

Лекция 2: Характеристика данных выборки и генеральной совокупности

1. Принципы подбора выборки
2. Гистограмма и полигон частот как приближение кривой распределения случайной величины
3. Параметры распределения и их влияние на вид кривой распределения

1 Принципы подбора выборки

Результат эксперимента - некоторая совокупность измерений, которую можно рассматривать как случайный вектор (вектор значений случайной величины).

Однократные измерения допускаются только в виде исключения!

Генеральная совокупность – полный набор всех возможных значений, которые может принимать случайная величина.

У исследователя никогда нет генеральной совокупности, а есть выборка ограниченного объема, по которой необходимо определить характеристики генеральной совокупности.

Выборка – набор значений величины $\{x_i\}$, полученный из генеральной совокупности в результате конечного числа испытаний N . Количество данных в выборке – ее **объем**.

Для проведения исследований необходимо, чтобы характер поведения данных в выборке как можно более точно повторял характер поведения данных в генеральной совокупности.

При отборе элементов выборки возможны **ошибки репрезентативности**. Классический пример: «Литрери Дайджест», выборы президента США в 1936 г. выборка: подписчики + абоненты телефонного справочника + автовладельцы. Вернулось 2,5 млн бюллетеней

57% республиканец Альф Лэндон	выиграл Рузвельт (более 60% голосов)
40% демократ Франклин Рузвельт	

Репрезентативность выборки достигается **рандомизацией** или случайным отбором членов из генеральной совокупности. Это обеспечивает равную возможность для всех членов генеральной совокупности попасть в состав выборки. На практике применяются принципы частичной рандомизации.

Статистический анализ выборочных данных позволяет:

- дать для больших выборок общие характеристики, отражающие центральную тенденцию ($M(x)$, $D(x)$);
- сравнивать выборки, оценивать их общие характеристики, определять вероятность того, что различия вызваны случайными причинами;
- получить сведения о взаимосвязях элементов в выборке;
- применить результаты анализа для предсказания и описания.

2 Гистограмма и полигон частот как приближение кривой распределения случайной величины

Предварительная обработка данных начинается с определения того, какими типами переменных представлены данные.

Типы переменных (признаков) представления данных:

- **непрерывные** – представлены действительными числами (например, длина или вес);
- **дискретные** – представлены целыми, как правило, положительными числами;
- **категориальные** (например, марка кабеля, тип материала, географический регион). Значения категориальных данных не могут быть положены на числовую прямую.

Построение **гистограммы** или **полигона частот** - самый простой способ наглядного представления о распределении вероятности выпадения того или иного значения случайной величины по выборке.

Пусть выборка из экспериментальных данных: $x = \{x_1, \dots, x_N\}$.


Алгоритм построения гистограммы и полигона частот

1. Построение вариационного ряда $x_1 \leq x_2 \leq \dots \leq x_N$
2. Группировка данных: разбиение отрезка $[x_1, x_N]$ на «карманы». Как и на сколько «карманов» разбивать?
Рассмотрим разбиение на «карманы» равной длины.


Определение числа «карманов»

- по правилу Стерджесса: $n = 1 + 3,322 \cdot \lg N$, 
- по формуле Брукса и Каррузера: $n = 5 \cdot \lg N$
- по формуле: $n = \sqrt{N}$


n интервалов



n интервалов




n интервалов



$$\Delta = \frac{x_N - x_1}{n},$$

$$a_1 = x_1, \quad b_n = x_N, \quad a_i = b_{i-1}, \quad \text{для } i = 2 \dots n$$

n интервалов




$$a_i = x_1 + (i-1)\Delta,$$
$$b_{ix} = x_1 + i\Delta$$

3. Вычисление числа значений, попавших в каждый интервал и построение (нормированной) *гистограммы*

$$T_i = \sum_{j=1}^N t_{j,i}, \quad t_{j,i} = \begin{cases} 1, & \text{если } x_j \in [a_i, b_i], \\ 0, & \text{если } x_j \notin [a_i, b_i]. \end{cases} \quad h_i = \frac{T_i}{N \cdot \Delta} \quad \text{- нормировка } T_i$$

ИЛИ

4. Определение координат центров отрезков c_i и построение *полигона (относительных) частот* – ломанной по точкам (c_i, T_i) или (c_i, h_i)



$h_i \cdot \Delta$ - вероятность попадания результата отдельно измерения в данный интервал. Полная вероятность равна 1, значит

$$\sum_{i=1}^N h_i \Delta = 1$$

При увеличении числа измерений в пределе получаем вместо гистограммы **кривую распределения** – график **функции плотности вероятности $f(x)$** .

Следовательно,

$$\int_{-\infty}^{+\infty} f(x) dx = 1$$


Вероятность попадания измеряемой величины в интервал $(-\infty, x]$ называют **функцией распределения** или **интегральной функцией распределения**:

$$F(x) = \int_{-\infty}^x f(z) dz$$

Исходя из определения,

$$F(-\infty) = 0 \quad F(+\infty) = 1 \quad P(x_1 < x < x_2) \equiv \int_{x_1}^{x_2} f(x) dx = F(x_2) - F(x_1)$$


3 Параметры распределения и их влияние на вид кривой распределения (котики)



Котики бывают разные. Как же выглядит типичный котик?

Для простоты рассмотрим одно свойство котиков: **размер**.

1 способ: какой размер котиков встречается чаще всего? Этот показатель называется **МОДА**



Частота моды = 3

Учебно-исследовательская работа. Лекция 2

2 способ: упорядочить всех котиков по размеру и найти середину этого ряда. Как правило, там находится котик, который обладает самым типичным размером. И этот размер называется **МЕДИАНОЙ**.



Если по середине два котика (общее число котиков, N – четное)
МЕДИАНА = сложить размеры двух средних котов и поделить пополам



3 способ: сложить размер всех котиков, поделить на их количество – найти **СРЕДНЕЕ ЗНАЧЕНИЕ**.



/ 3



Среднее значение



\bar{x}

НО!


СРЕДНЕЕ ЗНАЧЕНИЕ чувствительно к **ВЫБРОСАМ** (при их наличии перестает отражать типичный котиковый размер)

Чтобы избавиться от **ВЫБРОСОВ**

а) либо убирают по 5—10% самых больших и самых маленьких котиков и уже от оставшихся считают среднее - **УСЕЧЕННОЕ (ИЛИ УРЕЗАННОЕ) СРЕДНЕЕ**;



Выброс



Котики для усеченного среднего

б) вместо **СРЕДНЕГО** используют **МЕДИАНУ**

МОДА, МЕДИАНА, СРЕДНЕЕ ЗНАЧЕНИЕ - это основные методы нахождения типичного размера котиков.

Все вместе они называются **МЕРАМИ ЦЕНТРАЛЬНОЙ ТЕНДЕНЦИИ**.

Кроме типичности нас часто интересует, насколько разнообразными могут быть котики по размеру. И в этом нам помогают **МЕРЫ ИЗМЕНЧИВОСТИ**:

1) **РАЗМАХ** - разность между самым большим и самым маленьким котиком. Эта мера очень чувствительна к выбросам.

Чтобы избежать искажений применяют **МЕЖКВАРТИЛЬНЫЙ РАЗМАХ** - отсеивают 25% самых больших и 25% самых маленьких котиков и найти размах для оставшихся.



Размах

Учебно-исследовательская
работа. Лекция 2


2) **ОТКЛОНЕНИЕ** - разность между размером нашего конкретного котика (Барсика) и средним котиковым размером



Отклонение



Средний котик



Барсик

Чем крупнее (мельче) Барсик, тем больше **ОТКЛОНЕНИЕ**.

Чем больше котиков с **ОТКЛОНЕНИЕМ**, тем более разнообразны котики по размеру.



/ 3


Какое **ОТКЛОНЕНИЕ** наиболее типично для котиков? Можно найти его **СРЕДНЕЕ ЗНАЧЕНИЕ!**

НО! СРЕДНЕЕ ЗНАЧЕНИЕ ОТКЛОНЕНИЙ = 0 (из-за знаков **ОТКЛОНЕНИЙ**)

Избавиться от знака в математике можно двумя способами:


а) возвести в квадрат. Среднее от квадратов отклонений называется **ДИСПЕРСИЕЙ** (для оценки не сильно удобна, т.к. единицы измерения в квадрате)

б) взять корень квадратный из дисперсии и получить **СРЕДНЕКВАДРАТИЧЕСКОЕ ОТКЛОНЕНИЕ**



/ 3

Дисперсия D



/ 3

Среднеквадратическое отклонение S

Обе меры чувствительны к **ВЫБРОСАМ**.

МЕРЫ ЦЕНТРАЛЬНОЙ ТЕНДЕНЦИИ и **МЕРЫ ИЗМЕНЧИВОСТИ** очень часто совместно используются для описания той или иной группы котиков, т.к. как правило большинство (около 68%) котиков находятся в пределах **СРЕДНЕКВАДРАТИЧЕСКОГО ОТКЛОНЕНИЯ** от **СРЕДНЕГО ЗНАЧЕНИЯ**.

Оставшиеся 32% либо очень большие, либо очень маленькие.

Для большинства котиковых признаков имеет место такая картина:




График называется **НОРМАЛЬНЫМ РАСПРЕДЕЛЕНИЕМ ПРИЗНАКА**.


Математически:

Центр распределения характеризуется *средним значением μ* , *медианой Me* и *модой Mo* .

Среднее значение (первый начальный момент) равно математическому ожиданию случайной величины:

$$\mu = R_1 = \frac{1}{N} \sum_{i=1}^N x_i = \int_{-\infty}^{+\infty} x f(x) dx$$

R_1 - центр тяжести
в геометрии распределения.




Медиана делит площадь, ограниченную функцией плотности вероятности, на две равные части $P(X \leq Me) = F(Me) = 0,5$

Мода является наиболее вероятным значением случайной величины, то есть соответствует значению x , для которого $f(x) = \max$

Рассеяние случайных величин вокруг центра группирования оценивается **дисперсией**, **стандартным отклонением**, **коэффициентом вариации** и **размахом**.

Дисперсия (второй момент) – это математическое ожидание квадрата отклонения случайной величины от их среднего арифметического значения.

$$D_x = R_2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 = \int_{-\infty}^{+\infty} (x - \mu)^2 f(x) dx$$



Среднее квадратическое отклонение, СКО:

$$\sigma = \sqrt{D} = \sqrt{\frac{\sum_{i=1}^N (x - M_x)^2}{N}}$$

Стандартное отклонение:


$$s = \sqrt{\frac{\sum_{i=1}^N (x - M_x)^2}{N - 1}}$$

Коэффициент вариации – отношение стандартного отклонения к математическому ожиданию случайной величины.

Размах $w = x_{\max} - x_{\min}$



Другие меры для описания характера кривой распределения признака (распределения в обоих случаях сравниваются с нормальным):

- симметричность распределения (к-т асимметрии);
- вес хвостов распределения (тяжелые или лёгкие – к-т эксцесса).




Вес хвоста распределения

- «легкие» хвосты содержат лишь несколько значений. На графике плотности вероятности тонкие и длинные;
- «тяжелые» хвосты содержат довольно много значений. На графике выглядят толстыми.




Мнемоническое правило:



Скошенность распределения, когда один хвост кривой распределения крутой, а другой - пологий, характеризует **коэффициент асимметрии**, a_3 .

$$a_3 = \frac{R_3}{s^3} = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - M_x)^3}{s^3} = \frac{1}{s_{cm}^3} \int_{-\infty}^{\infty} (x - M_x)^3 f(x) dx$$

Скошенность нормального распределения = 0.



Синим – симметричное ($a_3=0$).

Черным - положительная асимметрия ($a_3>0$).

Красным - отрицательная асимметрия ($a_3<0$).

Вес хвостов распределения описывается **коэффициентом эксцесса (куртозиса) a_4** .

$$a_4 = \frac{R_4}{\sigma_{cm}^4} - 3 = \frac{\frac{1}{N} \sum_{i=1}^N (x_i - M_x)^4}{\sigma_{cm}^4} - 3 = \frac{1}{\sigma_{cm}^4} \int_{-\infty}^{\infty} (x - M_x)^4 f(x) dx - 3$$

«-3» в формуле для того, чтобы облегчить сравнение с нормальным распределением.

У нормального распределения $a_3=0$;

у распределения с «легкими» хвостами $a_3>0$;

у распределения с «тяжелыми» хвостами $a_3<0$.

Квантиль - значение, которое заданная случайная величина не превышает с фиксированной вероятностью. Т.е. квантиль можно рассматривать как обратную величину функции $F(x)$.