 & \end{array}$$

- $h = X_{\max} - X_{\min}$ — **размах выборки**

Примечание. Допустим разбили интервал (X_{\min}, X_{\max}) на k интервалов, чаще всего одинаковой длины. Тогда $h = \frac{h}{k}$. Тогда вариационный ряд можно заменить интервальным вариационным рядом.

Пример.

$$\begin{array}{cccccc} i & l_1 & l_2 & \dots & l_k & \sum \\ \hline m_i & m_2 & m_2 & \dots & m_k & n \\ \hline \frac{m_i}{n} & \frac{m_1}{m} & \frac{m_2}{m} & \dots & \frac{m_k}{m} & 1 \end{array}$$

На координатной плоскости построим прямоугольники:

- l_i — основание прямоугольника соответствующего интервала
- $\frac{m_i}{nl_i}$ — высота прямоугольника

Получаем ступенчатую фигуру площади 1, которая называется **гистограмма**.

Теорема 3.1. При

- $n \rightarrow \infty$
- $k(n) \rightarrow \infty$
- $\frac{k(n)}{n} \rightarrow 0$

Гистограмма по вероятности будет стремиться к плотности распределения:

$$\frac{m_i}{n} \xrightarrow{p} p(X_i \in l_i) = \int_{l_i} f(x) dx$$

Примечание. Чаще всего число интервалов берется по формулу Стержеса.

$$k \approx 1 + \log_k n$$

$$k \approx \sqrt[3]{n}$$

Примечание. Иногда выборка изображается в виде полигона

- l_i^m — середина i -го интервала