

# Основы математической статистики

## Лекция 3

# Задачи математической статистики

- Установление закономерностей, которым подчинены массовые случайные явления, основано на изучении методами теории вероятностей статистических данных — результатов наблюдений.

- Первая задача математической статистики — указать способы сбора и группировки статистических сведений, полученных в результате наблюдений или в результате специально поставленных экспериментов.
- Вторая задача математической статистики — разработать методы анализа статистических данных в зависимости от целей исследования.

- Задача математической статистики состоит в создании методов сбора и обработки статистических данных для получения научных и практических выводов.

# Генеральная и выборочная совокупности

- *Выборочной совокупностью* или просто *выборкой* называют совокупность случайно отобранных объектов.
- *Генеральной совокупностью* называют совокупность объектов, из которых производится выборка.
- *Объемом совокупности* (выборочной или генеральной) называют число объектов этой совокупности.

# Пример

- Если из 1000 деталей отобрано для обследования 100 деталей, то объем генеральной совокупности  $N = 1000$ , а объем выборки  $n = 100$ .

# Повторная и бесповторная выборки.

## Репрезентативная выборка

- *Повторной* называют выборку, при которой отобранный объект (перед отбором следующего) возвращается в генеральную совокупность.
- *Бесповторной* называют выборку, при которой отобранный объект в генеральную совокупность не возвращается. На практике обычно пользуются бесповторным случайным отбором.

- Свойства объектов выборки должны правильно отражать свойства объектов генеральной совокупности, или, как говорят, выборка должна быть *репрезентативной* (представительной).  
Считается, что выборка репрезентативна, если все объекты генеральной совокупности имеют одинаковую вероятность попасть в выборку, т. е. выбор осуществляется *случайно*.



# Статистическое распределение выборки

- Пусть из генеральной совокупности извлечена выборка, причем  $x_1$  наблюдалось  $n_1$  раз,  $x_2$  —  $n_2$  раз, ...,  $x_k$  —  $n_k$  раз и  $n_1 + n_2 + \dots + n_k = n$  — объем выборки. Наблюдаемые значения  $x_1, x_2, \dots, x_k$  называются *вариантами*, а последовательность вариантов, записанная в возрастающем порядке — *вариационным рядом*.

- Числа наблюдений  $n_1, n_2, \dots, n_k$  называют частотами, а их отношения к объему выборки  $\frac{n_1}{n} = p_1^*, \frac{n_2}{n} = p_2^*, \dots, \frac{n_k}{n} = p_k^*$  — относительными частотами. Отметим, что сумма относительных частот равна единице:

$$p_1^* + p_2^* + \dots + p_k^* = \frac{n_1}{n} + \frac{n_2}{n} + \dots + \frac{n_k}{n} = \frac{n_1 + n_2 + \dots + n_k}{n} = \frac{n}{n} = 1$$

- *Статистическим распределением* выборки называют перечень вариантов и соответствующих им частот или относительных частот. Статистическое распределение можно задать также в виде последовательности интервалов и соответствующих им частот (*непрерывное распределение*). В качестве частоты, соответствующей интервалу, принимают сумму частот вариантов, попавших в этот интервал.

# Пример

- Дана выборка:
- 12,2,6,2,6,12,6,2,6,12,6,6,12,12,12,6,6,12,6,6
- Составить вариационный ряд и статистическое распределение

# Решение

- Составим вариационный ряд:
- 2,2,2,6,6,6,6,6,6,6,6,6,6,6,12,12,12,12,12,12,12
- Создадим статистическое распределение:

Варианта $x_i$	2	6	12
Частота $n_i$	3	10	7

# Пример

- Задано распределение частот выборки объема  $n$  — 20:

Варианта $x_i$	2	6	12
Частота $n_i$	3	10	7

- Написать распределение относительных частот.

# Решение

- Найдем относительные частоты, для чего разделим частоты на объем выборки:

$$p_1^* = \frac{3}{20} = 0,15; \quad p_2^* = \frac{10}{20} = 0,50; \quad p_3^* = \frac{7}{20} = 0,35$$

- Поэтому получаем следующее распределение:

Варианта $x_i$	2	6	12
Относительная частота $p_i$	0,15	0,50	0,35


# Полигон и гистограмма

- Для графического изображения статистического распределения используются *полигоны* и *гистограммы*.
- *Полигоном частот* называют ломаную, отрезки которой соединяют точки  $(x_1; n_1), (x_2; n_2), \dots, (x_k; n_k)$ .
- *Полигоном относительных частот* называют ломаную, отрезки которой соединяют точки  $(x_1; p_1^*), (x_2; p_2^*), \dots, (x_k; p_k^*)$



- *Гистограммой частот* называют ступенчатую фигуру, состоящую из прямоугольников, основаниями которых служат частичные интервалы длиной  $h$ , а высоты равны отношению  $\frac{n_i}{h}$  (плотность частоты).
- Площадь  $i$ -го частичного прямоугольника равна  $\frac{n_i}{h} \cdot h = n_i$  — сумме частот вариант  $i$ -го интервала; следовательно, площадь гистограммы частот равна сумме всех частот, т. е. объему выборки.

# Пример гистограммы



- Гистограммой относительных частот называют ступенчатую фигуру, состоящую из прямоугольников, основаниями которых служат частичные интервалы длиной  $h$ , а высоты равны отношению  $\frac{P_i^*}{h}$  (плотность относительной частоты).
- Площадь  $i$ -го частичного прямоугольника равна  $\frac{P_i^*}{h} \cdot h = p_i^*$  - относительной частоте вариант, попавших в  $i$ -й интервал, следовательно, площадь гистограммы относительных частот равна сумме всех относительных частот, т. е. единице.

# Статистические оценки параметров распределения

- Статистической оценкой неизвестного параметра теоретического распределения называют функцию от наблюдаемых случайных величин.

# Генеральная и выборочная средние. Методы их расчета .

- Пусть изучается дискретная генеральная совокупность объема  $N$  относительно количественного признака  $X$ .
- *Генеральной средней*  $\bar{x}_G$  называют среднее арифметическое значений признака генеральной совокупности.

- Если все значения  $x_1, x_2, \dots, x_N$  признака генеральной совокупности объема  $N$  различны, то

$$\bar{x}_G = \frac{1}{N} (x_1 + x_2 + \dots + x_N)$$

- Если же значения признака  $x_1, x_2, \dots, x_k$  имеют соответственно частоты  $N_1, N_2, \dots, N_k$ , причем  $N_1 + N_2 + \dots + N_k = N$ , то

$$\bar{x}_G = \frac{1}{N} (x_1 N_1 + x_2 N_2 + \dots + x_k N_k)$$

ИЛИ

$$\bar{x}_G = \frac{1}{N} \sum_{i=1}^k x_i N_i$$

- Пусть для изучения генеральной совокупности относительно количественного признака  $X$  произведена выборка объема  $n$ .
- *Выборочной средней*  $\bar{x}_B$  называют среднее арифметическое значение признака выборочной совокупности.

- Если все значения  $x_1, x_2, \dots, x_k$  признака выборки объема  $n$  различны, то

$$\bar{x}_B = \frac{1}{n} (x_1 + x_2 + \dots + x_k)$$



- Если же значения признака  $x_1, x_2, \dots, x_k$  имеют соответственно частоты  $n_1, n_2, \dots, n_k$  причем  $n_1 + n_2 + \dots + n_k = n$ , то

$$\bar{x}_B = \frac{1}{n} (x_1 n_1 + x_2 n_2 + \dots + x_k n_k)$$

ИЛИ

$$\bar{x}_B = \frac{1}{n} \sum_{i=1}^k x_i n_i$$

# Генеральная и выборочная дисперсии.

- Для того чтобы охарактеризовать рассеяние значений количественного признака  $X$  генеральной совокупности вокруг своего среднего значения, вводят сводную характеристику — генеральную дисперсию.

- Генеральной дисперсией  $D_{\Gamma}$  называют среднее арифметическое квадратов отклонений значений признака генеральной совокупности от их среднего значения  $\bar{x}_{\tilde{A}}$ .
- Если все значения  $x_1, x_2, \dots, x_N$  признака генеральной совокупности объема  $N$  различны, то

$$D_{\Gamma} = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_{\Gamma})^2$$

- Если же значения признака  $x_1, x_2, \dots, x_k$  имеют соответственно частоты  $N_1, N_2, \dots, N_k$ , причем  $N_1 + N_2 + \dots + N_k = N$ , то

$$D_{\Gamma} = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{x}_{\Gamma})^2 N_i$$

- Генеральным средним квадратическим отклонением (стандартом) называют квадратный корень из генеральной дисперсии:

$$\sigma_{\Gamma} = \sqrt{D_{\Gamma}}$$

- Выборочной дисперсией  $D_B$  называют среднее арифметическое квадратов отклонения наблюдаемых значений признака от их среднего значения  $\bar{x}_A$ .
- Если все значения  $x_1, x_2, \dots, x_k$  признака выборки объема  $n$  различны, то

$$D_B = \frac{1}{n} \sum_{i=1}^k (x_i - \bar{x}_B)^2$$

- Если же значения признака  $x_1, x_2, \dots, x_n$  имеют соответственно частоты  $n_1, n_2, \dots, n_k$  причем  $n_1 + n_2 + \dots + n_k = n$ , то

$$D_B = \frac{1}{n} \sum_{i=1}^k n_i (x_i - \bar{x}_B)^2$$

- Выборочным средним квадратическим отклонением (стандартом) называют квадратный корень из выборочной дисперсии:  $\sigma_B = \sqrt{D_B}$



- Выборочная дисперсия является смещенной оценкой генеральной дисперсии, т.е. математическое ожидание выборочной дисперсии не равно оцениваемой генеральной дисперсии, а равно

$$M[D_B] = \frac{n-1}{n} D_G$$

- Легко «исправить» выборочную дисперсию так, чтобы ее математическое ожидание было равно генеральной дисперсии. Достаточно для этого умножить  $D_B$  на дробь  $\frac{n}{n-1}$ . Итак, в качестве оценки генеральной дисперсии принимают исправленную дисперсию

$$s^2 = \frac{1}{n-1} \sum_{i=1}^k n_i (x_i - \bar{x}_B)^2$$

- *Точечной* называют оценку, которая определяется одним числом. Все оценки, рассмотренные выше, — *точечные*. При выборке малого объема точечная оценка может значительно отличаться от оцениваемого параметра, т. е. приводить к грубым ошибкам. По этой причине при небольшом объеме выборки следует пользоваться интервальными оценками.

- *Интервальной* называют оценку, которая определяется двумя числами — концами интервала. Интервальные оценки позволяют установить точность и надежность оценок.

- Пусть  $X$  — оцениваемый параметр генеральной совокупности (генеральное среднее, генеральная дисперсия и т.д.), а  $\bar{x}$  — точечная оценка, полученная по выборке.
- Интервальной оценкой параметра  $X$  называется оценка вида

$$P(\bar{X} - \varepsilon < X < \bar{X} + \varepsilon) = P_{\alpha}$$

- При этом интервал  $(\bar{X} - \varepsilon, \bar{X} + \varepsilon)$  называется доверительным интервалом.
- Величина  $\varepsilon$  характеризует точность оценки, а величина  $P\alpha$  равна вероятности того, что параметр  $\bar{X}$  лежит в указанных пределах.

- Пусть рассматриваемый признак распределен в генеральной совокупности по нормальному закону с неизвестными значениями генерального среднего и дисперсии. Для того чтобы получить интервальную оценку генерального среднего  $X_{\Gamma}$ , поступают следующим образом.

- Для выборки некоторого объема  $n$  вычисляют выборочное среднее и исправленное среднее квадратическое отклонение .
- Выбирают доверительную вероятность  $P_\alpha$  (обычно 0,95 или 0,99) и для нее по таблице распределения Стьюдента находят параметр  $t$ .
- Рассчитывают полуширину доверительного интервала  $\varepsilon$ :
$$\varepsilon = \frac{t \cdot s}{\sqrt{n}}$$



- Получают интервальную оценку генеральной средней с выбранной доверительной вероятностью:

$$\bar{X}_B - \varepsilon < \bar{X}_T < \bar{X}_B + \varepsilon$$