

## Лекция 4

### ОСНОВЫ МАТЕМАТИЧЕСКОЙ ТЕОРИИ ВЫБОРОЧНОГО МЕТОДА ТОЧЕЧНОЕ И ИНТЕРВАЛЬНОЕ ОЦЕНИВАНИЕ

Наблюдения могут быть:

Сплошные (изучаются все объекты совокупности)

Выборочные (изучается часть объектов)

**Генеральная совокупность** – совокупность всех гипотетически возможных мыслимых наблюдений, которые могли бы быть произведены при данном реальном комплексе условий

**Выборочная совокупность**, или **выборка** – часть объектов, которая отобрана из генеральной совокупности для непосредственного изучения

**Объем генеральной совокупности** – число объектов (наблюдений) генеральной совокупности. Будем обозначать его как  $N$

**Объем выборки** – число объектов (наблюдений) выборки  $n$

Сущность выборочного метода состоит в том, чтобы по свойствам выборки можно было бы судить о свойствах генеральной совокупности. Для этого выборка должна обладать всеми свойствами генеральной совокупности, значимыми с точки зрения задач исследования. Такая выборка называется **репрезентативной**.

#### Преимущества выборочного метода

- Экономия затрат ресурсов (материальных, временных, трудовых)
- Иногда единственно возможный метод (например, в случае бесконечного объема генеральной совокупности, или когда исследование связано с уничтожением наблюдаемых объектов)
- Позволяет снизить ошибки регистрации (расхождения между истинным и зарегистрированным значениями признака)

**Основной недостаток** – ошибки репрезентативности (ошибки исследования)

#### Виды выборок

- Собственно-случайная (случайный выбор элементов без предварительного деления на группы)
- Механическая (элементы отбираются через определенный интервал)
- Типическая (выбор элементов случайным образом из типических групп)
- Серийная (отбираются целые группы, на которые делится случайно, а внутри группы все элементы подвергаются сплошному наблюдению)

**Способы образования выборки** – *повторный отбор* (при этом возможно повторное исследование элемента) и *бесповторный отбор* (невозможно повторное исследование элемента)

Далее будем считать, что выборка является **собственно-случайной** и (повторной либо бесповторной).

Важнейшая задача выборочного метода в математической статистике – оценка параметров генеральной совокупности по данным выборки

**Оценкой параметра** называют всякую функцию результатов наблюдений над случайной величиной (*статистику*), с помощью которой судят о значении этого параметра

Например, для выборки из  $n$  элементов в результате наблюдений некоторой случайной величины  $X$  получили значения  $X_1, X_2, \dots, X_n$ , по которой нужно оценить определенную характеристику  $\theta$  (среднее значение, дисперсию, медиану и т.д.) всей генеральной совокупности. Оценкой будет любая функция полученных значений  $\tilde{\theta}_n = \tilde{\theta}_n(X_1, X_2, \dots, X_n)$ , если по ней можно судить об истинном значении  $\theta$

Для разных выборок набор значений  $X_1, X_2, \dots, X_n$  будет получаться разным. Поэтому и значение оценки параметров  $\tilde{\theta}_n$  тоже будет разным – это случайная величина. Чтобы оценка была «качественной», разброс значений оценки, полученных для разных выборок, должен быть несущественным.

Оценки параметров могут быть **точечными** и **интервальными**

**Точечная оценка** есть определенное значение оцениваемого параметра, полученное по выборке.

**Интервальная оценка** есть интервал, который покрывает оцениваемый параметр с заданной вероятностью.

Рассмотрим сначала точечные оценки.

### **Точечные оценки**

Некоторые важные свойства оценок:

Оценка  $\tilde{\theta}_n$  параметра  $\theta$  называется **несмещенной**, если ее математическое ожидание равно оцениваемому параметру

$$M(\tilde{\theta}_n) = \theta$$

Требование несмещенности гарантирует отсутствие систематических ошибок при оценивании

Оценка  $\tilde{\theta}_n$  параметра  $\theta$  называется **состоятельной**, если она удовлетворяет закону больших чисел, т.е. сходится по вероятности к оцениваемому параметру

$$\tilde{\theta}_n \xrightarrow[n \rightarrow \infty]{P} \theta$$

Если оценка несмещенная и ее дисперсия  $\rightarrow 0$  при  $n \rightarrow \infty$ , то оценка является и состоятельной.

**Пример:** Отдельное выборочное значение является несмещенной оценкой генеральной

средней  $\bar{x}_2 = \frac{\sum_{i=1}^N x_i}{N}$ , но не является состоятельной оценкой. Выборочное среднее  $\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$

несмещенной и состоятельной оценкой генеральной средней

Несмещенная оценка  $\tilde{\theta}_n$  параметра  $\theta$  называется эффективной, если она имеет наименьшую дисперсию среди всех возможных несмещенных оценок параметра  $\theta$ , вычисленных по выборкам одного и того же объема  $n$ . Это решающее свойство, определяющее качество оценки. Степень эффективности любой оценки определяется отношением дисперсий данной и эффективной оценок. На практике часто в целях упрощения расчетов используются оценки, не обладающие высокой эффективностью. Например, генеральную среднюю можно оценивать медианой (при нормальном распределении асимптотически эффективность такой оценки стремится к  $2/\pi \approx 0,64$ ), в то время как эффективной оценкой является выборочная средняя.

### Точечная оценка генеральной средней

$\bar{x} = \frac{\sum_{i=1}^n x_i}{n}$  - выборочная средняя

$\bar{x}_2 = \frac{\sum_{i=1}^N x_i}{N}$  - генеральная средняя

**Теорема.** Выборочная средняя  $\bar{x}$  повторной выборки есть несмещенная и состоятельная оценка генеральной средней  $\bar{x}_2$ , причем

$$\sigma_{\bar{x}}^2 = \frac{\sigma^2}{n}$$

где  $\sigma^2$  - генеральная дисперсия

**Теорема.** Выборочная средняя  $\bar{x}$  бесповторной выборки есть несмещенная и состоятельная оценка генеральной средней  $\bar{x}_2$ , причем

$$\sigma_{\bar{x}}^2 = \frac{\sigma^2}{n} \left( \frac{N-n}{N-1} \right) \approx \frac{\sigma^2}{n} \left( 1 - \frac{n}{N} \right)$$

Если численность выборки не превышает 5% генеральной совокупности, то можно пользоваться формулой повторной выборки

## Точечная оценка генеральной дисперсии

$$\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n} - \text{выборочная дисперсия}$$

$$\sum_{i=1}^N \frac{(x_i - \bar{x}_c)^2}{N} - \text{генеральная дисперсия}$$

**Теорема.** Выборочная дисперсия  $\sum_{i=1}^n \frac{(x_i - \bar{x})^2}{n}$  повторной и бесповторной выборок есть

смещенная и состоятельная оценка генеральной дисперсии  $\sigma^2$ . Вычисленная по этой формуле дисперсия для разных выборок в среднем занижает генеральную дисперсию.

**Исправленная выборочная дисперсия** вычисляется по формуле

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

## Интервальные оценки

**Интервальной оценкой** параметра  $\theta$  называется числовой интервал, который с заданной вероятностью  $\gamma$  покрывает неизвестное значение параметра  $\theta$ . Соответствующий интервал называется **доверительным**, а вероятность  $\gamma$  - **доверительной вероятностью**, или **надежностью оценки**. Обычно рассматривают симметричный интервал  $(\theta - \Delta, \theta + \Delta)$

Величина доверительного интервала  $2\Delta$  уменьшается с ростом объема выборки и увеличивается с ростом доверительной вероятности. Величина  $\Delta$  является ошибкой репрезентативности (представительства) выборки

**Теорема.** Если случайная величина  $X$  имеет нормальный закон распределения с параметрами  $a_2 = \bar{x}_2$  и  $\sigma$ , т.е.  $N(a_2, \sigma^2)$ , то выборочная средняя  $\bar{x}$  имеет нормальный закон распределения  $N(a_2, \frac{\sigma^2}{n})$ .

Следовательно, параметр  $\frac{\bar{x} - a_2}{\left(\frac{\sigma}{\sqrt{n}}\right)}$  имеет стандартное нормальное распределение. Теорема

справедлива для любого объема выборки.

Поскольку параметры генеральной дисперсии ( $a_2$  и  $\sigma$ ) на практике неизвестны, их заменяют «наилучшими» оценками по данной конкретной выборке – выборочной средней (будем ее обозначать так же  $a$ ) и выборочной исправленной дисперсией  $\sigma_s$   $\sigma \rightarrow \sigma_s = \frac{\sigma\sqrt{n}}{\sqrt{n-1}}$

. Тогда в результате замены параметр (статистику)  $t = \frac{\bar{x} - a}{\left(\frac{\sigma_s}{\sqrt{n}}\right)}$ . Необходимо выяснить вид

распределения этой статистики. Умножим числитель и знаменатель  $t$  на  $\frac{\sigma}{\sqrt{n}}$  и выразим

исправленную выборочную дисперсию, которая считается по формуле  $\sigma_s^2 = \sum_{i=1}^n \frac{(x_i - a)^2}{n-1}$

через оценку «неисправленной» дисперсии  $s^2 = \sum_{i=1}^n \frac{(x_i - a)^2}{n}$

$$t = \frac{\bar{x} - a}{\left(\frac{\sigma_s}{\sqrt{n}}\right)} = \frac{(\bar{x} - a) / \frac{\sigma}{\sqrt{n}}}{\sqrt{\frac{ns^2}{(n-1)\sigma^2}}}$$

Случайная величина в числителе имеет стандартное нормальное распределение, как было отмечено выше. А случайная величина  $\frac{ns^2}{(n-1)\sigma^2}$  имеет хи-квадрат распределение с  $k = n - 1$  степенями свободы (так как это сумма квадратов нормально распределенных величин). Следовательно, статистика  $t$  имеет распределение Стьюдента.

Таким образом, статистика  $t = \frac{\bar{x} - a}{\sigma_{\bar{x}}}$ , где  $a$  - среднее (точечная оценка),  $\sigma_a = \frac{\sigma_s}{\sqrt{n}}$  -

среднеквадратичная ошибка среднего (точечная оценка),  $\sigma_s$  - стандартное отклонение (точечная оценка) имеет распределение Стьюдента с  $k = n - 1$  степенями свободы, где  $n$  - объем выборки.

Значение  $t^*$  определяют границы интервала  $\Delta = t^* \sigma_a$ , который с заданной доверительной вероятностью  $\gamma$  покрывает истинное среднее значение. Величина  $t^*$  зависит от доверительной вероятности и объема выборки  $t^* = t_{\gamma, n-1}$ . Будем называть ее коэффициентом Стьюдента. Можно найти по таблицам, либо с помощью встроенных функций SPSS


$$t^* = t_{\gamma, n-1} = \text{IDF.T}\left(\frac{1+\gamma}{2}, n-1\right)$$

Либо

$$t^* = t_{\gamma, n-1} = -\text{IDF.T}\left(\frac{1-\gamma}{2}, n-1\right)$$

При больших объемах выборки  $n$  распределение Стьюдента приближается к стандартному нормальному. На практике при  $n > 30$  можно приближенно считать

$$t^* \approx -\text{IDF.Normal}\left(\frac{1-\gamma}{2}, 0, 1\right) = \text{IDF.Normal}\left(\frac{1+\gamma}{2}, 0, 1\right)$$



Интервальной оценкой генеральной средней будет интервал

$$a - \sigma_{\bar{x}} t_{\gamma, n-1} \leq a_z \leq a + \sigma_{\bar{x}} t_{\gamma, n-1}$$

В SPSS для вычисления статистик выборки можно использовать опции

Анализ → Описательные статистики → Частоты

Анализ → Описательные статистики → Описательные статистики

Анализ → Описательные статистики → Разведочный анализ


Первый вариант (→ *Частоты*) рассматривали ранее. Познакомимся с возможностями опций *Анализ* → *Описательные статистики* → *Описательные статистики*

Пример. Файл Баланс.sav

	N	Среднее	Стандартная отклонения	Дисперсия
Статистика	Статистика	Стандартная ошибка	Статистика	Статистика
баланс	25	189,64	38,464	192,321
N валидных (по списку)	25			36987,240

Для более подробного описания используются опции

*Анализ* → *Описательные статистики* → *Разведочный анализ*



Описательные статистики

Доверительный интервал для среднего  %

M-оценки

Выбросы

Процентили

**Продолжить**

Отмена

Справка

### Сводный отчет по наблюдениям

	Допустимо		Наблюдения Пропущенные		Всего	
	N	Проценты	N	Проценты	N	Проценты
баланс	25	100,0%	0	0,0%	25	100,0%

### Описательные статистики

		Статистика	Стандартная ошибка
баланс	Среднее	189,64	38,464
	90% Доверительный интервал для среднего	Нижняя граница: 123,83	Верхняя граница: 255,45
		Среднее по выборке, усеченной на 5%	169,04
	Медиана	104,00	
	Дисперсия	36987,240	
	Стандартная отклонения	192,321	
	Минимум	0	
	Максимум	805	
	Диапазон	805	
	Межквартильный диапазон	269	
	Асимметрия	1,638	,464
	Экссесс	3,079	,902

$$\Delta = 65,81$$

$$t_{\gamma, n-1} = 1,71 (= 65,81 / 38,464)$$

$$\gamma = 0,9$$

$$n = 25$$

Проверим:

$$t_{\gamma, n-1} = -\text{IDF.T}(0.05, 24) = 1,71$$