

## Оглавление

1.	Описательная статистика и моделирование . . . . .	2
1.1.	Выборка, эмпирическое распределение, гистограмма	2
1.2.	Характеристики выборочного распределения . . . . .	5
1.3.	Производящие функции моментов . . . . .	9
1.4.	Практическое занятие по теме моделирования . . . . .	10

# 1. Описательная статистика и моделирование

## 1.1. Выборка, эмпирическое распределение, гистограмма

Главной задачей математической статистики является разработка методов построения научно-обоснованных выводов о массовых явлениях и процессах на основе данных наблюдений и экспериментов. Эти выводы касаются параметров, видов распределения и других свойств случайных величин по конечной совокупности наблюдений над ними — выборке.

Выборка понимается следующим образом. Пусть случайная величина  $\xi$  наблюдается в случайном эксперименте, который повторяется  $n$  раз при одних и тех же условиях. Этот составной эксперимент связан со случайным вектором  $(\xi_1, \dots, \xi_n)$ , где случайная величина  $\xi_j$  соответствует  $j$ -му эксперименту. В биостатистике с понятием эксперимента соотносится понятие индивида. Очевидно, что компоненты  $\xi_j$ ,  $j = 1, 2, \dots, n$ , — независимые в совокупности и распределенные по тому же закону, что и случайная величина  $\xi$ .

Закон распределения случайной величины  $\xi$  называется *законом распределения генеральной совокупности*, а случайный вектор  $(\xi_1, \dots, \xi_n)$  выборочным вектором. Реализация выборочного вектора называется *выборкой*  $(x_1, \dots, x_n)$  объема  $n$ .

Аналогично определяется выборка в случае нескольких случайных величин. Обычно  $p$ -мерную выборку представляют в виде следующей таблицы.

	$\xi_1$	$\xi_2$	$\dots$	$\xi_p$
$\omega_1$	$x_{11}$	$x_{12}$	$\dots$	$x_{1p}$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
$\omega_n$	$x_{n1}$	$x_{n2}$	$\dots$	$x_{np}$

Через  $\omega_j$ ,  $j = 1, \dots, n$ , обозначаются *индивиды*, через  $\xi_i$ ,  $i = 1, \dots, p$ , *признаки*, через  $\xi_{ji}$  *варианты* или значения признака  $\xi_i$  у индивида  $\omega_j$ .

Признаки подразделяются на *количественные, порядковые и качественные или категориальные*. К количественным признакам относятся те, которые можно измерить в определенном масштабе (оценки за контрольную работу), к порядковым те, которые измерить нельзя, но можно упорядочить, например, при построении по росту. Тяжесть заболевания с градациями: стабильное состояние, средней тяжести и тяжелое — относится к порядковому признаку. Основное отличие качественных признаков заключается в том, что их градации можно менять местами. Например, цвет глаз, тип операции, назначенный для лечения препарат и так далее.

Пусть выборка  $(x_1, \dots, x_n)$  содержит  $k$  различных градаций  $z_1, \dots, z_k$  признака  $\xi$ , причем градация  $z_i$  встречается  $n_i$  раз,  $\sum_{i=1}^k n_i = n$ . *Статистическим рядом* называется последовательность пар  $(z_i, n_i)$ ,  $i = 1, \dots, k$ .

В случае количественных или порядковых признаков применяют *вариационный ряд*, под которым понимают упорядоченную выборку

$$x^{(1)} \leq \dots \leq x^{(n)}.$$

Разность  $x^{(n)} - x^{(1)} = R$  называется *размахом выборки*.

При большом объеме выборки ее элементы объединяются в группы (разряды, карманы и т.п.), представляя результаты в виде *группированного статистического ряда*. Для этого интервал, содержащий все элементы выборки, разбивается на  $k$  непересекающихся интервалов. Длина этих интервалов обычно одинакова и равна  $b \approx \frac{w}{k}$ . После этого вычисляются частоты  $\nu_i$ , равные количеству элементов выборки, попадающих в этот интервал. Через  $z_i$  обозначаются середины интервалов группировки, частоты  $\frac{\nu_i}{n}$  называются *относительными*.

**Определение 1.** Пусть  $x_1, \dots, x_n$  выборка из генеральной совокупности

с функцией распределения  $F(x)$ . *Распределением выборки* называется распределение дискретной случайной величины со значениями  $x_1, \dots, x_n$  с вероятностями  $1/n$ . Соответствующая функция распределения называется выборочной или *эмпирической функцией распределения*

$$F_n(x) = \frac{\mu_n(x)}{n},$$

где  $\mu_n(x)$  равно количеству элементов выборки, не больших  $x$ .

**Теорема 1.** (Гливенко) Для любых  $x \in (-\infty; +\infty)$  и  $\epsilon > 0$

$$\lim_{n \rightarrow \infty} P\{|F_n(x) - F(x)| < \epsilon\} = 1.$$

Действительно, если считать „успехом“ событие  $x_i \leq x$  с вероятностью  $p = P\{x_i \leq x\}$ , то  $\mu_n(x)$  равно числу успехов в  $n$  независимых испытаниях. Из теоремы Бернулли получаем

$$\lim_{n \rightarrow \infty} P\left\{\left|\frac{\mu_n(x)}{n} - p\right| < \epsilon\right\} = \lim_{n \rightarrow \infty} P\{|F_n(x) - F(x)| < \epsilon\} = 1.$$

Таким образом, при каждом  $x$  эмпирическая функция  $F_n(x)$  сходится по вероятности к  $F(x)$  и при большом объеме выборки может служить приближенным значением (оценкой) функции распределения.

*Гистограммой частот* группированной выборки будем называть кусочно-постоянную функцию, принимающую на интервалах группировки значения  $n_i/b$ . Площадь под графиком равна  $n$ . *Гистограмма относительных частот* определяется аналогично с площадью под ступенчатым графиком, равной 1. При увеличении объема выборки и уменьшении интервалов группировки гистограмма относительных частот является статистическим аналогом плотности распределения генеральной совокупности.

Полигоном частот называется ломаная с вершинами  $(z_i, \frac{n_i}{b})$ , а в случае относительных частот  $(z_i - \text{середины интервалов группировки})$  с вершинами  $(z_i, \frac{n_i}{nb})$ .

## 1.2. Характеристики выборочного распределения

Числовые характеристики выборочного распределения называются выборочными или эмпирическими. *Выборочное среднее* и *выборочная дисперсия* имеют соответственно вид

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i, \quad m_2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2.$$

Введем выражения для начальных и центральных выборочных моментов

$$a_\nu = \frac{1}{n} \sum_{i=1}^n x_i^\nu, \quad m_\nu = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^\nu.$$

Можно показать, что

$$\begin{aligned} m_2 &= a_2 - \bar{x}^2, \\ m_3 &= a_3 - 3a_2\bar{x} + 2\bar{x}^3, \\ m_4 &= a_4 - 4a_2\bar{x} + 6a_2\bar{x}^2 - 3\bar{x}^4. \end{aligned} \tag{1}$$

В частности

$$\begin{aligned} m_2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n (x_i^2 - 2x_i\bar{x} + \bar{x}^2) = \\ &= a_2 - 2\bar{x}\bar{x} + \bar{x}^2 = a_2 - \bar{x}^2. \end{aligned}$$

**Определение 2.** Оценка  $\hat{\theta}_n$  называется *несмещенной*, если ее математическое ожидание совпадает с истинным значением параметра, т.е.  $\mathbf{E}\hat{\theta}_n = \theta$ .

Если  $\mathbf{E}\hat{\theta}_n = \theta + b(\theta)$ , то  $b(\theta)$  называется *смещением*.

**Утверждение 1.** Второй выборочный центральный момент является смещенной оценкой дисперсии  $\sigma^2$ , то есть

$$\mathbf{E}m_2 = \frac{\sigma^2(n-1)}{n}. \tag{2}$$

Поэтому в качестве оценки дисперсии используют выражение

$$S^2 = \frac{n}{n-1} m_2 = \frac{1}{n-1} \sum_{j=1}^n (x_j - \bar{x})^2.$$

Для того чтобы убедиться в этом, введем  $y_i = x_i - \mu$  с математическим ожиданием  $\mathbf{E}y_i = 0$  и дисперсией  $\mathbf{D}y_i = \sigma^2$ , тогда  $\bar{y} = \bar{x} - \mu$ ,

$$\begin{aligned} m_2 &= \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 = \\ &\text{из (1)} = \frac{1}{n} \sum_{i=1}^n y_i^2 - \bar{y}^2. \\ \mathbf{E}m_2 &= \frac{1}{n} \sum_{i=1}^n \mathbf{E}y_i^2 - \mathbf{E}\bar{y}^2 = \sigma^2 - \frac{1}{n^2} \sum_{i,j} \mathbf{E}y_i y_j = \\ &= \sigma^2 - \frac{1}{n^2} \sum_i \mathbf{E}y_i^2 = \sigma^2 - \frac{\sigma^2}{n}, \end{aligned}$$

так как  $\mathbf{E}y_i^2 = \mathbf{D}y_i = \sigma^2$ , а при  $i \neq j$  из-за независимости элементов выборки  $\mathbf{E}y_i y_j = \mathbf{E}y_i \mathbf{E}y_j = 0$ .

Стандартное отклонение выборочного среднего  $\frac{S}{\sqrt{n}}$  иначе называют *ошибкой среднего*.

Выборочной *модой* унимодального распределения является элемент выборки *mod*, встречающийся с наибольшей частотой. Например, в выборке 1, 1, 1, 1, 2, 2, 2, 3, 3, 4 модой является значение 1.

Выборочной *медианой* является число, которое делит вариационный ряд на две части, содержащие одинаковое число элементов. Если  $n = 2k$ , то  $med = (x^{(k)} + x^{(k+1)})/2$ . Если  $n = 2k + 1$ , то  $med = x^{(k+1)}$ . В данном примере  $med = 2$ .

С понятием функции распределения связано понятие  $P$ -квантили распределения — такого значения  $x_P$  случайной величины  $\xi$ , что

$$P\{\xi \leq x_P\} = P. \quad (3)$$

Если  $nP$  — не целое число, то выборочной квантилью  $x_P^*$  порядка  $P$  называется  $k$ -й член вариационного ряда, где  $k = [nP] + 1$ . Если  $nP = k$ , то выборочная квантиль  $x_P^*$  может принимать любое значение на интервале  $[x^{(k)}, x^{(k+1)})$ . Для определенности используют их среднее арифметическое.

Коэффициент асимметрии определяется как

$$\gamma_1 = \frac{\mu_3}{\mu_2^{\frac{3}{2}}}, \quad \text{выборочный как } g_1 = \frac{m_3}{m_2^{\frac{3}{2}}}.$$

Для вычисления используем соотношение между центральными и начальными моментами:  $m_2 = a_2 - \bar{x}^2$  и  $m_3 = a_3 - 3a_2\bar{x} + 2\bar{x}^3$ .

**Предложение 1.** В случае симметричного закона распределения, когда для плотности распределения справедливо

$$f(\mathbf{E}\xi - x) = f(\mathbf{E}\xi + x),$$

все нечетные моменты равны нулю.

Действительно,

$$\begin{aligned} \mu_{2k+1} &= \int_{-\infty}^{+\infty} (x - \mathbf{E}\xi)^{2k+1} f(x) dx = \\ &= \int_{-\infty}^{\mathbf{E}\xi} (x - \mathbf{E}\xi)^{2k+1} f(x) dx + \int_{\mathbf{E}\xi}^{+\infty} (x - \mathbf{E}\xi)^{2k+1} f(x) dx \end{aligned}$$

В первом интеграле сделаем замену  $x - \mathbf{E}\xi = y$ , а во втором  $x - \mathbf{E}\xi = -y$ .

Получаем

$$\int_{-\infty}^0 y^{2k+1} f(y + \mathbf{E}\xi) dy + \int_0^{-\infty} (-y)^{2k+1} f(\mathbf{E}\xi - y) (-dy) = 0.$$

Эксцесс  $\gamma_2 = \frac{\mu_4}{\mu_2^2} - 3$  используется в качестве метрики отклонения от нормального закона распределения, при котором эксцесс равен нулю. Выборочный эксцесс вычисляется как  $g_2 = \frac{m_4}{m_2^2} - 3$ .

**Предложение 2.** Пусть  $\xi \sim \mathcal{N}(0, 1)$ . Тогда  $\mu_4 = 3$ .

В плотности нормального распределения заменим  $\sigma^2$  на  $\frac{1}{h}$  и сосчитаем производные по  $h$

$$\int_{-\infty}^{+\infty} e^{-\frac{t^2 h}{2}} dt = \sqrt{2\pi} h^{-\frac{1}{2}}$$

$$\int_{-\infty}^{+\infty} e^{-\frac{t^2 h}{2}} \left(-\frac{t^2}{2}\right) dt = \sqrt{2\pi} \left(-\frac{1}{2}\right) h^{-\frac{3}{2}},$$

$$\int_{-\infty}^{+\infty} e^{-\frac{t^2 h}{2}} \left(-\frac{t^2}{2}\right)^2 dt = \sqrt{2\pi} \left(-\frac{1}{2}\right) \left(-\frac{3}{2}\right) h^{-\frac{5}{2}}.$$

При  $h = 1$  из последнего уравнения получаем

$$\int_{-\infty}^{+\infty} e^{-\frac{t^2 h}{2}} \left(\frac{t^4}{4}\right) dt = \sqrt{2\pi} \left(\frac{3}{4}\right), \implies \mu_4 = 3.$$




Рис. 1. Эксцесс нормального, равномерного и гамма распределений равны соответственно 0,  $-\frac{6}{5}$  и  $\frac{6}{\lambda}$ , где  $\lambda$  параметр формы.

Отсюда для  $\xi \sim \mathcal{N}(0, 1)$  эксцесс имеет вид  $\gamma_2 = \frac{\mu_4}{\mu_2^2} - 3 = 0$ . Нормально распределенная случайная величина  $\zeta$  со средним  $\mu$  и дисперсией  $\sigma^2$  выражается через  $\xi \sim \mathcal{N}(0, 1)$  как  $\zeta = \sigma\xi + \mu$ , следовательно,

$$\mu_4(\zeta) = \sigma^4 \mu_4(\xi), \quad \mu_2(\zeta) = \sigma^2 \mu_2(\xi), \quad \gamma_2(\zeta) = \frac{\sigma^4 \mu_4}{\sigma^4 \mu_2^2} - 3 = 0.$$



### 1.3. Производящие функции моментов

Производящая функция определяется для целочисленной случайной величины  $\xi$ , принимающей значения  $0, 1, 2, \dots$  с вероятностями  $p_0, p_1, p_2, \dots$ ,  $\sum_{j=1}^{\infty} p_j = 1$ , как

$$h(\nu) = \sum_{j=0}^{\infty} p_j \nu^j. \quad (4)$$

Нетрудно убедиться в том, что  $h(1) = 1$ ,

$$\begin{aligned} h'(1) &= \sum_{j=0}^{\infty} j p_j \nu^{j-1} |_{\nu=1} = \alpha_1 = \mathbb{E}\xi, \\ h''(1) &= \sum_{j=0}^{\infty} j(j-1) p_j \nu^{j-2} |_{\nu=1} = \alpha_2 - \alpha_1, \\ \mathbb{D}\xi &= h''(1) + h'(1) - (h'(1))^2. \end{aligned}$$

Главное прикладное значение производящих функций заключается в представлении производящей функции суммы двух независимых величин в виде произведений частных производящих функций. Это свойство справедливо и для производящей функции моментов, которая определяется для случайной величины  $\xi$  (необязательно целочисленной) как

$$g(t) = \mathbb{E}e^{t\xi} = \begin{cases} \int_{\Omega} e^{tx} f(x) dx & \text{в непрерывном случае,} \\ \sum_{j=1}^{\infty} p_j e^{tj} & \text{в дискретном случае.} \end{cases} \quad (5)$$

Значение  $k$ -й производной производящей функции моментов в нуле совпадает с  $k$ -м начальным моментом.

## 1.4. Практическое занятие по теме моделирования

На этом занятии предполагается рассмотреть основные законы распределения (биномиальное, Пуассона, равномерное, нормальное), вычислить математические ожидания, дисперсии, коэффициенты асимметрии и эксцесса. Промоделировать выборки, построить гистограммы и распределения модельных распределений. Сравнить характеристики теоретического и смоделированного распределения.

### Биномиальное распределение

Случайная величина - это величина, которая в результате опыта со случайным исходом принимает то или иное числовое значение, причем заранее неизвестно, какое именно. В случае конечного или счетного количества исходов случайная величина  $\xi$  называется **дискретной**.

Если известны значения  $x_1, x_2, \dots, x_N, \dots$ , которые принимает случайная величина  $\xi$ , а также вероятности  $p_i = P\{\xi = x_i\}$ ,  $i = 1, \dots, N$ ,  $p_1 + \dots + p_N + \dots = 1$ , то говорят, что задан ее **дискретный закон распределения**

$$\xi : \begin{pmatrix} x_1 & x_2 & \dots & x_N \\ p_1 & p_2 & \dots & p_N \end{pmatrix}. \quad (6)$$

Например, при подбрасывании монеты возможны два исхода: успех или неудача, которые кодируются соответственно 1 и 0. Успех обычно ассоциируется с выпадением монеты стороной "орел", которая выпадает с вероятностью  $p = 0.5$ . Неудача ассоциируется с выпадением стороны "решка", которая выпадает с вероятностью  $q = 1 - p = 0.5$ . Вероятность успеха  $p$  необязательно равна 0.5. Если при подбрасывании игрального кубика успехом считать выпадении шести очков, то  $p = \frac{1}{6}$ ,  $q = \frac{5}{6}$ . Случайная величина, принимающая два значения с вероятностями  $p$  и  $q = 1 - p$ , имеет **распределение Бернулли**. Для краткости можно использовать обозначение  $\xi \sim \beta(p, 1)$ .

Обозначим через  $\xi$  случайное число выпадения шести очков игрального кубика в  $n = 4$  независимых испытаниях с вероятностью выпадения шести очков (успех)  $p = \frac{1}{6}$ . Построим закон распределения этой случайной величины. Вычисление вероятностей  $P\{\xi = k\}$ ,  $k = 0, 1, \dots, 4$ , отображено в таблице 1, где через  $q = 1 - \frac{1}{6} = \frac{5}{6}$  обозначена вероятность невыпадения шести очков (неудача), через  $C_n^k$  число сочетаний по  $k$  из  $n$  элементов, которое вычисляется по формуле

$$C_n^k = \frac{n!}{k!(n-k)!}.$$

Проверим, что вероятности  $p_k$  соответствуют закону распределения:

$$\sum_{k=1}^4 p_k = \frac{5^4 + 4 \cdot 5^3 + 6 \cdot 5^2 + 4 \cdot 5 + 1}{6^4} = \frac{(5+1)^4}{6^4} = 1.$$

число успехов $k$	варианты комбинаций	вероятность $p_k$
0	o o o o	$C_4^0 p^0 q^4 = \left(\frac{5}{6}\right)^4$
1	• o o o   o • o o   o o • o   o o o •	$C_4^1 p^1 q^3 = 4 \cdot \frac{1}{6} \left(\frac{5}{6}\right)^3$
2	• • o o   • o • o   • o o •   o • • o o • • •   o o • •	$C_4^2 p^2 q^2 = 6 \cdot \left(\frac{1}{6}\right)^2 \left(\frac{5}{6}\right)^2$
3	• • • o   • • o •   • o • •   o • • •	$C_4^3 p^3 q^1 = 4 \cdot \left(\frac{1}{6}\right)^3 \left(\frac{5}{6}\right)^1$
4	• • • •	$C_4^4 p^4 q^0 = \left(\frac{1}{6}\right)^4$

Таблица 1. Биномиальный закон распределения при  $n = 4$  и  $p = 0.5$ .

Обозначим через  $\varepsilon_i$ ,  $i = 1, 2, \dots, n$ , независимые случайные величины, имеющие распределение Бернулли с параметром  $p$ . Случайная величина  $\xi = \varepsilon_1 + \dots + \varepsilon_n$ , равная случайному числу успехов из  $n$  независимых испытаний, имеет **биномиальный закон распределения**:

$$P\{\xi = k\} = C_n^k p^k (1-p)^{n-k}, \quad k = 0, 1, \dots, n. \quad (7)$$

Для краткости можно использовать обозначение  $\xi \sim \beta(p, n)$ .

Дисперсия суммы двух случайных величин  $\xi, \eta$  равна

$$\begin{aligned} D(\xi + \eta) &= \mathbb{E}((\xi + \eta) - \mathbb{E}(\xi + \eta))^2 = \mathbb{E}((\xi - \mathbb{E}\xi) + (\eta - \mathbb{E}\eta))^2 = \\ &= \mathbb{E}(\xi - \mathbb{E}\xi)^2 + \mathbb{E}(\eta - \mathbb{E}\eta)^2 + \underbrace{2\mathbb{E}(\xi - \mathbb{E}\xi)(\eta - \mathbb{E}\eta)}_{cov(\xi, \eta)} \end{aligned}$$

Если величины  $\xi, \eta$  независимы, то ковариация

$$cov(\xi, \eta) = \mathbb{E}(\xi - \mathbb{E}\xi)(\eta - \mathbb{E}\eta) = \mathbb{E}(\xi - \mathbb{E}\xi)\mathbb{E}(\eta - \mathbb{E}\eta) = 0,$$

и дисперсия суммы независимых величин равна сумме дисперсий. Отсюда получаем, что дисперсия биномиально распределенной случайной величины равна  $npq$ . Производящая функция моментов, коэффициенты асимметрии и эксцесса представлены в таблице 2.

В *R* для моделирования  $n$  биномиальных случайных величин с вероятностью успеха *prob* из *size* независимых испытаний используется функция *rbinom*( $n, size, prob$ ). Для СВ с распределением Бернулли  $size = 1$ .

## Распределение Пуассона

Отдельно рассматривается случай, когда число испытаний велико при малой вероятности успеха  $p$ . Например, вероятность вызова скорой помощи в определенном временном интервале чрезвычайно мала в каждом отдельном случае. Но при наличии большого числа испытаний количество вызовов может оказаться счетным, то есть равным  $0, 1, 2, \dots$ . Для того чтобы вычислить при  $p \rightarrow 0$  и  $n \rightarrow \infty$  предел вероятности

$$p_k = \frac{n!}{k!(n-k)!} p^k (1-p)^{n-k},$$

обозначим через  $\lambda = np$  и умножим и разделим  $p_k$  на  $n^k$ .

$$p_k = \frac{n(n-1)\dots(n-k+1)}{k!n^k} (np)^k (1-p)^{n-k} \approx \frac{\lambda^k}{k!} e^{-\lambda}, \quad (8)$$

так как, по замечательному пределу,  $e^{-1} = \lim_{p \rightarrow 0} (1 - p)^{\frac{1}{p}}$ , при заданном  $k$

$$\begin{aligned} \lim_{p \rightarrow 0} (1 - p)^{n-k} &= \lim_{p \rightarrow 0} \left( (1 - p)^{\frac{1}{p}} \right)^{pn} (1 - p)^{-k} = e^{-\lambda}, \\ \lim_{n \rightarrow \infty} \frac{n(n-1) \dots (n-k+1)}{n^k} &= 1. \end{aligned}$$

Случайная величина  $\xi$ , принимающая значения  $k = 0, 1, 2, \dots$  с вероятностями (8), имеет **распределение Пуассона**  $\mathcal{P}(\lambda)$ . Так как  $e^\lambda = \sum_{k=0}^{\infty} \frac{\lambda^k}{k!}$ , то

$\sum_{k=0}^{\infty} \frac{\lambda^k}{k!} e^{-\lambda} = 1$ . Математическое ожидание и дисперсия случайной величины  $\xi$  равны  $\lambda$ , так как

$$\begin{aligned} \mathbb{E}\xi &= \sum_{k=0}^{\infty} k p_k = \sum_{k=1}^{\infty} \frac{\lambda^k}{(k-1)!} e^{-\lambda} = \lambda \sum_{k=1}^{\infty} \frac{\lambda^{k-1}}{(k-1)!} e^{-\lambda} = \lambda, \\ \mathbb{E}\xi^2 &= \sum_{k=0}^{\infty} k^2 p_k = \sum_{k=1}^{\infty} \frac{k \lambda^k}{(k-1)!} e^{-\lambda} \stackrel{k=t+1}{=} \sum_{t=0}^{\infty} \frac{(t+1) \lambda^{t+1}}{t!} e^{-\lambda} = \lambda^2 + \lambda, \\ \mathbb{D}\xi &= \mathbb{E}\xi^2 - (\mathbb{E}\xi)^2 = (\lambda^2 + \lambda) - \lambda^2 = \lambda. \end{aligned}$$

Производящая функция моментов, коэффициенты асимметрии и эксцесса представлены в таблице 2. В  $R$  для моделирования  $n$  случайных величин, распределенных по закону Пуассона с интенсивностью  $\lambda$  используется функция  $rpois(n, \lambda)$ .

### Равномерное распределение.

Случайная величина  $\xi \sim U(a, b)$  равномерно распределена на интервале  $[a, b]$ , если ее плотность распределения имеет вид  $f(x) = \frac{1}{b-a}$  на интервале  $[a, b]$  и равна нулю вне этого интервала. МО равно середине интервала, дисперсия пропорциональна длине интервала.

$$\mathbb{E}\xi = \int_a^b \frac{x}{b-a} dx = \frac{1}{b-a} \frac{x^2}{2} \Big|_a^b = \frac{b^2 - a^2}{2(b-a)} = \frac{a+b}{2},$$

$$\mathbb{E}\xi^2 = \int_a^b \frac{x^2}{b-a} dx = \frac{1}{b-a} \frac{x^3}{3} \Big|_a^b = \frac{b^3 - a^3}{3(b-a)} = \frac{a^2 + ab + b^2}{3},$$

$$\mathbb{D}\xi = \mathbb{E}\xi^2 - (\mathbb{E}\xi)^2 = \frac{a^2 + ab + b^2}{3} - \left(\frac{a+b}{2}\right)^2 = \frac{(b-a)^2}{12}.$$

Производящая функция моментов, коэффициенты асимметрии и эксцесса представлены в таблице 2. В  $R$  для моделирования  $n$  случайных величин, распределенных по равномерному закону на интервале  $[a, b]$  используется функция  $runif(n, min = a, max = b)$ .

## Нормальное распределение




Рис. 2. Биномиальное распределение с параметрами  $n = 100$  и  $p = 0.2$  и нормальное распределение с параметрами  $\mu = 20$ ,  $\sigma^2 = 16$ .

Нормальное или гауссовское распределение  $\mathcal{N}(\mu, \sigma)$  было получено как предельное биномиальное распределение при увеличении числа испытаний. Плотность его распределения зависит от двух параметров  $\mu$ ,  $\sigma^2$ ,

смысл которых заключается в среднем и дисперсии.

$$f(x|\mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (9)$$

При  $\mu = 0$ ,  $\sigma^2 = 1$  распределение  $f(x|0, 1)$  называется стандартным нормальным. Для доказательства основного свойства плотности нужно вычислить двойной интеграл

$$\int_{-\infty}^{\infty} \int_{-\infty}^{\infty} e^{-\frac{x^2}{2} - \frac{y^2}{2}} dx dy = 4 \int_0^{\infty} \int_0^{\infty} e^{-\frac{x^2}{2} - \frac{y^2}{2}} dx dy = \left( \int_{-\infty}^{\infty} e^{-\frac{x^2}{2}} dx \right) \left( \int_{-\infty}^{\infty} e^{-\frac{y^2}{2}} dy \right),$$

который может быть вычислен переходом к полярным координатам  $x = r \cos \phi$ ,  $y = r \sin \phi$  с якобианом преобразования

$$dxdy = \begin{vmatrix} \frac{\partial x}{\partial r} & \frac{\partial x}{\partial \phi} \\ \frac{\partial y}{\partial r} & \frac{\partial y}{\partial \phi} \end{vmatrix} dr d\phi = \begin{vmatrix} \cos \phi & -r \sin \phi \\ \sin \phi & r \cos \phi \end{vmatrix} dr d\phi = r dr d\phi,$$

$$4 \int_0^{\infty} \int_0^{\infty} e^{-\frac{x^2}{2} - \frac{y^2}{2}} dx dy = 4 \int_0^{\frac{\pi}{2}} d\phi \int_0^{\infty} e^{-\frac{r^2}{2}} r dr = 2\pi \left( -e^{-\frac{r^2}{2}} \right) \Big|_0^{\infty} = 2\pi.$$

Отсюда  $\int_{-\infty}^{\infty} e^{-\frac{x^2}{2}} dx = \sqrt{2\pi}$ , и справедливо свойство плотности. Пусть  $\xi_0 \sim \mathcal{N}(0, 1)$ . МО  $\mathbb{E}\xi_0 = 0$  из-за симметричности функции относительно нуля:

$$\mathbb{E}\xi_0 = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} x e^{-\frac{x^2}{2}} dx = 0,$$

$$\mathbb{E}\xi_0^2 = \int_{-\infty}^{\infty} \frac{1}{\sqrt{2\pi}} x^2 e^{-\frac{x^2}{2}} dx = \frac{2}{\sqrt{2\pi}} \int_0^{\infty} x \cdot x e^{-\frac{x^2}{2}} dx =$$

Воспользуемся интегрированием по частям  $\int uv' dx = uv - \int u'v dx$ , где  $u = x$ ,  $v' = x e^{-\frac{x^2}{2}}$ ,  $v = -e^{-\frac{x^2}{2}}$ .

$$= -\frac{2}{\sqrt{2\pi}} x e^{-\frac{x^2}{2}} \Big|_0^{\infty} + \frac{2}{\sqrt{2\pi}} \int_0^{\infty} e^{-\frac{x^2}{2}} dx = 1.$$

Следовательно,  $\mathbb{D}\xi_0 = 1$ . Отсюда для  $\xi = \sigma\xi_0 + \mu$  имеем МО  $\mathbb{E}\xi = \mathbb{E}(\sigma\xi_0 + \mu) = \mu$  и дисперсию  $\mathbb{D}\xi = \mathbb{D}(\sigma\xi_0 + \mu) = \sigma^2\mathbb{D}\xi_0 = \sigma^2$ .

Производящая функция моментов, коэффициенты асимметрии и эксцесса представлены в таблице 2. В  $R$  для моделирования  $n$  случайных величин, распределенных по нормальному закону с параметрами  $\mu, \sigma$ , используется функция  $rnorm(n, mean = \mu, sd = \sigma)$ .

Распределение	Среднее	Дисперсия	$\gamma_1$	$\gamma_2$	ПФМ
$\mathcal{N}(\mu, \sigma)$	$\mu$	$\sigma^2$	0	0	$exp(\mu t + \frac{\sigma^2}{2} t^2)$
$\beta(p, n)$	$np$	$npq$	$\frac{q-p}{\sqrt{npq}}$	$\frac{1-6qp}{npq}$	$(q + pe^t)^n$
$\mathcal{P}(\lambda)$	$\lambda$	$\lambda$	$\lambda^{-\frac{1}{2}}$	$\lambda^{-1}$	$exp(\lambda(e^t - 1))$
$U(a, b)$	$\frac{a+b}{2}$	$\frac{(b-a)^2}{12}$	0	$-\frac{6}{5}$	$\frac{e^{tb} - e^{ta}}{t(b-a)}$
$\gamma(\lambda, \alpha)$	$\frac{\lambda}{\alpha}$	$\frac{\lambda}{\alpha^2}$	$\frac{2}{\sqrt{\lambda}}$	$\frac{6}{\lambda}$	$(1 - \frac{t}{\alpha})^{-\lambda}$

Таблица 2. Характеристики распределений

Покажем, что эксцесс равномерного распределения равен  $-\frac{6}{5}$ . Так как эксцесс не зависит от сдвига и масштаба, рассмотрим случай  $\xi \sim U(0, 1)$ .

$$\alpha_k = \int_0^1 x^k dx = \frac{1}{k+1}.$$

$$\mu_2 = \alpha_2 - \alpha_1^2 = \frac{1}{3} - \frac{1}{4} = \frac{1}{12},$$

$$\mu_3 = 0,$$

$$\mu_4 = \alpha_4 - 4\alpha_3\alpha_1 + 6\alpha_2\alpha_1^2 - 3\alpha_1^4 = \frac{1}{5} - \frac{4}{4 \cdot 2} + \frac{6}{3 \cdot 4} - \frac{3}{16} = \frac{1}{80},$$

$$\gamma_2 = \frac{\mu_4}{\mu_2^2} - 3 = \frac{12^2}{80} - 3 = -\frac{96}{80} = -\frac{6}{5}.$$

Покажем, что коэффициент асимметрии и эксцесс распределения Пуассона  $\mathcal{P}(\lambda)$  равны соответственно  $\frac{1}{\sqrt{\lambda}}$  и  $\frac{6}{\lambda}$ .



$$\begin{aligned}
\alpha_k = \mathbb{E}\xi^k &= \sum_{j=1}^{\infty} \frac{j^{k-1}\lambda^j}{(j-1)!} e^{-\lambda} \quad j=t+1 = \lambda \sum_{t=0}^{\infty} \frac{(t+1)^{k-1}\lambda^t}{t!} e^{-\lambda}. \\
&\alpha_1 = \lambda, \quad \alpha_2 = \lambda^2 + \lambda, \\
\alpha_3 &= \lambda(\alpha_2 + 2\alpha_1 + 1) = \lambda(\lambda^2 + \lambda + 2\lambda + 1) = \lambda^3 + 3\lambda^2 + \lambda, \\
\alpha_4 &= \lambda(\alpha_3 + 3\alpha_2 + 3\alpha_1 + 1) = \\
&= \lambda(\lambda^3 + 3\lambda^2 + \lambda + 3\lambda^2 + 3\lambda + 3\lambda + 1) = \lambda^4 + 6\lambda^3 + 7\lambda^2 + \lambda, \\
\mu_3 &= \alpha_3 - 3\alpha_2\alpha_1 + 2\alpha_1^3 = (\lambda^3 + 3\lambda^2 + \lambda) - 3\lambda(\lambda^2 + \lambda) + 2\lambda^3 = \lambda, \\
\mu_4 &= \alpha_4 - 4\alpha_3\alpha_1 + 6\alpha_2\alpha_1^2 - 3\alpha_1^4 = \\
&= (\lambda^4 + 6\lambda^3 + 7\lambda^2 + \lambda) - 4\lambda(\lambda^3 + 3\lambda^2 + \lambda) + 6\lambda^2(\lambda^2 + \lambda) - 3\lambda^4 = \\
&= 3\lambda^2 + \lambda, \\
\gamma_1 &= \frac{\mu_3}{\mu_2^{3/2}} = \frac{\lambda}{\lambda^{3/2}} = \frac{1}{\sqrt{\lambda}}, \quad \gamma_2 = \frac{\mu_4}{\mu_2^2} - 3 = \frac{3\lambda^2 + \lambda}{\lambda^2} - 3 = \lambda^{-1}.
\end{aligned}$$

**Пример домашнего задания, рассчитанного на несколько занятий.** 1) Про моделировать 500 значений случайной величины, имеющей сложно-пуассоновское распределение с параметром  $\lambda = 1$  пуассоновского числа нормально распределенных компонент с параметрами  $\mu = 2, \sigma^2 = 0.24$ . 2) Вычислить закон распределения, теоретические и выборочные характеристики распределения: среднее, дисперсию, асимметрию, эксцесс. 3) Оценить параметры распределения по выборке методом моментов и методом максимального правдоподобия. 4) Проверить согласие с моделью при помощи критерия хи-квадрат.