

МАТЕМАТИЧЕСКАЯ СТАТИСТИКА(МС)

Математическая статистика изучает и разрабатывает методы сбора, обработки и интерпретации статистической информации для получения научных и практических выводов.

Теоретической основой математической статистики являются законы распределения и предельные теоремы закона больших чисел.

ВЫБОРОЧНЫЙ МЕТОД

Определение 1. Вся совокупность единиц,

подвергаемых обследованию на какой-либо признак X , называется **генеральной совокупностью** (Г.С.).

Количество единиц генеральной совокупности называется **объемом Г.С.** и обозначается **N** .

Различают **сплошное и несплошное** обследования единиц Г.С. на некоторый признак X .

К **сплошному** наблюдению (обследованию) относятся, например, перепись населения, медосмотр студентов 1-го курса, ЕГЭ по русскому языку всех без исключения выпускников школ и т.д.

Виды несплошного наблюдения:

- 1) анкетное;
- 2) обследование основного массива;
- 3) монографическое (на какой-либо отдельный признак);
- 4) выборочное.

Определение 2. Единицы, отобранные из Г.С. для обследования на некоторый признак, образуют **выборочную совокупность (в.с.)** или **выборку**.

Количество единиц **в.с.** называется **объемом в.с.** и обозначается **n**.

Выборочное обследование применяется в тех случаях, когда:

- 1) Г.С. очень велика;
- 2) время, выделенное для обследования, ограничено;
- 3) обследование связано с уничтожением обследуемых объектов;
- 4) необходимо проверить точность сплошного наблюдения.

Преимущество выборочного метода в том, что:

- 1) он позволяет экономить силы, средства и время, т.е. является более дешевым и быстрым;

2) позволяет оперативно вмешиваться в ход процесса и вносить коррективы на промежуточных этапах;

3) является более точным и объективным.

Различают 2 способа отбора единиц в **в.с.**:

1) **повторный;**

2) **бесповторный.**

При повторном отборе отобранная единица регистрируется и после обследования на признак **X** возвращается в **Г.С.** и может участвовать в обследовании на другие признаки.

При неповторном отборе отобранная единица регистрируется и после обследования на признак X не возвращается в Г.С.

Виды отбора:

не требующие разбиения Г.С. на группы:

1. Собственно-случайный отбор;
2. Механический отбор;

требующие разбиения Г.С. на группы:

3. Типический отбор;
4. Серийный отбор.

От того, правильно ли организован отбор единиц в в.с., зависят точность и качество результатов и выводов выборочного обследования.

При собственно-случайном отборе каждая единица Г.С. имеет равные шансы попасть в выборку: единицы Г.С. регистрируются, снабжаются номером и участвуют в жеребьевке.

При механическом отборе единицы Г.С. упорядочиваются, и в соответствии с процентом отбора извлекается определенное количество единиц, например, при 25%-й выборке отбирается каждая четвертая единица.

Типический отбор применяется в тех случаях, когда Г.С. неоднородна по составу. Тогда по некоторому признаку Г.С. разбивается на однородные типические группы и из каждой группы

собственно-случайным или механическим способами извлекаются единицы в в.с.

Серийный отбор применяется в тех случаях, когда Г.С. однородна по составу. Тогда вся Г.С. разбивается на группы или **серии** и среди этих серий собственно-случайным или механическим способами извлекаются единицы в в.с.

Выборка должна быть **репрезентативной** (представительной), т.е. должна правильно отражать исследуемый признак Г.С.

Выборочный метод решает следующие задачи:

- 1) Организация выборочной совокупности;
- 2) Вычисление числовых характеристик (параметров) в.с.;
- 3) Оценка параметров Г.С. и выводы о них;
- 4) Определение необходимой численности выборки.

Статистическое распределение выборки

Пусть из Г.С. объемом N отобрана выборка объема n , которая обследуется на некоторый признак X (например, з/плата рабочих, % жирности молока, диаметр деталей и т. д.).

Определение^(вту). Значения признака X : $x_1, x_2, \dots, \dots, x_n$ называются **вариантами**, а упорядоченная последовательность вариантов называется **вариационным рядом**.

Вариационный ряд можно задавать как в виде последовательности значений x_i , так и поинтервально.

Определение^(вту). Число повторений варианты x_i называется ее **частотой** и обозначается m_i , причем

$$\sum_{i=1}^n m_i = n.$$


Последовательность частот m_i называется **частотным рядом**.

Определение^[ВТ]. Соответствие между вариационным и частотным рядами назыв. **статистическим распределением выборки**.

Способы задания статистического распределения выборки: **табличный и графический**.

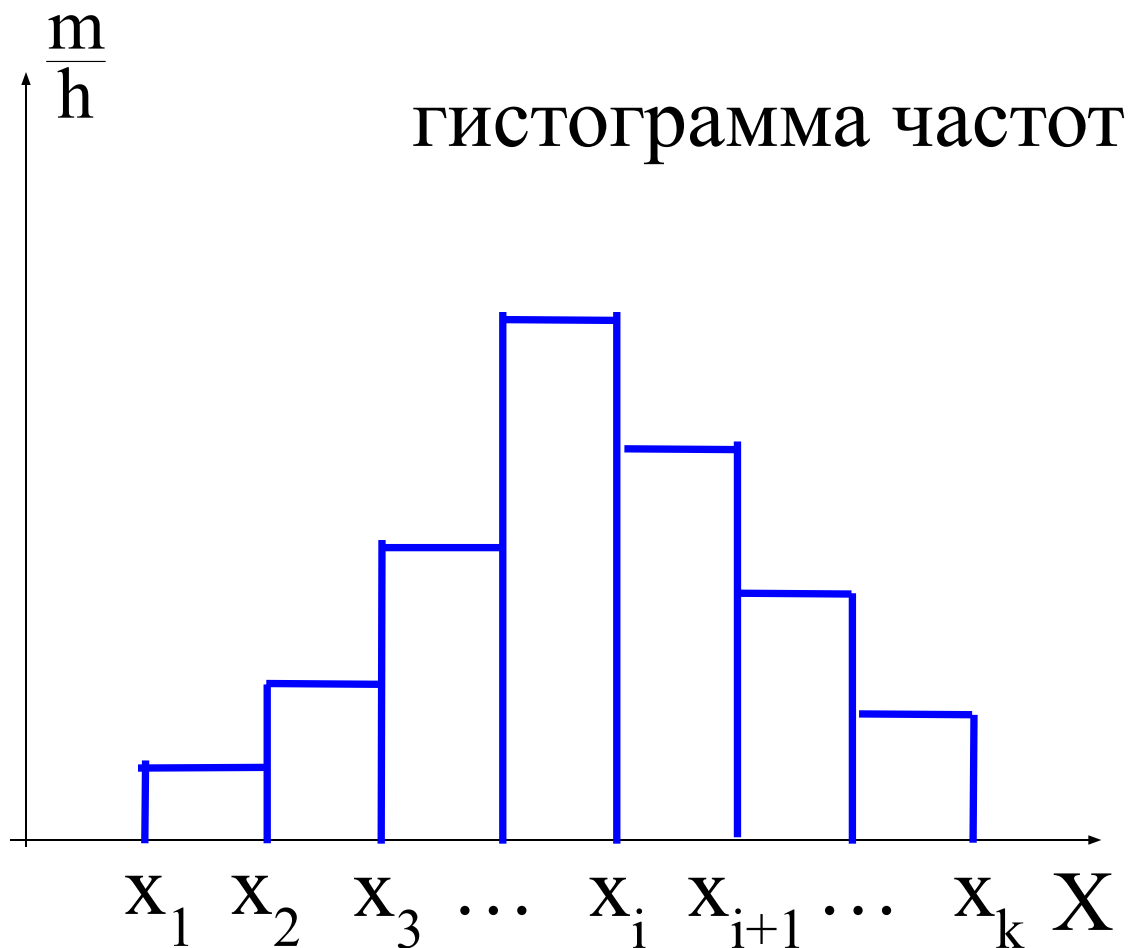
а) вариационный ряд задается в виде последовательности вариант:

X	m
x_1	m_1
x_2	m_2
.....
x_i	m_i
.....
x_n	m_n



б) вариационный ряд задается в виде последовательности интервалов:

X	m
$x_1 - x_2$	m_1
$x_2 - x_3$	m_2
.....
$x_i - x_{i+1}$	m_i
.....
$x_k - x_{k+1}$	m_k



$h = \Delta x_i = x_{i+1} - x_i \quad (i = 1, N), \quad \frac{m_i}{h} - \text{ВЫСОТЫ ПРЯМ-КОВ}$

Числовые характеристики в.с.

Определение. Числовые характеристики (или статистики) – это параметры, которые в сжатой форме отражают особенности Г.С.

К ним относятся:

- 1) **выборочная средняя** – среднее взвешенное значение признака в в.с.:

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

2) **выборочная дисперсия** – среднее взвешенное квадратов отклонений значений признака от среднего значения:

$$\sigma^2(X) = \frac{1}{n} \sum_{i=1}^k (x_i - \bar{x})^2 m_i$$

выборочная дисперсия – мера колеблемости значений признака около среднего значения.

3) **выборочная доля** – доля единиц в в.с., обладающих тем или иным признаком:

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

где m – число единиц в в.с., обладающих исследуемым признаком, n – объем выборки. Тогда $(n - m)$ – число единиц в.с., не обладающих этим признаком, отсюда:

$$1 - w = 1 - \frac{m}{n} = \frac{n - m}{n}$$

Числовые характеристики Г.С.

1) **Генеральная средняя** – среднее взвешенное значение признака в Г.С.:

$$\bar{x} = \frac{1}{N} \sum_{i=1}^L x_i M_i, \quad \text{где} \quad N = \sum_{i=1}^L M_i$$

2) **Генеральная дисперсия** – дисперсия признака в Г.С.:

$$D(X) = \sigma_0^2(X) = \frac{1}{N} \sum_{i=1}^L (x_i - x)^2 M_i$$

3) **Генеральная доля** – доля единиц, обладающих тем или иным признаком в Г.С.:

$$p = \frac{M}{N},$$

где M – число единиц, обладающих этим признаком в Г.С.

Тогда $q = 1 - p = 1 - \frac{M}{N}$

- доля единиц, не обладающих этим признаком в Г.С.

Характеристики в.с. отличаются от соответствующих характеристик Г.С.

Определение. Отклонение характеристик в.с. от соответствующих характеристик Г.С. называется **ошибкой репрезентативности** или **ошибкой выборки**.

Определение. **Средняя ошибка** репрезентативности μ показывает, на сколько в среднем параметры в.с. отклоняются от соответствующих параметров Г.С.

Определение. **Предельная ошибка** репрезентативности Δ показывает наибольшее отклонение характеристики в.с. от соответствующей характеристики Г.С.

Предельная и средняя ошибки выборки связаны между собой соотношением:

$$\Delta = t\mu,$$

где **t** называется **коэффициентом надежности** или **коэффициентом достоверности**.

Оценки параметров распределения

Какую-либо характеристику Г.С. (\bar{x} , σ_0^2 или w) обозначим через θ , а соответствующую характеристику в.с. – через $\tilde{\theta}$.

Определение 1. Оценка генеральной характеристики, заданная одним числом, называется **точечной**.

Определение 2. Оценка генеральной характеристики, заданная двумя числами, называется **интервальной**.

Определение 3. Интервал

$$\tilde{\theta} - \Delta_{\theta} \leq \bar{\theta} \leq \tilde{\theta} + \Delta_{\theta}$$

или

$$|\bar{\theta} - \tilde{\theta}| \leq \Delta_{\theta}$$

называется **доверитель-**

ным интервалом для $\bar{\theta}$, а Δ_{θ} называется **точностью оценки**.

Определение 4. Вероятность того, что $\bar{\theta}$ попадет в доверительный интервал, называется **надежностью γ** оценки $\bar{\theta}$, т.е.:

$$P(|\bar{\theta} - \tilde{\theta}| \leq \Delta_{\theta}) = \gamma$$

Требования к числовым характеристикам

Пусть из Г.С. объема N извлекаются всевозможные повторные выборки объемов n и вычисляются $\tilde{\theta}_i$ – значения $\tilde{\theta}$, затем находят $M(\tilde{\theta})$

Определение. Оценка $\tilde{\theta}$ называется **несмещенной**, если при любом объеме выборки:

$$M(\tilde{\theta}) = \bar{\theta}.$$

Если же $M(\tilde{\theta}) \neq \bar{\theta}$, то оценка называется смещенной.

Определение. Состоятельной называется статистическая оценка $\tilde{\theta}$, которая при $n \rightarrow \infty$ сходится по вероятности к оцениваемому параметру $\bar{\theta}$:

$$\lim_{n \rightarrow \infty} P(|\bar{\theta} - \tilde{\theta}| \leq \Delta) = 1$$

Если имеются несколько несмещенных оценок $\tilde{\theta}$, вычисленных при одинаковых n , то лучшая из них – та, которая имеет минимальный разброс.

Определение. Эффективной называется несмещенная состоятельная оценка $\tilde{\theta}$, которая при заданном n имеет минимальную дисперсию $D(\tilde{\theta})$.

Теорема 1. Математическое ожидание среднего арифметического одинаково распределенных СВ равна математическому ожиданию каждой из этих СВ, а дисперсия среднего арифметического n СВ в n раз меньше дисперсии каждой из них:

$$M\left(\frac{X_1 + X_2 + \dots + X_n}{n}\right) = M(X_i)$$

$$D\left(\frac{X_1 + X_2 + \dots + X_n}{n}\right) = \frac{1}{n} D(X_i)$$

$$\sigma\left(\frac{X_1 + X_2 + \dots + X_n}{n}\right) = \frac{1}{\sqrt{n}} \sigma(X_i)$$

Теорема 2. Выборочная средняя \tilde{x} является **несмещенной и состоятельной оценкой** генеральной средней \bar{x} .

Теорема 3. Выборочная доля w является несмещенной и состоятельной оценкой генеральной доли p .

Теорема 4. Исправленная выборочная дисперсия:

$$S^2(X) = \frac{n}{n-1} \sigma^2(X)$$

является несмещенной и состоятельной оценкой генеральной дисперсии $D(X) = \sigma_0^2(X)$.

Теорема Чебышева-Ляпунова (для средней)

С вероятностью, равной $\Phi(t) = \gamma$, где t – коэффициент надежности, можно утверждать, что отклонение генеральной средней от выборочной

средней по абсолютной величине не превзойдет предельной ошибки выборки Δ_x :

$$P(|\bar{x} - \tilde{x}| \leq \Delta_x) = \Phi(t) = \gamma,$$

где предельная ошибка выборки для средней при собственно-случайном отборе:

$$\Delta_{\text{хповт}} = t \sqrt{\frac{\sigma_x^2}{n}} \quad \text{- для повторного отбора;}$$

$$\Delta_{\text{хбесповт}} = t \sqrt{\frac{\sigma_x^2}{n} \left(1 - \frac{n}{N}\right)} \quad \text{- для бесповторного отбора}$$

Значение $\gamma = \Phi(t)$ отыскивается в таблице
Приложения 2.

Теорема Чебышева-Ляпунова (для доли)

С вероятностью, равной $\Phi(t) = \gamma$ можно утверждать, что абсолютная величина отклонения генеральной доли от выборочной доли не превзойдет предельной ошибки выборки Δ_w :

$$P(| p - w | \leq \Delta_w) = \Phi(t) = \gamma,$$

где предельная ошибка выборки для доли при собственно-случайном отборе:

$$\Delta_{w_{\text{повт}}} = t \sqrt{\frac{w(1-w)}{n}} \quad \text{- для повторного отбора;}$$

$$\Delta_{w_{\text{бесп}}} = t \sqrt{\frac{w(1-w)}{n} \left(1 - \frac{n}{N}\right)} \quad \text{- для бесповторного отбора}$$

Из теорем Чебышева-Ляпунова следует, что с вероятностью $\gamma = \Phi(t)$ **доверительный интервал для генеральной средней:**

$$\tilde{x} - \Delta_x \leq \bar{x} \leq \tilde{x} + \Delta_x ,$$

а доверительный интервал для генеральной доли:

$$w - \Delta_w \leq p \leq w + \Delta_w$$

Из формулы:

$$\Delta_x = t \sqrt{\frac{\sigma_x^2}{n}}$$

следует, что, чем больше объем в.с. n , тем меньше предельная ошибка Δ_x , а значит, и средняя ошибка

$$\mu_x = \sqrt{\frac{\sigma_x^2}{n}}$$

С другой стороны, чем выше надежность $\Phi(t)$, тем больше коэффициент надежности t и тем больше ошибка Δ_x . При бесповторном отборе:

$$\Delta_{x\text{бесповт}} < \Delta_{x\text{повт}},$$

а значит, доверительный интервал точнее, чем при повторном отборе. Такие же выводы справедливы для ошибок Δ_w по доле.

Приведенные выше формулы предельных ошибок для средней и для доли имеют место при собственно-случайном отборе. Все формулы,

приведенные для собственно- случайного отбора, справедливы и для механического способа отбора.

Сводка формул для собственно- случайного и механического способов отбора

N – объем Г.С., **n** – объем в.с.

Характеристики в.с.

$\bar{x} = \frac{1}{n} \sum_{i=1}^k x_i m_i$ - выборочная средняя, где **k** – число вариантов вариационного ряда

$$\mathbf{n} = \sum_{i=1}^k m_i$$

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

$$w = \frac{m}{n} - \text{выборочная доля}$$

Ошибки репрезентативности(выборки)

Для средней: $\Delta_{\text{хповт}} = t \sqrt{\frac{\sigma_x^2}{n}}$, $\Delta_{\text{хбесп}} = t \sqrt{\frac{\sigma_x^2}{n} \left(1 - \frac{n}{N}\right)}$

$$\mu_{\text{хповт}} = \sqrt{\frac{\sigma_x^2}{n}}, \quad \mu_{\text{хбесп}} = \sqrt{\frac{\sigma_x^2}{n} \left(1 - \frac{n}{N}\right)}$$

Для доли: $\Delta_{\text{wповт}} = t \sqrt{\frac{\sigma_w^2}{n}}$, $\Delta_{\text{wbесп}} = t \sqrt{\frac{\sigma_w^2}{n} \left(1 - \frac{n}{N}\right)}$

$$\mu_{\text{вповт}} = \sqrt{\frac{\sigma_w^2}{n}}, \quad \mu_{\text{вбесп}} = \sqrt{\frac{\sigma_w^2}{n} \left(1 - \frac{n}{N}\right)}$$

Доверительные интервалы

Для средней: $\tilde{x} - \Delta_x \leq \bar{x} \leq \tilde{x} + \Delta_x$

Для доли: $w - \Delta_w \leq p \leq w + \Delta_w$

**Сводка формул для типического
способа отбора**

N – объем Г.С., n – объем в.с.;

l – количество типических групп;

k_j – число вариантов в j -й типической группе ($j = \overline{1, l}$)

N_j - объем j -й типической группы в Г.С.;

n_j - объем j -й типической группы в в.с.;

$$n_j = \sum_{i=1}^{k_j} m_i, \quad \mathbf{n} = \sum_{j=1}^l n_j$$

Внутригрупповые характеристики
 j -й типической группы

$\tilde{x}_j = \frac{1}{n_j} \sum_{i=1}^{k_j} x_i m_i$ - внутригрупповая средняя j -й
типической группы;

$\sigma_j^2 = \frac{1}{n_j} \sum_{i=1}^{k_j} (x_i - \tilde{x}_j)^2 m_j$ - внутригрупповая дисперсия;

$w_j = \frac{m_j}{n_j}$ - внутригрупповая доля

Общие(межгрупповые) характеристики в.с.

$\tilde{x} = \frac{1}{n} \sum_{j=1}^1 \tilde{x}_j n_j$ - общая(межгрупповая) средняя;

$\sigma_x^2 = \frac{1}{n} \sum_{j=1}^1 \sigma_j^2 n_j$ - общая дисперсия по средней;

$w = \frac{1}{n} \sum_{j=1}^1 w_j n_j$ - общая доля;

$\sigma_w^2 = \frac{1}{n} \sum_{j=1}^1 w_j(1-w_j)n_j$ - общая дисперсия по доле;

Предельные ошибки выборки

Для средней: $\Delta_{\text{хповт}} = t \sqrt{\frac{\sigma_x^2}{n}}$, $\Delta_{\text{хбесповт}} = t \sqrt{\frac{\sigma_x^2}{n} \left(1 - \frac{n}{N}\right)}$

Для доли: $\Delta_{\text{wповт}} = t \sqrt{\frac{\sigma_w^2}{n}}$, $\Delta_{\text{wbесп}} = t \sqrt{\frac{\sigma_w^2}{n} \left(1 - \frac{n}{N}\right)}$

Доверительные интервалы записываются так же, как и при собственно-случайном отборе.

Сводка формул для серийного способа отбора

S – общее число серий в Г.С.

s – число серий, отобранных в в.с.

j – номер серии, $j = \overline{1, s}$.

\tilde{x}_j – средняя в j –й серии;

w_j – доля в j –й серии;

Общие характеристики в.с.

$$\tilde{x} = \frac{1}{s} \sum_{j=1}^s \tilde{x}_j ; \quad \sigma_x^2 = \frac{1}{s} \sum_{j=1}^s (\tilde{x}_j - \tilde{x})^2$$

$$w = \frac{1}{s} \sum_{j=1}^s w_j ; \quad \sigma_w^2 = \frac{1}{s} \sum_{j=1}^s (w_j - w)^2$$

Пределные ошибки

$$\Delta_{x \text{ ПОВТ}} = \mathbf{t} \cdot \sqrt{\frac{\sigma_x^2}{s}}, \quad \Delta_{x \text{ ПОВТ}} = \mathbf{t} \cdot \sqrt{\frac{\sigma_x^2}{s}},$$

$$\Delta_{x \text{ ПОВТ}} = \mathbf{t} \cdot \sqrt{\frac{\sigma_x^2}{s}}, \quad \Delta_{x \text{ ПОВТ}} = \mathbf{t} \cdot \sqrt{\frac{\sigma_x^2}{s}},$$