

Практика №2 ОСНОВНЫЕ ПОНЯТИЯ МАТЕМАТИЧЕСКОЙ СТАТИСТИКИ

Задачи математической статистики

Математическая статистика возникла и создавалась параллельно с теорией вероятностей в XVII в. Дальнейшее развитие математической статистики (вторая половина XIX и начало XX в.) обязано, в первую очередь П. Л. Чебышеву, А. А. Маркову, А. М. Ляпунову и др.

Математическая статистика – раздел математики, который посвящен способам получения выводов из *опытных данных* (результатов наблюдений). Поскольку математическая статистика изучает общие закономерности массовых явлений в абстрактной форме, безразличной к природе рассматриваемых объектов, ее выводы могут быть применены к самым разнообразным явлениям при условии, что в них реально осуществляются основные положения общей теоретической схемы.

Итак, задача математической статистики состоит в создании методов сбора и обработки статистических данных для получения научных и практических выводов.

Отсюда вытекают основные разделы математической статистики.

1. Теория оценок.

Эта теория позволяет приближенно вычислить и оценить параметры случайных величин (математическое ожидание, дисперсию и т.д.) *по данным опыта*.

2. Статистическая проверка гипотез.

Эта теория позволяет проверить справедливость интересующих нас гипотез *по данным опыта*.

3. Дисперсионный анализ.

Эта теория позволяет найти слабые (статистические) зависимости между величинами, т. е. направлена на поиск зависимостей в экспериментальных данных путём исследования значимости различий в средних значениях. В данном пособии будут рассмотрены только первые два раздела.

Выборка из генеральной совокупности.

Вариационный ряд. Гистограмма относительных частот

Определим основные понятия математической статистики. Предположим, что исследуется случайная величина X . Раз за разом воспроизводится опыт, в результате которого случайная величина X принимает какое-то значение. Но закон распределения X нам неизвестен. Как его определить? Очевидно, нет другой возможности, чем раз за разом

проводить опыты, фиксировать значения, которые принимает случайная величина, и пытаться по ряду этих значений определить ее закон распределения, хотя бы приближенный. Совокупность всех значений, которые может принять случайная величина в результате проводимых опытов, называется *генеральной совокупностью* G .

Генеральная совокупность - достаточно большая совокупность однородных объектов, некоторая характеристика которых меняется случайным образом, от объекта к объекту. Наша цель научиться определять, как распределена эта характеристика по всей генеральной совокупности.

Исследовать все элементы генеральной совокупности невозможно и нецелесообразно, т.к. генеральная совокупность может быть очень велика. В связи с этим из генеральной совокупности отбирают определенное число элементов:

$$x_1, x_2, \dots, x_n. \quad (2.1)$$

и их изучают. Результаты исследований показали, что выводы, сделанные по этим элементам, точно характеризуют данное явление. Такой метод называется *выборочным*. Часть объектов, которая попала на проверку, называется *выборочной совокупностью* X или просто *выборкой*.

Число элементов в генеральной совокупности и в выборке будем называть их объемами. Объем генеральной совокупности равен N , а выборки - n . Набор чисел (2.1) называют *элементами выборки* или *вариантами*. Расположенные в порядке возрастания значения x_1, x_2, \dots, x_n образуют ряд, называемый *вариационным рядом*:

$x_{\min}, \dots, x_{\max}$ - вариационный ряд.

Число $R = x_{\max} - x_{\min}$ называется *размахом выборки*.

Для построения вариационного ряда выполним действия:

1. Разделим отрезок $[x_{\min}, x_{\max}]$ на некоторое число l интервалов одинаковой длины $\Delta = \left(\frac{R}{k}\right)$. Величину k приближенно вычисляют по формуле $l = [1 + 3,2 \lg n]$, где n - объём выборки.

$$x_i = x_{i-1} + i\Delta.$$

2. Подсчитаем число элементов выборки, попадающих в каждый интервал:

$$n_1, n_2, \dots, n_m. \quad (2.2)$$

Очевидно, $n_1 + n_2 + \dots + n_m = n$.

Числа (2.2) называются *частотами попадания в интервал*. Составим табл. 22.

Таблица 22

$x_0 - x_1$	$x_1 - x_2$		$x_{n-1} - x_n$
n_i	n_1		n_m
$\omega_i = \frac{n_i}{n}$	$\frac{n_1}{n}$		$\frac{n_m}{n}$

Элементы третьей строки называются *относительными частотами попадания в интервал*. Очевидно, $\frac{n_1}{n} + \frac{n_2}{n} + \dots + \frac{n_m}{n} = 1$.

Полученная таблица называется *выборочным распределением случайной величины X*.

3) Изобразим выборочное распределение на графике (рис. 2.1). Для этого на оси OX отложим интервалы $x_i - x_{i+1}$ и на каждом из них как на основании построим прямоугольник, площадь которого ω_i , т.е. высота i -го прямоугольника $\frac{\omega_i}{\Delta}$.

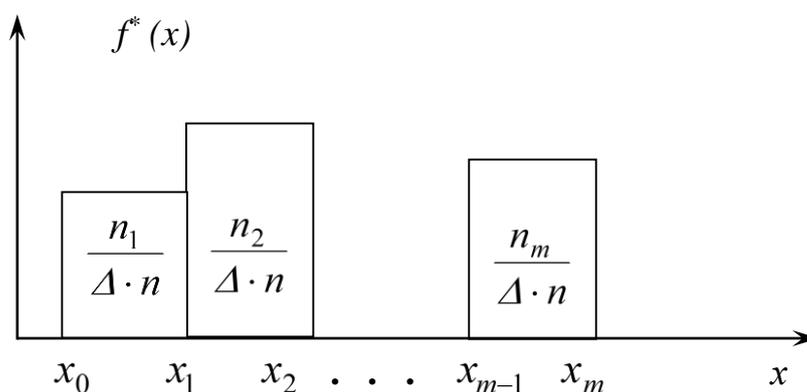


Рис. 2.1. Гистограмма относительных частот

Построенный график называется *гистограммой относительных частот* и представляет собой *выборочный аналог* плотности вероятности случайной величины. Площадь гистограммы равна единице.

Пример 1.

При проведении 20-ти серий из 10-ти бросков игральной кости число выпадений шести очков оказалось равным 1,1,4,0,1,2,1,2,2,0,5,3,3,1,0,2,2,3,4,1. Составим вариационный ряд: 0,1,2,3,4,5. Статистический ряд для абсолютных и относительных частот имеет вид табл. 23.

Таблица 23

x_i	0	1	2	3	4	5
-------	---	---	---	---	---	---

n_i	3	6	5	3	2	1
$\omega_i = \frac{n_i}{n}$	$\frac{3}{20}$	$\frac{6}{20}$	$\frac{5}{20}$	$\frac{3}{20}$	$\frac{2}{20}$	$\frac{1}{20}$

Числовые характеристики статистического распределения: выборочное среднее, дисперсия

4.1. Параметры распределения

Одна из задач математической статистики: по имеющейся выборке оценить значения числовых характеристик исследуемой случайной величины. Основными числовыми характеристиками выборки являются выборочное среднее \bar{x}_g и выборочная дисперсия D_g .

Определение. *Выборочным средним* называется среднее арифметическое значений случайной величины, принимаемых в выборке:

$$\bar{x}_g = \frac{x_1 + \dots + x_n}{n} \text{ или } \bar{x}_g = \frac{\sum_{i=1}^l x_i n_i}{n}. \quad (2.3)$$

Выборочное среднее \bar{x}_g служит для точечной оценки математического ожидания $M(X)$ исследуемой случайной величины

$$\bar{x} = \frac{x_1 + \dots + x_n}{n}$$

Определение. *Выборочной дисперсией* называется

$$D_g(X) = \frac{\sum_{i=1}^l (x_i - \bar{x}_g)^2 \cdot n_i}{n} = \frac{\sum_{i=1}^l x_i^2 \cdot n_i}{n} - \bar{x}_g^2. \quad (2.4)$$

Выборочная дисперсия $D_g(X)$ служит для точечной оценки дисперсии $D(X)$.

В отличие от выборочного среднего, выборочная дисперсия является смещенной оценкой дисперсии генеральной совокупности. Пользуясь оценкой D_g вместо D , мы будем совершать некоторую систематическую ошибку, так как её математическое ожидание несколько меньше истинного значения. Чтобы её ликвидировать, достаточно ввести поправку, умножив D_g на $\frac{n}{n-1}$. Таким образом,

можно предложить другую оценку дисперсии – *исправленную дисперсию* s^2 , вычисляемую по формуле $s^2 = \frac{n}{n-1} D_g = \frac{\sum_{i=1}^l (x_i - \bar{x}_g)^2 n_i}{n-1}$. Эта оценка

является состоятельной несмещенной оценкой дисперсии D .

Такая оценка будет являться *несмещенной*. Ей соответствует *исправленное среднее квадратическое отклонение (СКО)*

$$s = \sqrt{s^2} = \sqrt{\frac{\sum_{i=1}^l (x_i - \bar{x}_g)^2 n_i}{n-1}}. \quad (2.5)$$

При больших n поправка $\frac{n}{n-1}$ становится близкой к единице и её применение теряет смысл.

Пример 1. Оптический пирометр установлен на светящуюся нить накала, различными операторами было произведено несколько измерений температуры. Получены следующие результаты (табл.25).

Таблица 25

Температура, °C	925	950	975	1000	1025	500
Число измерений	1	9	6	18	10	2

Требуется найти среднюю квадратическую и вероятную ошибки в предположении, что эта выборка взята из нормально распределенной совокупности.

Решение. Найдем сначала выборочное среднее значение \bar{x}_g .

Проще находить среднее для $1000 - x$, а не для x (табл. 26).

Таблица 26

$1000-x_i$	Число измерений n	$n \cdot (1000-x_i)$	$(1000-x_i)^2$	$n \cdot (1000-x_i)^2$
1	2	3	4	5
75	1	75	5625	5625
50	9	450	2500	22500
25	6	150	625	3750
0	18	0	0	0
-25	10	-250	625	6250
-50	2	-100	2500	5000
$\sum_{i=1}^l$	46	325	—	43125

$$1000 - \bar{x}_g = \frac{\sum_{i=1}^l x_i n_i}{n} = \frac{325}{46} = 7,1 \text{ или } \bar{x}_g = 1000 - 7,1 = 992,9^\circ.$$

$$D_g(X) = \frac{\sum_{i=1}^l x_i^2 \cdot n_i}{n} - \bar{x}_g^2 = \frac{43125}{46} - 7,1^2 = 887.$$

Найдем исправленную дисперсию s^2 ,

$$s^2 = \frac{n}{n-1} D_e = \frac{46}{45} \cdot 887 = 906,7 \text{ } ^\circ\text{C}.$$

Статистическая проверка статистических гипотез

Сопоставление высказанной гипотезы относительно генеральной совокупности с имеющимися выборочными данными, сопровождаемое количественной оценкой степени достоверности получаемого вывода и осуществляемое с помощью того или иного статистического критерия, называется проверкой статистических гипотез.

Определение. *Статистической гипотезой* называют гипотезу о виде неизвестного распределения генеральной совокупности или о параметрах известных распределений.

Определение. *Нулевой (основной)* называют выдвинутую гипотезу H_0 . *Конкурирующей (альтернативной)* называют гипотезу H_1 , которая противоречит нулевой.

Если выдвигаемая гипотеза сводится к утверждению о том, что значение некоторого неизвестного параметра генеральной совокупности в точности равно заданной величине, то эта гипотеза называется простой. В других случаях гипотеза называется сложной.

Выдвинутая нулевая гипотеза может быть правильной или неправильной, поэтому возникает необходимость статистической проверки справедливости основной гипотезы H_0 (табл.27).

Таблица 27

Нулевая гипотеза H_0	Результаты решения относительно H_0	
	Отклонена	Принята
Верна	Ошибка 1-го рода, её вероятность $P(H_1/H_0) = \alpha$	Правильное решение, его вероятность $P(H_0/H_0) = 1 - \alpha$
Неверна	Правильное решение, его вероятность $P(H_1/H_1) = 1 - p$	Ошибка 2-го рода, её вероятность $P(H_0/H_1) = p$

Так как проверка статистических гипотез осуществляется на основании выборочных данных, то решение неизбежно сопровождается вероятностью ошибочного заключения как в ту, так и в другую сторону.

В какой-то небольшой доле случаев нулевая гипотеза может оказаться отвергнутой, в то время как она справедлива. Такую ошибку называют *ошибкой первого рода*, а её вероятность – *уровнем значимости* α . Другими словами это та вероятность, которой можно пренебречь.

Наоборот, в какой-то небольшой доле случаев нулевая гипотеза принимается, в то время как на самом деле она ошибочна. Такую ошибку

называют *ошибкой второго рода*. Вероятность ошибки второго рода p . Вероятность $1-p$ называют мощностью критерия.

Для проверки нулевой гипотезы пользуются специально подобранной случайной величиной, распределение которой известно. В общем случае её обозначают K – критерий согласия, устанавливающий, когда полученное в действительности указанное отклонение следует принять несущественным, а когда существенным. Критерий K является функцией от результатов наблюдения.

Критерий Пирсона для проверки гипотезы о виде закона распределения случайной величины

С помощью критерия Пирсона можно проверять гипотезы о различных законах распределения. Для данного критерия в качестве величины, характеризующей степень различия между теоретическим и выборочным законами распределения, выбирается статистика

$$K = \chi^2 = \sum_{i=1}^l \frac{(n_i - n_i^*)^2}{n_i}, \quad (2.8)$$

которая учитывает расхождения между теоретическими n_i и выборочными n_i^* частотами. Эта случайная величина называется χ^2 («хи квадрат») статистикой Пирсона. Смысл ее очевиден: суммируются квадраты отклонений эмпирических частот от теоретических. Целью исследования является сравнение эмпирических и теоретических частот, которые, конечно, отличаются друг от друга, и выяснить, являются ли эти различия несущественными, не опровергающими гипотезу о выбранном законе распределения исследуемой случайной величины, или они настолько велики, что противоречат этой гипотезе.

Можно доказать, что вне зависимости от реального закона распределения генеральной совокупности, закон распределения случайной величины при $n \rightarrow \infty$ стремится к закону распределения с числом степеней свободы $k = l - 1 - r$, где r – число параметров предполагаемого распределения, оцененных по данным выборки, l – число интервалов. Для выбранного критерия строится критическая область, определяемая условием

$$P(\chi_{\text{выб.}}^2 < \chi_{\text{крит}}^2(l; \alpha)) = \alpha,$$

где α – уровень значимости. Следовательно, критическая область задается неравенством $\chi_{\text{выб.}}^2 < \chi_{\text{крит}}^2(l; \alpha)$ а область принятия гипотезы

$$\chi_{\text{выб.}}^2 < \chi_{\text{крит}}^2(l; \alpha).$$

Таким образом, для проверки нулевой гипотезы H_0 генеральная совокупность распределена по выбранному закону – нужно вычислить по

выборке наблюдаемое значение критерия:

$$\chi_{\text{выб.}}^2 = \sum_{i=1}^l \frac{(n_i - n_i^*)^2}{n_i},$$

а по таблице критических точек распределения χ^2 найти критическую точку $\chi_{\text{крит}}^2(l; \alpha)$, используя известные значения α и $k = l - 1 - r$.

Если $\chi_{\text{выб.}}^2 < \chi_{\text{крит}}^2(k; \alpha)$ нулевую гипотезу принимают, при $\chi_{\text{выб.}}^2 > \chi_{\text{крит}}^2(k; \alpha)$ ее отвергают.

Замечание. Число параметров распределения r , оцененных по данным выборки для нормального и равномерного распределений равно двум, а для показательного – одному.

Из вышесказанного следует, что для проверки данной гипотезы H_0 необходимо найти теоретические и эмпирические частоты.

Пусть получена выборка достаточно большого объема n с большим количеством различных значений вариантов. Для удобства её обработки разделим интервал от наименьшего до наибольшего из значений вариантов на k равных частей по методике, предложенной выше. Будем считать, что значения вариантов, попавших в каждый интервал, приближенно равны числу, задающему середину интервала. Подсчитав число вариантов, попавших в каждый интервал, составим так называемую сгруппированную выборку (табл. 28).

Таблица 28

варианты \bar{x}_i	\tilde{x}_1	\tilde{x}_1	...		\tilde{x}_k
частоты n_i	n_1	n_2	...		n_k

Примечание. $\tilde{x}_i = \frac{x_i + x_{i+1}}{2}$ – значения середин интервалов, а n_i – число вариант, попавших в i -й интервал (эмпирические частоты).

По полученным данным можно вычислить выборочное среднее \bar{x}_g и выборочное среднее квадратическое отклонение σ_g . Тип закона определим по построенной гистограмме или из общих соображений. Например, ошибки измерений в основном распределены по нормальному закону, а надежность безотказной работы прибора – по показательному. Для проверки предположения, что генеральная совокупность распределена по выбранному закону с параметрами $M(X) = \bar{x}_g$; $D(X) = \sigma_g^2$, необходимо вычислить теоретические частоты по формуле

$$n_i = p_i \cdot n,$$

где $p_i = p_i(x_i < X < x_{i+1}) = \int_{x_i}^{x_{i+1}} f(x)dx$ – вероятность попадания в i -й интервал, n – объем выборки.

Здесь и далее $f(x)$ – функция плотности распределения вероятностей случайной величины X , выбранного закона распределения. Для простоты вычислений можно воспользоваться приближенной формулой вычисления определенного интеграла

$$p_i = p_i(x_i < X < x_{i+1}) = \int_{x_i}^{x_{i+1}} f(x)dx = f(\tilde{x}_i) \cdot (x_{i+1} - x_i) = f(\tilde{x}_i) \cdot h, \quad (2.9)$$

где $\tilde{x}_i = \frac{x_i + x_{i+1}}{2}$.

Рассмотрим практические приёмы нахождения теоретических вероятностей и теоретических частот для основных законов распределения.

1. Нормальный закон распределения.

Функция плотности распределения задается формулой

$$f(x) = \frac{1}{\sigma_g \sqrt{2\pi}} \cdot e^{-\frac{(x-\bar{x}_g)^2}{2\sigma_g^2}} = \frac{1}{\sigma_g} \cdot \varphi\left(\frac{x-\bar{x}_g}{\sigma_g}\right).$$

График функции $f(x)$ называют нормальной кривой или кривой Гаусса (рис. 2.3).

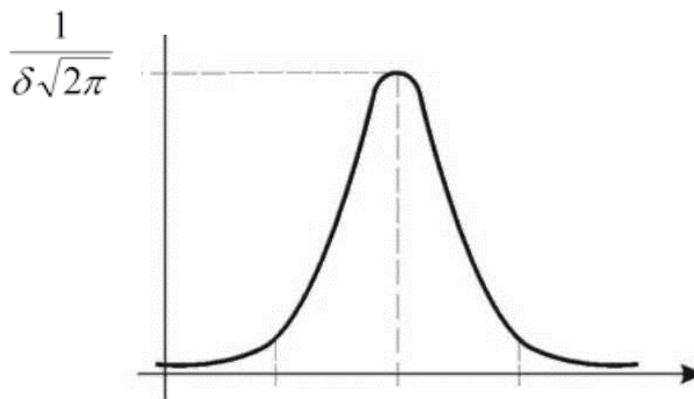


Рис. 2.3. Кривая Гаусса

Тогда вероятности p_i вычисляются по формуле

$$p_i = p_i(x_i < X < x_{i+1}) = \int_{x_i}^{x_{i+1}} f(x)dx = \Phi\left(\frac{x_{i+1} - \bar{x}_g}{\sigma_g}\right) - \Phi\left(\frac{x_i - \bar{x}_g}{\sigma_g}\right),$$

где $\Phi(x) = \frac{1}{\sqrt{2\pi}} \int_0^x e^{-\frac{z^2}{2}} dz$ – функция Лапласа, её значения находят по прил.

2.

Чаще всего пользуются приближенной формулой

$$p_i = p_i(x_i < X < x_{i+1}) = \int_{x_i}^{x_{i+1}} f(x) dx = \frac{1}{\sigma_\epsilon} \cdot \varphi\left(\frac{\tilde{x}_i - \bar{x}_\epsilon}{\sigma_\epsilon}\right) \cdot \Delta,$$

где $\varphi(x) = \frac{1}{\sqrt{2\pi}} \cdot e^{-\frac{x^2}{2}}$ – табулированная функция (см. прил. 1).

Умножив полученные вероятности на объем выборки n , найдем теоретические частоты: $n_i = p_i \cdot n$.

2. Равномерный закон распределения.

При использовании критерия Пирсона для проверки гипотезы о равномерном распределении генеральной совокупности с предполагаемой плотностью вероятности

$$f(x) = \begin{cases} 0, & x \notin [a, b]; \\ \frac{1}{b-a}, & x \in [a, b]. \end{cases}$$

необходимо, вычислив по имеющейся выборке значения \bar{x}_ϵ и σ_ϵ^2 , оценить параметры a и b .

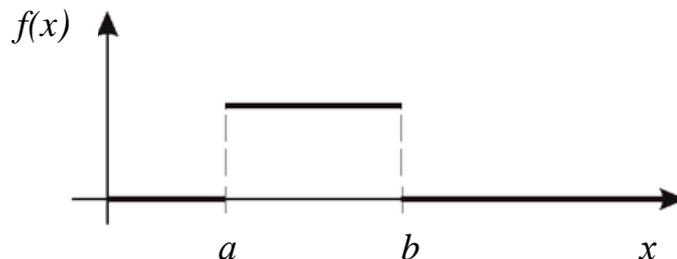


Рис. 2.4. График функции плотности равномерного распределения

Действительно, так как для равномерного распределения $M(X) = \frac{a+b}{2}$ и $\sigma(X) = \sqrt{D(X)} = \sqrt{\frac{(a-b)^2}{12}} = \frac{a-b}{2\sqrt{3}}$, то оценки параметров a и b – концов интервала, в котором наблюдались возможные значения случайной величины X , находим из системы (2.10), где через a^* и b^* обозначены оценки соответствующих параметров равномерного распределения.

$$\begin{cases} \frac{b^* + a^*}{2} = \bar{x}_g; \\ \frac{b^* - a^*}{2\sqrt{3}} = \sigma_g. \end{cases} \quad (2.10)$$

Решая систему уравнений, получим

$$a^* = \bar{x}_g - \sqrt{3}\sigma_g, \quad b^* = \bar{x}_g + \sqrt{3}\sigma_g.$$

Тогда теоретическое распределение будет иметь вид

$$f(x) = \begin{cases} 0, & x \notin [a^*, b^*]; \\ \frac{1}{b^* - a^*}, & x \in [a^*, b^*]. \end{cases}$$

Вероятности p_i вычисляются по формуле:

$$p_i = p_i(x_i < X < x_{i+1}) = \int_{x_i}^{x_{i+1}} f(x) dx = \int_{x_i}^{x_{i+1}} \frac{1}{b^* - a^*} dx = \frac{x_{i+1} - x_i}{b^* - a^*} = \frac{\Delta}{b^* - a^*}.$$

Умножив полученные вероятности на объем выборки n , найдем теоретические частоты: $n_i = p_i \cdot n$.

3. Показательный закон распределения.

Функция плотности определяется формулой

$$f(x) = \begin{cases} 0, & x < 0; \\ \lambda e^{-\lambda x}, & x \geq 0. \end{cases}$$

Вычислив по имеющейся выборке значения \bar{x}_g и σ_g^2 , необходимо оценить параметр λ . Для показательного распределения $M(X) = \frac{1}{\lambda}$. Следовательно, в качестве оценки параметра λ возьмём величину $\lambda^* = \frac{1}{\bar{x}_g}$.

. Тогда теоретическое распределение будет иметь вид

$$f(x) = \begin{cases} 0, & x < 0; \\ \frac{1}{\bar{x}_g} e^{-\frac{1}{\bar{x}_g} x}, & x \geq 0. \end{cases}$$

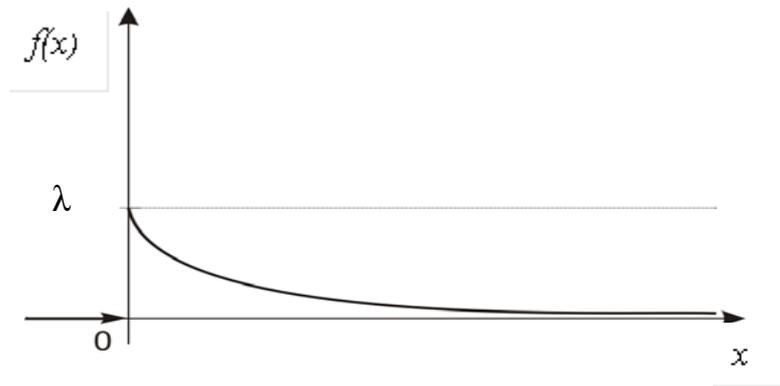


Рис. 2.5. График функции плотности равномерного распределения

Вероятности p_i вычисляются по формуле

$$p_i = P(x_i < X < x_{i+1}) = \int_{x_i}^{x_{i+1}} f(x) dx = \int_{x_i}^{x_{i+1}} \frac{1}{\bar{x}_g} e^{-\frac{1}{\bar{x}_g} x} dx = e^{-\frac{1}{\bar{x}_g} x_i} - e^{-\frac{1}{\bar{x}_g} x_{i+1}}$$

Чаще всего пользуются приближенной формулой

$$p_i = P(x_i < X < x_{i+1}) = \int_{x_i}^{x_{i+1}} f(x) dx = \frac{1}{\bar{x}_g} e^{-\frac{1}{\bar{x}_g} \tilde{x}_i} \cdot \Delta,$$

где $\tilde{x}_i = \frac{x_i + x_{i+1}}{2}$.

Тогда теоретические частоты вычисляются по формуле

$$n_i = p_i \cdot n,$$

где n – объем выборки.

Примеры проверки гипотез о законе распределения выборочных данных

Задача 7.

В ходе проведения эксперимента получен следующий набор данных:

55,42	67,49	57,71	64,59	56,01	70,97	71,53	47,66	67,70	82,75
40,89	29,04	59,59	97,18	51,00	67,15	62,16	52,77	53,26	33,04
68,22	96,22	46,60	51,25	58,66	65,12	67,98	61,10	60,44	65,73
53,19	69,11	71,90	71,24	83,94	74,64	73,35	50,80	75,48	59,12
89,03	60,87	60,01	46,90	54,85	27,21	72,91	45,28	49,57	44,11
67,54	78,21	54,19	65,35	26,81	70,84	34,52	60,96	76,75	63,58
93,89	44,32	54,91	48,84	63,08	68,11	71,08	72,17	80,42	59,43
55,41	70,35	62,28	22,61	63,95	100,46	54,59	79,99	41,43	63,39
80,67	62,73	48,82	38,49	77,63	52,98	62,16	43,78	65,55	56,26
42,33	58,28	51,16	83,50	45,74	49,66	53,69	54,96	67,58	79,60

Пусть случайная величина X –наугад взятое значение из набора данных. Требуется для случайной величины X :

- 1..Составить выборочное распределение.
2. Построить гистограмму и график выборочной функции распределения.
3. Найти состоятельные несмещенные оценки математического ожидания и дисперсии.
4. Построить доверительные интервалы для математического ожидания и дисперсии с уровнем доверия $p=0,95$.
5. На основании анализа формы построенной гистограммы выдвинуть гипотезу о законе распределения и проверить справедливость гипотезы по критерию Пирсона с уровнем значимости $\alpha=0,05$.

Решение.

1. *Первым этапом статистического изучения вариации являются построение вариационного ряда - упорядоченного распределения единиц совокупности по возрастающим (чаще) или по убывающим (реже) значениям признака и подсчет числа единиц с тем или иным значением признака. Для этого сначала построим ранжированный ряд. Ранжированный ряд — это перечень отдельных единиц совокупности в порядке возрастания (убывания) изучаемого признака.*

22,61	43,78	49,57	53,69	57,71	61,10	65,12	68,11	72,17	80,42
26,81	44,11	49,66	54,19	58,28	62,16	65,35	68,22	72,91	80,67
27,21	44,32	50,80	54,59	58,66	62,16	65,55	69,11	73,35	82,75
29,04	45,28	51,00	54,85	59,12	62,28	65,73	70,35	74,64	83,50
33,04	45,74	51,16	54,91	59,43	62,73	67,15	70,84	75,48	83,94
34,52	46,60	51,25	54,96	59,59	63,08	67,49	70,97	76,75	89,03
38,49	46,90	52,77	55,41	60,01	63,39	67,54	71,08	77,63	93,89
40,89	47,66	52,98	55,42	60,44	63,58	67,58	71,24	78,21	96,22
41,43	48,82	53,19	56,01	60,87	63,95	67,70	71,53	79,60	97,18
42,33	48,84	53,26	56,26	60,96	64,59	67,98	71,90	79,99	100,46

Интервальным вариационным рядом называется упорядоченная совокупность интервалов варьирования значений случайной величины с соответствующими частотами или частностями попаданий в каждый из них значений величины.

Для его построения выполняем следующие действия:

1. Находим размах выборки

$$R = x_{\text{наиб}} - x_{\text{наим}} = 100,46 - 22,61 = 77,85$$

2. Назначаем число частичных интервалов k :

$$k = 1 + 3,322 \ln n.$$

Обычно $k = 9 \div 12$. Выберем $k=12$

- 3.Находим длину Δ (шаг разбиения):

$$\Delta = \frac{R}{k}, \Delta = \frac{77.85}{12} = 6.5, a_1 = 22.61$$

4. Численность отдельной группы сгруппированного ряда опытных данных называется выборочной частотой. Обозначается:

m_i^* – выборочная частота.

$$\sum_{i=1}^k m_i^* = 1$$

Относительная выборочная частота-отношение выборочной частоты данных вариантов к объёму выборки. Обозначается:

p_i^* – относительная выборочная частота.

$$p_i^* = \frac{m_i^*}{n}, \text{ где } i \text{ – номер варианты.}$$

Выборочная относительная частота сходится по вероятности к соответствующей вероятности.

$$\sum_{i=1}^k p_i^* = 1$$

5. Составляем таблицу.

i	$[a_i; a_{i+1}]$	m_i^*	p_i^*	$h_i^* = \frac{p_i^*}{\Delta}$	$\tilde{x}_i = \frac{a_i + a_{i+1}}{2}$
1	22,61-29,11	4	0,04	0,006	25,86
2	29,11-35,61	2	0,02	0,003	32,36
3	35,61-42,11	3	0,03	0,005	38,86
4	42,11-48,61	9	0,09	0,014	45,36
5	48,61-55,11	18	0,18	0,028	51,86
6	55,11-61,61	15	0,15	0,023	58,36
7	61,61-68,11	20	0,2	0,03	64,86
8	68,11-74,61	12	0,12	0,018	71,36
9	74,61-81,11	9	0,09	0,014	77,86
10	81,11-87,61	3	0,03	0,005	84,36
11	87,61-94,11	2	0,02	0,003	90,86
12	94,11-100,61	3	0,03	0,005	97,36
		$\Sigma = 100$	$\Sigma = 1$		

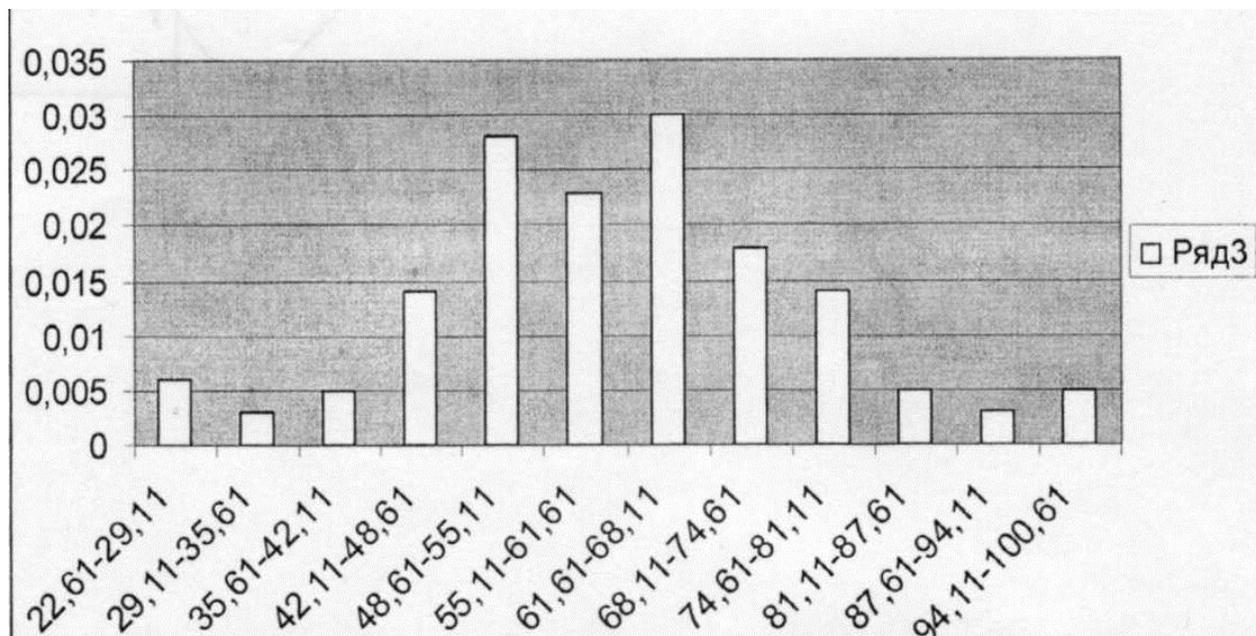
Где h_i^* – плотность относительной частоты;

\tilde{x}_i – середина частичных интервалов.

2. Построение гистограммы плотностей относительных частот.

Гистограмма относительных частот — это фигура, состоящая из прямоугольников, опирающихся на интервалы группировки с высотами равными $h_i^* = \frac{p_i^*}{\Delta}$. Площадь всей гистограммы должна быть равна 1.

Гистограмма является оценкой генеральной функции плотности $f(x)$.



По виду гистограммы мы подбираем подходящий для данного случая теоретический закон распределения:

Сравниваем гистограмму с теоретическими кривыми основных законов (нормальный, показательный, равномерный).

По виду гистограммы можно выдвинуть гипотезу о нормальном законе случайной величины X .

3. *Нахождение состоятельных несмещенных оценок математического ожидания и дисперсии. Найдем оценки математического ожидания a^* и дисперсии D^* .*

Основными параметрами генеральной совокупности являются математическое ожидание (генеральная средняя) $M(X)$ и среднее квадратическое отклонение s . Это постоянные величины, которые можно оценить по выборочным данным. Оценка генерального параметра, выражаемая одним числом, называется точечной.

Точечной оценкой генеральной средней a является выборочное среднее. Выборочным средним называется среднее арифметическое всех значений величины, встречающихся в выборке.

Если выборочное среднее вычисляется по не сгруппированным данным, то для его определения сумму всех значений делят на количество элементов в выборке. В данном случае определяем по сгруппированным данным (см. табл.):

$$a^* = \bar{x} = \frac{\sum_{i=1}^k \tilde{x}_i \cdot m_i^*}{n} = \frac{6083}{100} = 60.83,$$

$$D^* = \bar{s}^2 = \frac{\sum_{i=1}^k (\tilde{x}_i - \bar{x})^2 \cdot m_i^*}{n} = \frac{23387.9}{99} = 236.24,$$

$$\bar{s} = \sqrt{\bar{s}^2} = \sqrt{236.24} = 15.37.$$

$(\tilde{x}_i - \bar{x})^2 \cdot m_i^*$	$\tilde{x}_i \cdot m_i^*$
4891,6	103,44
1621,08	64,72
1448,04	116,58
2153,89	408,24
1448,3	933,48
91,51	875,4
324,82	1297,2
1330,57	856,32
2610,19	700,74
1660,98	253,08
1803,60	181,72
4003,32	292,08
$\Sigma = 23387.9$	$\Sigma = 6083$

$$a \approx \bar{x}, \quad \sigma \approx \bar{s}.$$

4. Построим доверительные интервалы для математического ожидания и дисперсии.

Найдем доверительный интервал для оценки с надежностью $\gamma = 0,95$ неизвестного математического ожидания $M(x)$ нормально распределенного признака X генеральной совокупности, если генеральное стандартное отклонение $\bar{s} = 15,37$, выборочная средняя $\bar{x} = 60,83$, объем выборки $n = 100$.

Требуется найти доверительный интервал

$$\bar{x} - t \times \frac{\bar{s}}{\sqrt{n}} < M(x) < \bar{x} + t \times \frac{\bar{s}}{\sqrt{n}}$$

Все величины, кроме t , известны. Найдем t из соотношения

$$\Phi(t) = \frac{\gamma}{2} = \frac{0,95}{2} = 0,475$$

По таблице находим $t = 1,96$.

Подставив $t = 1,96$, $\bar{x} = 60,83$, $\bar{s} = 15,37$, $n = 100$, окончательно получим доверительный интервал

Для $M(x)$:

$$J_{\gamma} = \left(\bar{x} - t \cdot \frac{\bar{s}}{\sqrt{n}}; \bar{x} + t \cdot \frac{\bar{s}}{\sqrt{n}} \right),$$

$$J_{\gamma} = (60.1; 61.56).$$

Для $D(x)$:

$$J_{\gamma} = \left(\bar{s}^2 - t \cdot \sigma_{\bar{s}^2}; \bar{s}^2 + t \cdot \sigma_{\bar{s}^2} \right), \quad J_{\gamma} = (220.33; 252.15).$$

$$\sigma_{\bar{s}^2} = \sqrt{\frac{2}{n-1} \cdot \bar{s}^2} = 33.5.$$

5. Построенная гистограмма по форме напоминает график плотности вероятности нормального распределения. Поэтому естественно выдвинуть гипотезу о нормальном распределении случайной величины X . Проверим справедливость выдвинутой гипотезы по критерию Пирсона с уровнем значимости $\alpha=0,05$. Тогда гипотетическая функция плотности распределения случайной величины X имеет вид:

$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-a)^2}{2\sigma^2}}$$

Нормальный закон распределения также называется законом Гаусса.

Нормальный закон распределения занимает центральное место в теории вероятностей. Это обусловлено тем, что этот закон проявляется во всех случаях, когда случайная величина является результатом действия большого числа различных факторов. К нормальному закону приближаются все остальные законы распределения.

Можно легко показать, что параметры a и σ , входящие в плотность распределения являются соответственно математическим ожиданием и средним квадратическим отклонением случайной величины X .

График плотности нормального распределения называется нормальной кривой или кривой Гаусса.

Нормальная кривая обладает следующими свойствами:

- Функция определена на всей числовой оси.

- $f(x) > 0$
- Ось ОХ является горизонтальной асимптотой графика плотности вероятности, т.к. при неограниченном возрастании по абсолютной величине аргумента x , значение функции стремится к нулю.
- $f(x)$ достигает \max в точке $x-a$;

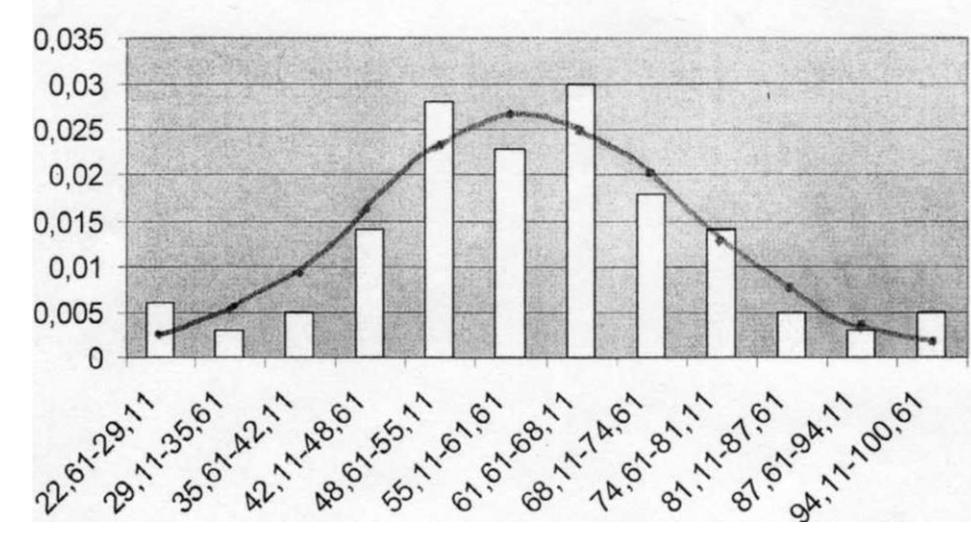
$$f(x) = \frac{1}{\sigma\sqrt{2\pi}} \cdot e^{-\frac{(x-a)^2}{2\sigma^2}} = \frac{1}{\sigma} \cdot \varphi\left(\frac{x-a}{\sigma}\right)$$

График функции имеет две точки перегиба $x = a \pm \sigma$

Для простоты вычислений составим таблицу:

i	$t_i = \frac{\tilde{x}_i - a^*}{\sigma^*}$	$\varphi(t_i)$	$f(\tilde{x}_i) = \frac{\varphi(t_i)}{\sigma^*}$	$p_i = f(\tilde{x}_i) \cdot \Delta$
1	-2,28	0,03	0,002	0,013
2	-1,85	0,072	0,005	0,033
3	-1,43	0,144	0,009	0,059
4	-1,01	0,24	0,016	0,104
5	-0,58	0,337	0,022	0,143
6	-0,16	0,394	0,026	0,169
7	0,26	0,386	0,025	0,163
8	0,69	0,314	0,02	0,13
9	1,11	0,216	0,014	0,091
10	1,53	0,124	0,008	0,052
11	1,95	0,06	0,004	0,026
12	2,38	0,024	0,002	0,013
				$\Sigma = 0,0996$

Функцию плотности $f(\tilde{x}_i) = \frac{\varphi(t_i)}{\sigma^*}$ изобразим на гистограмме.



Критерий Пирсона - основан на изучении меры расхождения между теоретическим и статистическим распределением, которая в данном случае оценивается по сумме квадратов разности этих расхождений по всем интервалам выборки с учётом «веса» сл. в. $n \cdot p_i$.

Пирсон доказал, что значения статистического критерия не зависят от функции распределения $f(x)$ и от числа опытов n , а зависят от числа частичных интервалов r интервального вариационного ряда.

Далее используем правило проверки гипотезы по критерию Пирсона.

1. Вычисляем квантиль $\chi_p^2(r-l-1)$. Для её вычисления нужно воспользоваться табличными распределениями χ^2 , в которых значения сл. в. находят по заданному уровню значимости α и вычисленному числу свободы ν .

$$\nu = r - l - 1 = 8 - 2 - 1 = 5, \text{ где}$$

r - число частичных интервалов. Если в некоторых из интервалов значения $m_i^* < 5$, то надо объединить расположенные рядом интервалы так, чтобы $m_i^* > 5$ или $m_i^* = 5$, тогда число r - число из необъединённых интервалов, l число неизвестных параметров.

$$\text{Имеем } p=1-\alpha=0,95, m=8, l=2.$$

По таблице распределения χ^2 находим

$$\chi_{0,95}^2(8-2-1) = \chi_{0,95}^2(5) = 11,1.$$

2. Находим $X_{\text{выбор.}}^2$ по формулам:

$$X_{\text{выбор.}}^2 = \frac{\sum_{i=1}^R (n \cdot p_i^* - n \cdot p)^2}{n \cdot p_i}, \text{ или } X_{\text{выбор.}}^2 = \frac{\sum_{i=1}^R (m_i^* - m_i)^2}{m_i}.$$

i	p_i^*	$n \cdot p_i^*$	$n \cdot p_i$	$(n \cdot p_i^* - n \cdot p_i)$	$(n \cdot p_i^* - n \cdot p_i)^2$	$\frac{(n \cdot p_i^* - n \cdot p_i)^2}{n \cdot p_i}$
1	0,09	9	10,5	-1,5	2,25	0,2
2	0,09	9	10,4	-1,4	1,96	0,2
3	0,18	18	14,3	3,7	13,69	0,96
4	0,15	15	16,9	-1,9	3,61	0,2
5	0,2	20	16,3	3,7	13,69	0,8
6	0,12	12	13	-1	0,01	0,001

7	0,09	9	9,1	-0,1	0,01	0,001
8	0,08	8	9,1	-1,1	1,21	0,133
						$\Sigma = X_{\text{выбор.}} = 2.495$

Для этого удобно результаты вычислений вносить в следующую таблицу

3. Окончательно имеем

$2.495 = X_{\text{выбор.}}^2 < X_{0.95}^2 = 11.1$. что означает: гипотезу о нормальном распределении случайной величины X принимаем, т. к.