

ПРАКТИЧЕСКОЕ ЗАНЯТИЕ № 4

ОЦЕНКА ПАРАМЕТРОВ ГЕНЕРАЛЬНОЙ СОВОКУПНОСТИ ПО ВЫБОРОЧНЫМ ДАННЫМ

Цель работы

1. Изучить основы первичной обработки данных;
2. Научиться строить гистограмму;
3. Освоить вычисление точечных и интервальных оценок выборочных данных.

Основными понятиями математической статистики являются: **генеральная совокупность, выборка, теоретическая функция распределения.**

Генеральная совокупность – это множество всех мыслимых значений наблюдений (объектов), однородных относительно некоторого признака, которые могли быть сделаны. Число всех наблюдений, составляющих генеральную совокупность, называется ее объемом N . Например, популяция представляет собой множество индивидуумов. Изучение целой популяции трудоемко и дорого и, может быть, просто невозможно. Поэтому собирают данные по выборке индивидуумов, которых считают представителями этой популяции, позволяющими сделать вывод относительно этой популяции.

Выборка – это совокупность случайно отобранных наблюдений (объектов) для непосредственного изучения из генеральной совокупности. Объем выборки n . Выборка обязательно должна удовлетворять условию **репрезентативности**, т.е. давать обоснованное представление о генеральной совокупности. Как сформировать репрезентативную (представительную) выборку? В идеале стремятся получить случайную (**рандомизированную**) выборку. Для этого составляют список всех индивидуумов в популяции и случайно их отбирают. Но иной раз затраты при составлении списка могут оказаться недопустимыми и тогда берут приемлемую выборку, например, одну клинику, больницу и исследуют всех пациентов в этой клинике с данным заболеванием.

Каждый элемент выборки x_i называется **вариантой**. Число наблюдений варианты n_i называется **частотой встречаемости**. Последовательность вариантов, записанных в **возрастающем порядке**, называется **вариационным рядом**.


Гистограмма частот – это ступенчатая фигура, состоящая из смежных прямоугольников, построенных на одной прямой, основания

которых одинаковы и равны ширине класса, а высота равна или частоте попадания в интервал n_i или относительной частоте $\frac{n_i}{n}$.

Ширину интервала i можно определить по формуле Стерджеса:

$$i = \frac{x_{\max} - x_{\min}}{1 + 3.32 \lg n},$$

где x_{\max} – максимальное, а x_{\min} – минимальное значения вариант, а их разность носит название вариационный размах.
 n – объем выборки.



Пример 4.1. Наблюдения за числом частиц, попавших в счетчик Гейгера, в течение минуты дали следующие результаты:

21 30 39 31 42 34 36 30 28 30 33 24 31 40 31 33 31 27 31 45 31 34 27 30 48 30 28 30 33 46 43 30 33 28 31 27 31 36 51 34 31 36 34 37 28 30 39 31 42 37.

Построить по этим данным интервальный вариационный ряд с равными интервалами (I интервал 20-24; II интервал 24-28 и т.д.) и начертить гистограмму.

Р е ш е н и е .

Интервал	20-24	24-28	28-32	32-36	36-40	40-44	44-48	48-52
Частота	1	4	22	8	7	4	2	2




Рис.4.1. Гистограмма распределения

Оценка параметров генеральной совокупности по ее выборке

Смысл статистических методов заключается в том, чтобы по выборке ограниченного объема n , т.е. по некоторой части генеральной совокупности, высказать **обоснованное суждение о свойствах генеральной совокупности.**

Числовые значения, характеризующие генеральную совокупность, называются параметрами. Одна из задач математической статистики – определение параметров большого массива по исследованию его части.

Статистическое оценивание может выполняться двумя способами:

1) **Точечная оценка** – оценка, которая дается для некоторого параметра одним значением.

2) **Интервальная оценка** – по данным выборки оценивается интервал, в котором лежит истинное значение параметра с заданной вероятностью.

Точечная оценка параметров генеральной совокупности

Точечная оценка – это оценка, которая определяется одним числом. И это число определяется по выборке. Это функция результатов выборки, и она является точечной оценкой генерального параметра, т.е. принимает только одно значение.

Качество оценки устанавливается по трем свойствам: быть состоятельной, эффективной и несмещенной.

Точечная оценка называется **состоятельной**, если при увеличении объема выборки выборочная характеристика стремится к соответствующей характеристике генеральной совокупности.

Точечная оценка называется **эффективной**, если она имеет наименьшую дисперсию выборочного распределения по сравнению с другими аналогичными оценками.

Точечную оценку называют **несмещенной**, если ее математическое ожидание равно оцениваемому параметру при любом объеме выборки.

Несмещенной оценкой генеральной средней (математического ожидания) служит выборочная средняя \bar{x}_g :

$$\bar{x}_g = \frac{1}{n} \sum_{i=1}^k x_i n_i, \text{ где}$$

x_i - варианта выборки;

n_i - абсолютная частота встречаемости варианты x_i ;

n - объем выборки.

Выборочная средняя является несмещенной оценкой генеральной средней, так как $M(\bar{x}_e) = \bar{x}_{ген}$, то есть она эквивалентна истинному среднему в генеральной совокупности.

Выборочная дисперсия S_e^2 не обладает свойством несмещенности. Это смещенная оценка генеральной дисперсии $\sigma_{ген}^2$.

$$\sigma_{ген}^2 \neq M(S_e^2)$$

На практике используют **исправленную дисперсию S^2** , которая является несмещенной оценкой дисперсии генеральной совокупности:

$$S^2 = \frac{n}{n-1} S_e^2(x) = \frac{n}{n-1} \frac{\sum_{i=1}^K (x_i - \bar{x}_e)^2 \cdot n_i}{n};$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^K (x_i - \bar{x}_e)^2 \cdot n_i.$$

$$\sigma_{ген}^2 = M(S^2)$$

Кроме того, в расчетах используют **S - исправленное среднее квадратическое отклонение**, называемое **стандартным отклонением** в выборке и ошибку выборочной средней m_x

$$m_x = \frac{S}{\sqrt{n}}, \text{ которая отражает точность оценки}$$

Стандартная ошибка уменьшится, т.е. оценка станет более точной, если объем выборки n увеличится и данные имеют небольшое рассеяние S .

Рассмотрим разницу между S – стандартным отклонением в выборке и m – стандартной ошибкой среднего. На первый взгляд они очень схожи, но их используют в разных целях.

Среднее квадратическое отклонение S отражает вариабельность в значениях данных, и его указывают, если надо пояснить изменчивость в наборе данных, разброс данных.

Ошибка выборочной средней m_x характеризует точность выборочного среднего \bar{x}_e и должна быть указана, если интерес представляет среднее значение выборки.

Пример 4.2. Из генеральной совокупности извлечена выборка объема $n = 50$.

x_i	2	5	10	7
-------	---	---	----	---

n_i	16	12	8	14
-------	----	----	---	----

Найти несмещенную оценку генеральной средней.

Р е ш е н и е .

$$\bar{x}_e = \frac{1}{n} \sum_{i=1}^K x_i n_i;$$

$$\bar{x}_e = \frac{16 \cdot 2 + 5 \cdot 12 + 7 \cdot 8 + 10 \cdot 14}{50} = 5,76.$$

Пример 4.3. По выборке объема 30 найдено значение выборочной дисперсии $S_e^2 = 3$. Найти несмещенную оценку дисперсии генеральной совокупности.

Р е ш е н и е .

Эта несмещенная оценка равна исправленной дисперсии:

$$S^2 = \frac{n}{n-1} S_e^2, \quad S^2 = \frac{30}{29} \cdot 3 = 3,1.$$

Пример 4.4. Найти несмещенную оценку генеральной средней, дисперсии генеральной совокупности и стандартное отклонение по выборке объема 12, описывающую продолжительность в секундах физической нагрузки до развития приступа стенокардии.

289, 203, 359, 243, 232, 210, 251, 251, 246, 224, 239, 220, 211.

Р е ш е н и е .

$$\bar{x}_e = \frac{289 + 203 + \dots + 211}{12} = 244;$$

$$S^2 = \frac{1}{11} \left[(289 - 244)^2 + (203 - 244)^2 + \dots + (211 - 244)^2 \right] = 1849;$$

$$S^2 = 1849;$$

$$S = 43.$$

Интервальная оценка параметров генеральной совокупности

Точечные оценки параметров распределения не дают информации о степени близости к соответствующему теоретическому параметру. Поэтому построение интервала, в котором с заданной степенью достоверности будет находиться оцениваемый параметр, является более информативным способом оценивания неизвестных параметров.

Интервальная оценка – это числовой интервал, который определяется двумя числами – границами интервала, содержащий неизвестный параметр генеральной совокупности.

Доверительный интервал – это интервал, в котором с той или иной заранее заданной вероятностью находится неизвестный параметр генеральной совокупности.

Доверительная вероятность p – это такая вероятность, что событие вероятности $1-p$ можно считать невозможным. $\alpha = 1-p$ – это уровень значимости.

(Обозначения доверительной вероятности и уровня значимости могут отличаться от приведенных выше). Обычно в качестве доверительных вероятностей используют **вероятности, близкие к 1**. Тогда событие, что интервал накроет характеристику, будет практически достоверным. Это $p \geq 0,95$, $p \geq 0,99$, $p \geq 0,999$.

Эти вероятности признаны достаточными для уверенного суждения о генеральных параметрах на основании известных выборочных показателей. Обычно указывают 95 % доверительный интервал.

Для выборки малого объема ($n < 30$) нормально распределенного количественного признака x доверительный интервал может иметь вид:

$$\bar{x}_e - m_{\bar{x}}t \leq \mu \leq \bar{x}_e + m_{\bar{x}}t$$

где, μ – генеральное среднее;

\bar{x}_e – выборочное среднее;

t – нормированный показатель распределения Стьюдента, с $(n-1)$ степенями свободы, который определяется вероятностью попадания генерального параметра в данный интервал. Термин "степени свободы" означает, что их можно вычислить как объем выборки минус число ограничивающих условий.

$$m_x - \text{ошибка выборочной средней. } m_x = \frac{S}{\sqrt{n}}$$

Для интерпретации доверительного интервала в клинических работах следует помнить, что ширина доверительного интервала зависит от m_x – средней ошибки выборочной средней, которая в свою очередь зависит от объема выборки (n) и от изменчивости данных (S). Если выборка небольшая, то доверительный интервал более широкий, чем в случае выборки большого объема. Широкий доверительный интервал указывает на неточную оценку, а узкий – на точную оценку.

Верхний и нижние пределы доверительного интервала показывают, будут ли результаты клинически значимы.

Пример 4.5. Количественный признак x генеральной совокупности распределен нормально. По выборке объема $n = 16$ найдены среднее выборочное $= 20,2$ и среднее квадратическое отклонение $S = 0,8$. Определить неизвестное математическое ожидание при помощи доверительного интервала при $p \geq 0,95$.

Р е ш е н и е .

$$\bar{x}_g - m_{\bar{x}}t \leq \mu \leq \bar{x}_g + m_{\bar{x}}t$$

Найдем t из таблицы распределения Стьюдента при уровне значимости $\alpha \leq 0.05$ и числе степеней свободы $f = n-1; f = 16-1 = 15$.

$$t(\alpha \leq 0,05, f = 15) = 2,13.$$

Запишем:

$$20,2 - \frac{0,8}{\sqrt{16}} \cdot 2,13 \leq \mu \leq 20,2 + \frac{0,8}{\sqrt{16}} \cdot 2,13 (p \geq 0,95)$$

$$19,8 \leq \mu \leq 20,6 \quad (p \geq 0,95).$$

Пример 4.6. Имеется выборка объема $n = 11$ – это значение систолического давления у мужчин в начальной стадии шока.

x : 127, 124, 155, 129, 77, 147, 65, 109, 145, 141.

С помощью пакета прикладных программ на ЭВМ провести статистическую обработку данных выборки и определить доверительный интервал для генеральной средней при $p \geq 0,95$.

Р е ш е н и е . Пусть расчет на ЭВМ дал выборочное среднее $\bar{x}_g = 122,01$; $m_{\bar{x}} = 8,59$. По таблице распределения Стьюдента найдем:

$$t(\alpha \leq 0,05, f = 11-1 = 10) = 2,23; \quad \mu = \bar{x}_g \pm m_{\bar{x}}t$$

$$\mu = 122,01 \pm 8,59 \cdot 2,23 \quad (p \geq 0,95);$$

$$\mu = 122 \pm 19; \quad (p \geq 0,95).$$