

ДИСПЕРСИОННЫЙ АНАЛИЗ

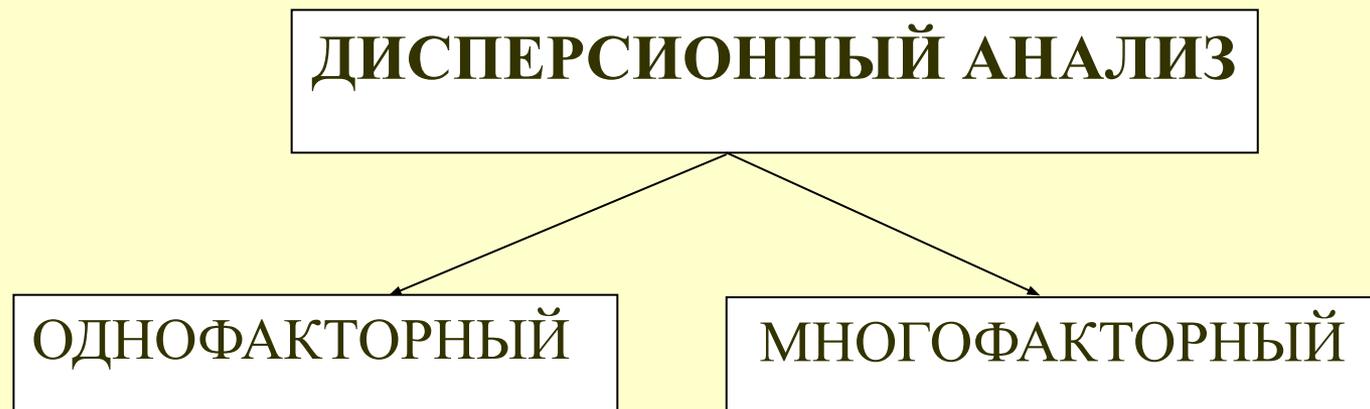
Лекция 7

План лекции:

- Виды дисперсионного анализа и его характеристики
- Этапы дисперсионного анализа
- Формулы для однофакторного дисперсионного анализа
- Сила влияния фактора
- Достоверность влияния фактора

Виды дисперсионного анализа и его характеристики

Раздел статистики, изучающий влияние факторов на изменчивость случайной величины, называется **дисперсионным анализом**.



Условия:

- изучаемые факторы должны быть независимыми;
- распределение выборочных данных должно соответствовать нормальному распределению или сводится к нему путем соответствующих преобразований

$x - \mu = A + e$, где μ – средняя арифметическая генеральной совокупности;

x – конкретное значение переменной;

A – доля отклонения переменной, связанная с влиянием данного конкретного фактора;

e – остаточная часть отклонения, не объяснимая влиянием данного фактора.

- Признаки, изменяющиеся под влиянием тех или иных причин, называются результативными.
- Сами причины называются факторами.
- Конкретное числовое значение фактора называется градацией (или уровнем) фактора.
- Степень изменения всех признаков и отклонение их от средней арифметической ряда характеризуется дисперсией $D(x)$:

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

$$D_{\text{общ}} = D_{\text{факт}} + D_{\text{случ}}$$

$$F = \frac{D_{\text{факт}}}{D_{\text{случ}}} \quad - \text{ критерий Фишера}$$

Если $F > F_{\text{кр}}$ (при вероятности $P=0,95$), то влияние фактора **существенно**. Если $F < F_{\text{кр}}$ (вероятность $P < 0,95$), фактор **не влияет** на изучаемый признак.

Этапы дисперсионного анализа:

- Представить данные в виде таблицы.

Номер наблюдения (j)	Уровни фактора(i)					
	1	2	3	...	I	a
1	x_{11}	x_{21}	x_{31}		x_{i1}	x_{a1}
2	x_{12}	x_{22}	x_{32}		x_{i2}	x_{a2}
...						
j	x_{1j}	x_{2j}	x_{3j}		x_{ij}	x_{aj}
n	x_{1n}	x_{2n}	x_{3n}		x_{in}	x_{an}
Суммы по группам:	$\sum x_1$	$\sum x_2$	$\sum x_3$		$\sum x_i$	$\sum x_a$
Средние по группам:	\bar{X}_1	\bar{X}_2	\bar{X}_3		\bar{X}_i	\bar{X}_a

i – индекс уровня фактора (от 1 до a);

j – индекс варианты (от 1 до n).

- Общее варьирование всех вариантов (x_{ij}), независимо от того, в какой группе они находятся, вокруг общей средней \bar{X} характеризуется дисперсией $D_{\text{общ.}}$.

$$D_{\text{общ.}} = \frac{\sum_{ij} (x_{ij} - \bar{X})^2}{N - 1}$$

где $N = a \cdot n$ – число всех вариантов;
 $df_{\text{общ.}} = N - 1$ – число степеней свободы.

- Варьирование групповых средних \bar{X}_i или средних каждого уровня данного изучаемого фактора вокруг общей средней \bar{X} , характеризуется факторной дисперсией $D_{\text{факт}}$.

$$D_{\text{факт}} = \frac{\sum_i n_i (\bar{X}_i - \bar{X})^2}{a - 1}$$

$df_{\text{факт}} = a - 1$ – число степеней свободы.

n_i – среднее число вариантов в каждой группе,

n – если число вариантов в группах одинаково.

- Варьирование вариант x_{ij} внутри каждой группы вокруг каждой групповой средней \bar{x}_i характеризует случайная или остаточная дисперсия $D_{\text{случ}}$.

$$D_{\text{случ}} = \frac{\sum_i \left[\sum_j (x_{ij} - \bar{x}_i)^2 \right]}{N - a}$$

$df_{\text{случ}} = N - a$ – число степеней свободы.

Причем: **$(N - a) + (a - 1) = N - 1$**

Формулы для однофакторного дисперсионного анализа

Источник варьирования	Сумма квадратов SS (числитель)	Число степеней свободы df (знаменатель)	Формулы для дисперсии MS
Общее (все варианты)	$\sum_{ij} (x_{ij} - \bar{x})^2$	N - 1	$\frac{1}{N-1} \sum_{ij} (x_{ij} - \bar{x})^2$
Групповые средние (фактор A)	$\sum_i n_i (\bar{x}_i - \bar{x})^2$	a - 1	$\frac{1}{a-1} \sum_i n_i (\bar{x}_i - \bar{x})^2$
Варианты внутри групп (случайные отклонения)	$\sum_i \left[\sum_j (x_{ij} - \bar{x}_i)^2 \right]$	N - a	$\frac{1}{N-a} \sum_i \left[\sum_j (x_{ij} - \bar{x}_i)^2 \right]$

Пример. Провести однофакторный дисперсионный анализ для выяснения влияния дозы удобрения (кг) на урожайность (ц/га).

№	$A_1=15$	$A_2=20$	$A_3=25$	$A_4=30$
	x_{1j}	x_{2j}	x_{3j}	x_{4j}
1	8	8,2	11,8	7,5
2	8,4	9	13	8,5
3	9	10	12,5	6,4
4	8,7	10	10	9
5	8,3	9,2	13,1	8,1
6	8,5	10	12	7

$$\bar{x}_i = \begin{matrix} 8,5 & 9,1 & 12,1 & 7,8 \end{matrix}$$

$$\sum x_i = \begin{matrix} 50,9 & 56,4 & 72,4 & 46,5 \end{matrix}$$

$$(\sum x_i)^2 = \begin{matrix} 2590,81 & 3180,96 & 5097,96 & 2162,25 \end{matrix}$$

$$\sum x_{ij} = 226,2; \quad \left(\sum x_{ij}\right)^2 = 226,2^2 = 51166,44 \quad \sum x_{ij}^2 = 2210,44$$

Вычисления:

- Сумма квадратов $SS_{\text{общ}}$ для общей вариации:

$$SS_{\text{общ}} = \sum x_{ij}^2 - \frac{(\sum x_{ij})^2}{N} = 2210,44 - \frac{51166,44}{24} = 78,505$$

- Сумма квадратов $SS_{\text{факт}}$ для вариации между группами:

$$SS_{\text{факт}} = \frac{1}{n} \sum (\sum x_i)^2 - \frac{(\sum x_{ij})^2}{N} = \frac{1}{6} 13175,78 - \frac{51166,44}{24} = 64,03$$

Средний квадрат, характеризующий факторную дисперсию $MS_{\text{факт}}$:

$$MS_{\text{факт}} = \frac{SS_{\text{факт}}}{df_{\text{факт}}} = \frac{64,03}{3} = 21,34$$

- Сумма квадратов $SS_{случ}$ для вариации внутри групп:

$$SS_{сл} = SS_{общ} - SS_{фак} = 78,505 - 64,03 = 14,475$$

- Сумма квадратов $SS_{случ}$ для вариации внутри групп:

$$MS_{сл} = \frac{SS_{сл}}{df_{сл}} = \frac{14,475}{20} = 0,724$$

$$\text{т.к. } MS_{случ} < MS_{фак}, \quad F = \frac{MS_{фак}}{MS_{сл}} = \frac{21,34}{0,724} = 29,475$$

$$\text{а } F_{теор} = 3,1 \text{ для } P=0,95 \text{ и } df_{сл} = 20 \text{ и } df_{фак} = 3$$

ВЛИЯНИЕ ФАКТОРА ДОСТОВЕРНО!

Сила влияния фактора

- Сила влияния фактора η_A^2 определяется:

$$\eta_A^2 = \frac{D_{\text{факт.}}}{D_{\text{факт.}} + D_{\text{случ.}}} \quad \text{где}$$

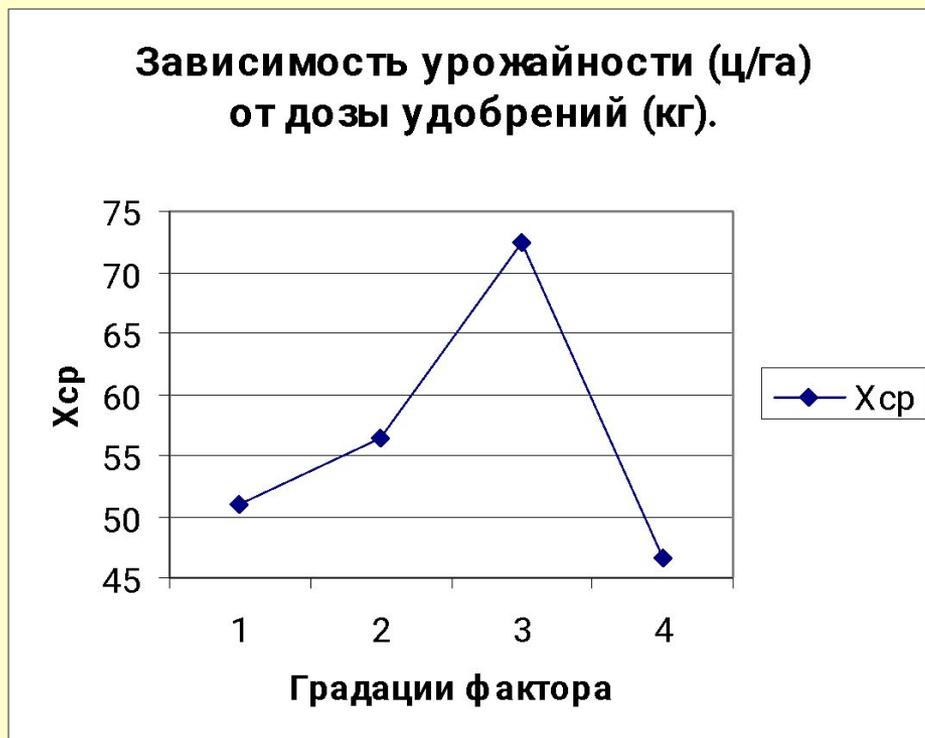
$$D_{\text{факт}} = \frac{MS_{\text{факт.}} - MS_{\text{случ.}}}{n} = \frac{MS_{\text{факт.}} - D_{\text{случ.}}}{n}$$

В нашем случае $D_{\text{факт}} = \frac{21,34 - 0,724}{6} = 3,436$

$$\eta_A^2 = \frac{D_{\text{факт.}}}{D_{\text{факт.}} + D_{\text{случ.}}} = \frac{3,436}{3,436 + 0,724} = 0,826$$

Вывод:

82,6% от действия всех факторов приходится на дозу удобрения, 17,4% – приходится на долю случайных факторов.



Для выявления наиболее эффективной дозы удобрения построим график

Достоверность влияния фактора

- Дисперсионный анализ позволяет установить, существуют ли **достоверные различия** между отдельными **уровнями** фактора.

$$S_d = \sqrt{\frac{D_{случ.}}{n}} \quad n - \text{число вариантов в каждой группе.}$$

- Отношение разницы d к ее ошибке S_d , т.е. $t = \frac{d}{S_d}$, должно быть таким, чтобы оно гарантировало достоверность не менее чем при $P=0,95$.

- Коэффициент Q, рассчитан для разного количества **групп a** и степеней свободы **df_{случ.}**

$$S_d = \sqrt{\frac{D_{случ.}}{n}} = \sqrt{\frac{0,724}{6}} = 0,35;$$

$$d_{12} = 9,1 - 8,5 = 0,6;$$

$$d_{23} = 12,1 - 9,1 = 3;$$

$$t_{12} = \frac{d_{12}}{S_d} = \frac{0,6}{0,35} = 1,7;$$

$$t_{23} = \frac{d_{23}}{S_d} = \frac{3}{0,35} = 8,57;$$

Q=4 для df_{случ.}=20 и a=4;

$t_{12} < Q$, разница **не достоверна!**

$t_{23} > Q$, разница **достоверна!**

Вывод:

Внесение удобрений достоверно влияет на урожайность посевов. Наибольшую эффективность имеет фактор (удобрение), градация которого равна $A_3=25$ кг.



БЛАГОДАРЮ ЗА ВНИМАНИЕ