

# Общая теория статистики

Тема

Выборочное  
наблюдение



**Найдите: медиану стажа и среднюю зарплату для коллектива из 5 человек**

<b>Номер</b>	<b>Стаж, лет</b>	<b>Зарплата, т.р.</b>
<b>1</b>	<b>5</b>	<b>№ в списке</b>
<b>2</b>	<b>12</b>	<b>8</b>
<b>3</b>	<b>№ в списке</b>	<b>15</b>
<b>4</b>	<b>20</b>	<b>22</b>
<b>5</b>	<b>25</b>	<b>19</b>

# Определение выборочного наблюдения

- Выборочное наблюдение — это способ несплошного статистического наблюдения, при котором обследуются не все единицы изучаемой (генеральной) совокупности, а лишь часть ее (выборка), отобранная по определенным правилам (научно) и обеспечивающая получение данных, характеризующих совокупность в целом.

# Причины применения:

- ◆ Экономия

- ◆ Невозможность

проведения сплошного

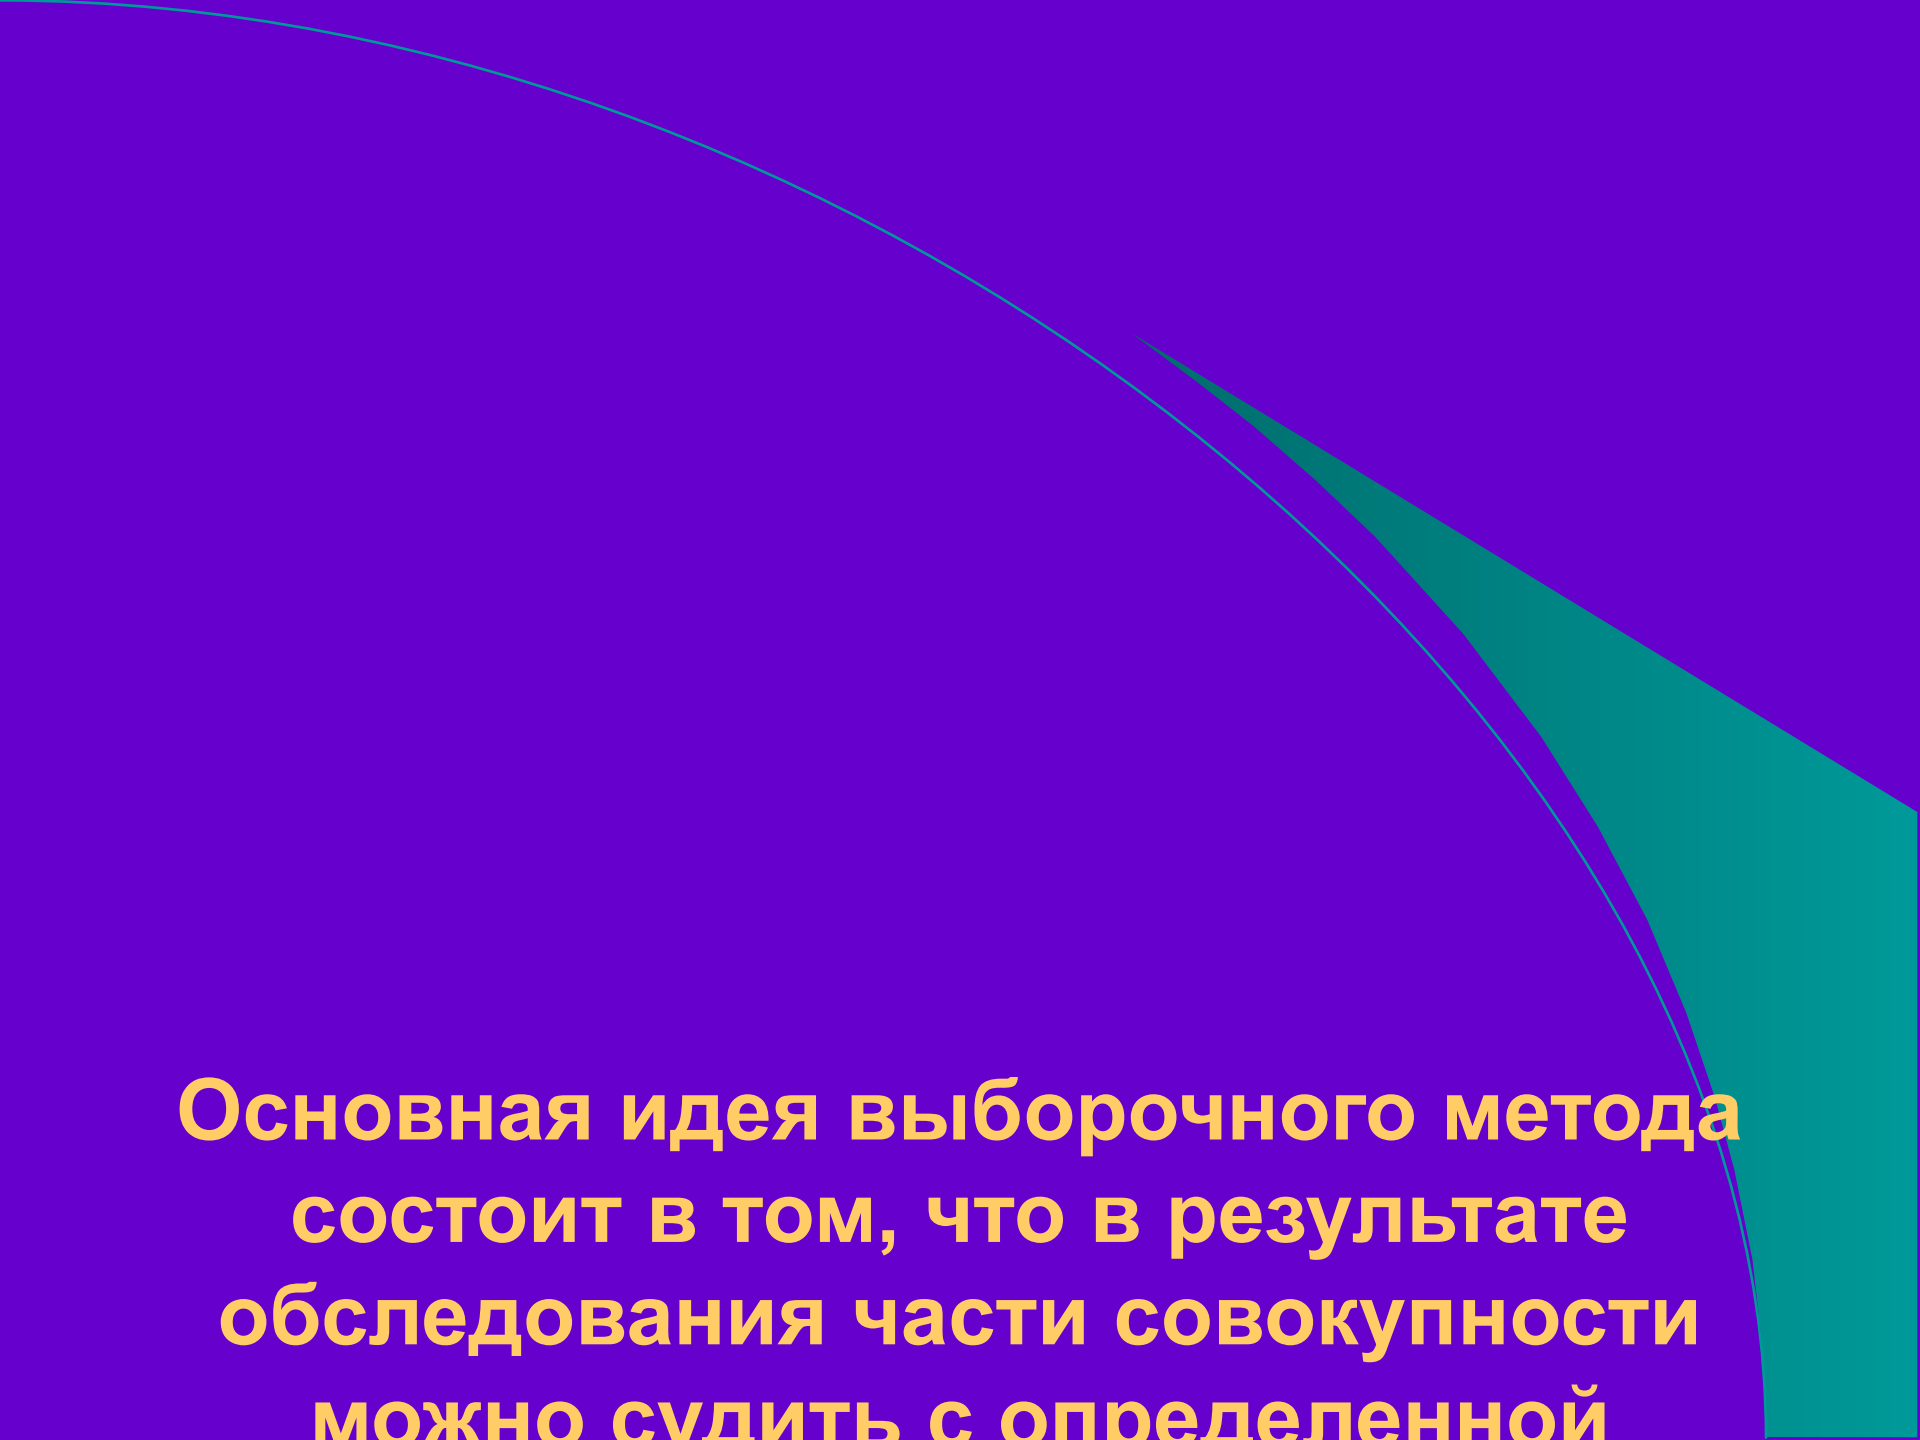
исследования

# Основные обозначения

- $N$  – объем, численность, число единиц ГС
- $n$  – объем ВС

$\bar{x}$  – генеральная \_ средняя;

$W_{ген}$  – доля \_ единиц, обладающих признаком \_ в \_ ГС



**Основная идея выборочного метода  
состоит в том, что в результате  
обследования части совокупности  
можно судить с определенной**

**Для того, чтобы выборочная совокупность давала объективные результаты, она должна быть репрезентативной (каждая единица генеральной совокупности должна иметь равную возможность попасть в выборку). Тогда с увеличением объема выборки характеристики выборочной совокупности будут приближаться к характеристикам генеральной совокупности.**

Теоретической основой выборки являются теоремы закона больших чисел (Чебышева, Ляпунова, Бернулли и др.)



# Задачи выборочного метода

- ◆ Определение доверительного интервала, в котором находится характеристика генеральной совокупности
- ◆ Определение минимального объема выборки
- ◆ Определение доверительной вероятности того, что разность между характеристиками выборочной и генеральной совокупностей не превзойдет наперед заданного числа

# Пример. Имеются данные о зарплате рабочих в у. е.

Группы по з/пл.	ГС - человек	Из них попали в выборку
10-13	100	5
13-16	150	10
16-19	400	30
19-22	200	45
22-25	150	10
<b>Итого</b>	<b>1000</b>	<b>100</b>

# Сходство ГС и ВС

- Из теорем Чебышева, Ляпунова и закона больших чисел следует:

Хотя каждая выборочная средняя отличается от генеральной, среднее значение по ним равно генеральной:

$$\frac{\sum \tilde{x}}{n} = \bar{x}$$

## ВЫВОД.

Реально наблюдаемая совокупность объектов, статистически представленная рядом наблюдений  $x_1, x_2, \dots, x_n$  случайной величины  $X$ , является *выборкой*, а гипотетически существующая (домысливаемая) – *генеральной совокупностью*.

В основе решения задач на выборочный метод лежат формулы предельных ошибок выборки

$$\Delta = t_{\mu}$$

# Обозначения

$t$  - число, связанное с вероятностью  
через табл. закона распределения

$\mu$  - средняя ошибка выборки

$\Delta$  - предельная ошибка

# Ошибки выборки

$$\left| \bar{x} - \bar{x}_0 \right| = \varepsilon_{\bar{x}} \quad - \text{ошибка средней}$$

$\bar{x}_0$  - генеральная средняя

$$\left| W - W_0 \right| = \varepsilon_w \quad - \text{ошибка доли}$$

$W_0$  - генеральная доля

# Характеристики выборочной совокупности

$$\bar{x} = \frac{\sum x_i \cdot n_i}{n}$$

- выборочная средняя

$$\sigma^2 = \frac{\sum (x_i - \bar{x})^2 \cdot n_i}{n}$$

- выборочная дисперсия

$$W = \frac{m}{n}$$

- выборочная доля



# Объем выборки

- Число наблюдений  $n$ , образующих выборку, называется **объемом выборки**. Если объем выборки  $n$  достаточно велик ( $n \rightarrow \infty$ ), выборка считается **большой**, в противном случае она называется **выборкой ограниченного объема**.

**Малой считается  
выборка,  
в которую входит  
меньше 30 единиц.**

## Рассмотрим особенности малой выборки.

Если мы работаем с обычной выборкой, то используется таблица «Интеграла вероятностей закона нормального распределения».

В случае малой выборки необходимо пользоваться таблицей «Распределение Стьюдента», при этом число степеней свободы равно:

$$K = n - 1$$

# Объем выборки

Выборка считается *малой*, если при измерении одномерной случайной величины  $X$  объем выборки не превышает 30 ( $n \leq 30$ ), а при измерении одновременно нескольких ( $k$ ) признаков в многомерном пространстве отношение  $n$  к  $k$  не превышает 10 ( $n/k < 10$ ).

# Условия проведения выборки

*Выборка будет представлять всю совокупность с приемлемой точностью при выполнении двух условий.*

# Условия проведения выборки

*Во-первых, она должна быть достаточно **многочисленной**, чтобы в ней могли проявиться закономерности, существующие в генеральной совокупности.*

# Условия проведения выборки

*Во-вторых, элементы выборки должны быть отобраны **объективно**, независимо от воли исследователя, чтобы каждый из них имел одинаковые шансы быть отобранным или чтобы эти шансы были известны исследователю.*

# характеристика выборочного наблюдения

*Генеральная совокупность может быть конечной (число наблюдений  $N = \text{const}$ ) или бесконечной ( $N = \infty$ ), а выборка из генеральной совокупности – это всегда результат ограниченного ряда  $n$  наблюдений.*



# Способы отбора

- По виду различают индивидуальный, групповой и комбинированный отбор. При **индивидуальном** отборе в выборочную совокупность отбираются отдельные единицы генеральной совокупности, при **групповом отборе** – группы единиц, а **комбинированный отбор** предполагает сочетание группового и индивидуального отбора.

# *Виды и схемы отбора*

Процесс образования выборочной совокупности называется **отбором**. Он осуществляется в порядке беспристрастного, случайного отбора единиц из генеральной совокупности.

Существуют **ПЯТЬ** **ОСНОВНЫХ** **способов отбора**

# Простой случайный отбор

при котором  $n$  объектов случайно извлекаются из генеральной совокупности  $N$  объектов (например с помощью таблицы или датчика случайных чисел), причем каждая из возможных выборок имеют равную вероятность. Такие выборки называются *собственно-случайными*.

# Случайная выборка

- ◆ Случайная выборка - основа всех других способов отбора.
- ◆ Случайная выборка осуществляется методом жеребьевки: все единицы совокупности нумеруются, номера записываются на карточки, а потом отбираются.
- ◆ **Отбор может быть повторным и бесповторным.**

# Формулы предельных ошибок выборки

	Повторный отбор	Бесповторный отбор
Для средней	$t \cdot \sqrt{\frac{\sigma^2}{n}}$	$t \cdot \sqrt{\frac{\sigma^2}{n} \cdot \left(1 - \frac{n}{N}\right)}$
Для доли	$t \cdot \sqrt{\frac{w \cdot (1 - w)}{n}}$	$t \cdot \sqrt{\frac{w \cdot (1 - w) \cdot \left(1 - \frac{n}{N}\right)}{n}}$

# Обозначения:

- $\sigma^2$  - выборочная дисперсия;
- $W$  - выборочная доля;
- $n$  - объем выборочной совокупности;
- $N$  - объем генеральной совокупности;
- $t$  - число, связанное с вероятностью, которая берется из таблицы интеграла вероятностей закона распределения.

## *Пример*

Для определения среднего срока службы изделий было обследовано 250 изделий. При этом средний срок службы был установлен на уровне 41,9 месяца. Среднее квадратическое отклонение равно 6,2 месяцам.

С вероятностью 0,9973 определить, в каких пределах находится средний срок службы всех изделий

# Решение:

- $P=0,9973$ ,  $t=3$  (из таблицы интеграла вероятностей закона нормального распределения).

$$\Delta_{\bar{x}} = 3 \cdot \sqrt{\frac{6,2^2}{250}} = 1,2 \text{ мес}$$

$$\bar{x} - \Delta_{\bar{x}} \leq \bar{x}_0 \leq \bar{x} + \Delta_{\bar{x}}$$

$$41,9 - 1,2 \leq \bar{x}_0 \leq 41,9 + 1,2$$

$$40,7 \text{ мес} \leq \bar{x}_0 \leq 43,1 \text{ мес}$$



# Пример

- Определить вероятность того, что предельная ошибка средней службы не превысит 1 месяц.

Решение:

$$\Delta_{\bar{x}} = t \cdot \sqrt{\frac{\sigma^2}{n}}$$

$$t = \frac{\Delta_{\bar{x}}}{\sqrt{\frac{\sigma^2}{n}}} = \frac{1}{\sqrt{\frac{6,2^2}{250}}} = 2,55$$

$$P = 0,9892$$

# Пример

## Определение минимального объема выборки.

Сколько следует прохронометрировать операций, чтобы с вероятностью 0,9973 можно было бы утверждать, что разность между средней продолжительностью операций в выборочной и генеральной совокупности не превысит 1 секунды, если по результатам предыдущего испытания установлено, что средняя продолжительность операции равна 30 секундам, а среднее квадратическое отклонение равно 7 секундам?

# Решение :

$$n = ?$$

$$\Delta = 1$$

$$n = \frac{t^2 \cdot \sigma^2}{\Delta_x^2} = \frac{3^2 \cdot 7^2}{1^2} = 441$$

*Ответ:* нужно прохронометрировать не менее 441 операции.

## ***Простой отбор с помощью регулярной процедуры***

осуществляется с применением  
механической составляющей  
(номера квартиры, даты, дня  
недели, буквы алфавита) и  
полученные таким способом  
выборки называются  
*механическими.*

## Стратифицированный отбор

заключается в том, что генеральная совокупность объема  $N$  подразделяется на части совокупности или слои (страты) объема  $N_1, N_2, \dots, N_r$ , так что  $N_1 + N_2 + \dots + N_r = N$ .

# Стратифицированный отбор

Страты - однородные объекты с точки зрения статистических характеристик (например, население по возрасту делится на две страты – в трудоспособном и нетрудоспособном возрасте; банки – по размеру капитала). В этом случае выборки называются *стратифицированными* (*расслоенными, типическими, районированными*).

## Серийный отбор

- Приемы **серийного** отбора используются для формирования *серийных или гнездовых выборок*. Они удобны в том случае, если необходимо обследовать сразу "блок" или серию объектов (например, партию товара, продукцию определенной серии или предприятия территориально-административной единицы).

Вся совокупность делится на серии, после чего механическим или собственно случайным способом отбирается некоторое количество серий. Все единицы совокупности, входящие в отобранные серии, подвергаются сплошному контролю.



Метод отбора	Повторный		Бесповторный	
	для средней	для доли	для средней	для доли
Выборка				
Серийная (гнездовая)	$t \sqrt{\frac{\delta_x^2}{r}}$	$t \sqrt{\frac{\delta_w^2}{r}}$	$t \sqrt{\frac{\delta_x^2}{r} \left(1 - \frac{r}{R}\right)}$	$t \sqrt{\frac{\delta_w^2}{r} \left(1 - \frac{r}{R}\right)}$

$r$  – количество отобранных серий

$R$  – общее число серий

$$\delta_{\bar{x}}^2 = \frac{\sum(\bar{x}_i - \bar{x})^2}{r} \quad \bar{x} = \frac{\sum \bar{x}_i}{r}$$

$\delta_{\bar{x}}^2$  - межсерийная дисперсия

$$\delta_W^2 = \frac{\sum(W_i - \bar{W})^2}{r} \quad \bar{W} = \frac{\sum W_i}{r}$$

$\delta_W^2$  - межсерийная выборочная дисперсия для доли

$W_i$  - доля изучаемого признака в  $i$ -той группе

$\bar{W}$  - средняя выборочная доля изучаемого признака

Пример:

*На предприятии 10 бригад. Изучается производительность труда. Отбираются 2 бригады. Средняя производительность труда 1-й бригады – 4,6 тонны, а 2-й – 3 тонны. С вероятностью 0,9973 определить пределы в кот. будет находиться средняя производительность труда рабочих данного предприятия.*

$$t = 3$$

$$\bar{x} = \frac{4,6 + 3}{2} = 3,8m.$$

$$\delta_{\bar{x}}^2 = \frac{(4,6 - 3,8)^2 + (3 - 3,8)^2}{2} = 0,64$$

$$\Delta_{\bar{x}} = 3 \cdot \sqrt{\frac{0,64}{2} \cdot \left(1 - \frac{2}{10}\right)} = 1,5m.$$

$$3,8 - 1,5 \leq \bar{x}_0 \leq 3,8 + 1,5$$

$$2,3 \leq \bar{x}_0 \leq 5,3$$


OTBET:  $2,3 \leq \bar{x}_0 \leq 5,3$

# Типическая выборка

способ проведения типической выборки:

1. вся совокупность делится на типические группы

*пример*



2. из каждой типической группы отбирается некоторое количество единиц

Отбор может быть как **пропорциональным** объёму типических групп, так и **непропорциональным**

# Объем выборки

При отборе, пропорциональном объему типических групп, число наблюдений по каждой группе определяется по формуле:

$$n_i = n \cdot \frac{N_i}{N}$$

$n_i$  -объем выборки из  $i$ -й типической группы.

$n$  -общий объем выборки.

$N_i$  -объем  $i$ -й типической группы в генеральной совокупности.

$N$  -объем генеральной совокупности.

# Типическая выборка: формулы

Метод отбора		Повторный		Бесповторный	
		Для средней	Для доли	Для средней	Для доли
Выборка					
Типическая (при отборе пропорциональном объему групп)		$t \cdot \sqrt{\frac{\sigma_i^2}{n}}$	$t \cdot \sqrt{\frac{w_i \cdot (1 - w_i)}{n}}$	$t \cdot \sqrt{\frac{\sigma_i^2}{n} \cdot (1 - \frac{n}{N})}$	$t \cdot \sqrt{\frac{w_i \cdot (1 - w_i)}{n} \cdot (1 - \frac{n}{N})}$

# Типическая выборка: пример

**Задача.** Определим средний возраст мужчин, вступающих в брак, произведя 5%-ю типическую выборку:

соц. группа	число мужчин $n_i$	средний возраст $\bar{x}_i$	ср. кв. отклонение $\sigma_i$	доля мужчин, вступающих во второй брак. $w_i$
рабочие	60	24	5	0.10
служащие	40	27	8	0.20

С вероятностью 0,954 определить

- 1) пределы, в которых будет находиться средний возраст мужчин, вступающих в брак
- 2) долю мужчин, вступающих в брак во второй раз.



# Типическая выборка: пример

Решение. 1) Средний возраст вступления в брак мужчин находится в пределах

$$\bar{x} - \Delta_{\bar{x}} \leq \bar{x}_0 \leq \bar{x} + \Delta_{\bar{x}}$$

$$\bar{x} = \frac{\sum \bar{x}_i n_i}{\sum n_i} = \frac{24 \cdot 60 + 27 \cdot 40}{100} = 25,2 \text{ года};$$

$$\sigma_i^2 = \frac{\sum \sigma_i^2 n_i}{\sum n_i} = \frac{25 \cdot 60 + 64 \cdot 40}{100} = 40,6$$

# Решение примера типической выборки

$$\Delta_{\bar{x}} = 2 \cdot \sqrt{\frac{40,6}{100} (1 - 0,05)} = 1,2 \text{ года}$$

Таким образом, с вероятностью 0,954 можно утвердить, что средний возраст мужчин, вступающих в брак, принимает значения  **$25,2 \pm 1,2$**  года,

или

$$24 \leq \bar{x} \leq 26,4$$

# Типическая выборка: пример

Решение. 2) Доля мужчин, вступающих в брак во второй раз, находится в пределах

$$\bar{w} - \Delta_w \leq w_0 \leq \bar{w} + \Delta_w$$

$$\bar{w} = \frac{\sum w_i n_i}{\sum n_i} = \frac{0,1 \cdot 60 + 0,2 \cdot 40}{100} = 0,14 = 14\%$$

$$\overline{w_i(1-w_i)} = \frac{\sum w_i(1-w_i)n_i}{\sum n_i} = \frac{(0,1 \cdot 0,9) \cdot 60 + (0,2 \cdot 0,8) \cdot 40}{100} = 0,098$$

# Вывод по примеру типической выборки

$$\Delta_w = 2 \cdot \sqrt{\frac{0,098}{100} (1 - 0,05)} = 0,06 = 6\%$$

Таким образом, с вероятностью 0,954 можно утверждать, что доля мужчин, вступающих в брак во второй раз, принимает значения **14% ± 6%**, или

$$8\% \leq p \leq 20\%$$

# Комбинированный (ступенчатый )

## отбор

может сочетать в себе сразу несколько способов отбора (например, стратифицированный и случайный или случайный и механический); такая выборка называется *комбинированной*.

## Методы отбора

По методу отбора различают *повторную и бесповторную* выборку. *Бесповторным* называется отбор, при котором попавшая в выборку единица не возвращается в исходную совокупность и в дальнейшем выборе не участвует; при этом численность единиц генеральной совокупности  $N$  сокращается в процессе отбора.

При повторном отборе попавшая в выборку единица после регистрации возвращается в генеральную совокупность и таким образом сохраняет равную возможность наряду с другими единицами быть использованной в дальнейшей процедуре отбора; при этом численность единиц генеральной совокупности  $N$  остается неизменной (метод в социально-экономических исследованиях применяется редко). Однако, при большом  $N$  ( $N \rightarrow \infty$ ) формулы для бесповторного отбора приближаются к аналогичным для повторного отбора и практически чаще используются последние ( $N = \text{const}$ ).

# Механическая выборка

При механической выборке вся совокупность делится на группы по числу единиц, которые должны войти в выборку, после чего из каждой группы отбирается 1 единица. Таким образом механическая выборка является бесповторной. Для механической выборки применяются формулы собственно-случайного, бесповторного отбора



Механическая выборка применяется в случаях, когда генеральная совокупность каким либо образом , упорядочена , т.е. имеется определенная последовательность в расположении единиц (табельные номера работников, избирательные списки, телефонные номера респондентов, номера домов и квартир и т.п.)

## Характеристики генеральной и выборочной совокупности

- В основе статистических выводов проведенного исследования лежит распределение случайной величины  $X$ , наблюдаемые же значения  $(x_1, x_2, \dots, x_n)$  называются **реализациями** случайной величины  $X$  ( $n$  – объем выборки).

# Характеристики генеральной и выборочной совокупности

Распределение случайной величины  $X$  в генеральной совокупности носит теоретический, идеальный характер, а ее выборочный аналог является *эмпирическим* распределением.

# Выборочная доля

- **Отношение числа единиц, обладающих данным признаком или данным его значением  $m$ , к общему числу единиц выборочной совокупности  $n$  называется выборочной долей  $w$ :**
- $w = m/n$ .

# Пример

В партии товара, содержащей 10 тыс. штук, при 4% выборке доля выборки  $k$  в абсолютной величине составляет 400 шт. ( $n = N \times 0,04$ ); если же в этой выборке обнаружено 12 бракованных изделий, то выборочная доля брака  $w$  составит 0,03 ( $w = 12/400 = 0,03$  или 3%).

$$\sigma^2 = \frac{\sum (x_i - \bar{x})^2 \cdot n_i}{n}$$

$W_0$ -генеральная доля

$$W_0 = \frac{M}{N}$$

$W$  – выборочная доля

$$W = \frac{m}{n}$$

# Ошибка выборочного наблюдения

Поскольку выборочная совокупность отлична от генеральной, то возникают **ошибки выборки**. При сплошном и выборочном наблюдении могут произойти ошибки двух видов: регистрации и репрезентативности.

# Ошибка выборочного наблюдения

Ошибки *регистрации* могут иметь *случайный* и *систематический* характер. *Случайные* ошибки складываются из множества различных неконтролируемых причин, носят непреднамеренный характер и обычно по совокупности уравнивают друг друга (например, изменения показателей прибора при температурных колебаниях или магнитных бурях).



# Ошибка выборочного наблюдения

*Систематические* ошибки тенденциозны, так как нарушают правила отбора объектов в выборку (например, отклонения в измерениях при изменении настройки измерительного прибора или отбор каждой четвертой квартиры при 25% выборке в доме с четырьмя квартирами на лестничной площадке).

Теоремы закона больших чисел  
устанавливают связь между предельной  
ошибкой выборки, гарантированной с  
определенной вероятностью, числом ( $t$ ) и  
средней ошибкой выборки ( $\mu$ )

При оценке результатов малой выборки величина генеральной дисперсии в расчетах не используется. Для определения возможных пределов ошибки пользуются так называемым **критерием Стьюдента**, определяемым по формуле

$$t = \frac{\tilde{x} - \bar{x}}{\mu_{MB}}$$

где  $\mu_{MB} = \frac{\sigma}{\sqrt{n-1}}$  - мера случайных колебаний выборочной средней в малой выборке.

# Теорема Ляпунова

- А.М. Ляпунов доказал, что распределение выборочных средних ( а следовательно, и их отклонений от генеральной средней ) при достаточно большом числе независимых наблюдений приближенно нормально при условии, что генеральная совокупность обладает конечной средней и ограниченной дисперсией.

# Теорема Ляпунова

- Математически теорему Ляпунова можно записать так:

$$P \left\{ \left| \bar{x} - \tilde{x} \right| \leq \Delta_x \right\} = \frac{1}{\sqrt{2\pi}} \cdot \int_{-t}^t e^{-\frac{t^2}{2}} dt = F(t)$$

где  $\Delta_x = \sqrt{\frac{\sigma^2}{n}}$

- $\pi=3,14$ (математическая постоянная);
- $\Delta_x$  - предельная ошибка выборки, которая дает возможность выяснить, в каких пределах находится величина генеральной средней.

# Ошибка выборочного наблюдения

Параметры эмпирического распределения  $\mu$  и  $s^2$  являются случайными величинами, следовательно, ошибки выборки также являются случайными величинами, могут принимать для разных выборок разные значения и поэтому принято вычислять *среднюю ошибку*.

# Средняя ошибка выборки

$$m = \sqrt{\frac{\sigma^2}{n}}$$

# Средняя ошибка выборки

выражает среднее квадратическое отклонение выборочной средней от математического ожидания. Эта величина при соблюдении принципа случайного отбора зависит прежде всего от объема выборки  $N$  и от степени колеблемости признака: чем больше  $N$  и чем меньше вариация признака (следовательно, и значение  $\sigma^2$ ), тем меньше величина средней ошибки выборки  $m$ .



# Необходимый объем выборки

ФОРМУЛЫ РАСЧЁТА НЕОБХОДИМОЙ ЧИСЛЕННОСТИ ВЫБОРКИ ДЛЯ СОБСТВЕННО-СЛУЧАЙНОГО ОТБОРА

$\mu$	Собственно-случайный отбор	
	повторный	бесповторный
Для средней	$\frac{t^2 \sigma^2}{\Delta^2}$	$\frac{t^2 \sigma^2 N}{N\Delta^2 + t^2 \sigma^2}$
Для доли	$\frac{t^2 w(1-w)}{\Delta^2}$	$\frac{t^2 Nw(1-w)}{N\Delta^2 + t^2 w(1-w)}$

# Задача

В городе 2000 семей.

Предполагается провести  
выборочное  
обследование методом  
случайной бесповторной  
выборки для нахождения  
среднего размера семьи.

Определить необходимую  
численность выборки  
при условии, что с  
вероятностью 0,954 ошибка  
выборки не превысит 1  
человека при среднем  
квадратическом отклонении  
3 человека.

# Формула

$$\Delta_{\bar{x}} = t \sqrt{\frac{\sigma^2}{n} \left( 1 - \frac{n}{N} \right)}$$

# Решение

$$n = \frac{t^2 \cdot \sigma^2 \cdot N}{N \cdot \Delta_{\bar{x}}^2 + t^2 \cdot \sigma^2}$$

# Исходные данные

$$N = 2000$$

$$P = 0,954$$

$$t = 2$$

$$\sigma = 3$$

$$\Delta_{\bar{x}} = 1$$

# Ответ

$$n = \frac{4 \cdot 9 \cdot 2000}{2000 \cdot 1 + 4 \cdot 9} = 36$$

Необходимо обследовать не менее 36 семей.