

Дисперсионный анализ

План.


1. Сущность дисперсионного анализа. Градации факторов и их анализ.
2. Простейшая схема варьирования при различии по одному фактору.
3. Рабочие формулы для вычисления дисперсий.
4. Вычисление F- критерия для определения влияния изучаемого фактора в общей изменчивости изучаемого признака.
5. Количественная оценка влияния отдельных факторов.

Сущность дисперсионного анализа.

Установление роли отдельных факторов в изменчивости того или иного признака.

Дисперсионный анализ позволяет оценивать значимость влияния отдельных факторов, а так же их относительную роль в общей изменчивости признака.

Основатель дисперсионного анализа –
Рональд Фишер.



В фактическом отклонении варианты от средней генеральной совокупности фигурируют два компонента:

- та часть отклонения, которая зависит именно от данного фактора – **A**;
- остаточная часть, независящая от данного фактора – **e**.

В таком случае можно сравнивать **A** и **e**.

При достоверном влиянии изучаемого фактора значение **A** будет превышать значение **e**.

По степени превышения **A** над **e** можно судить о том, насколько достоверно влияние данного фактора.

Разберём простейшую схему, когда анализируется влияние одного фактора, могущего принимать разные градации, или количественные уровни: **1,2,3... i ...a.**

Отдельные наблюдения (варианты) разбиваются на группы согласно этим градациям фактора.

Количество **наблюдений** в одном уровне: **1,2,3 ...j ...n.**

Распределение вариантов при различии по одному фактору

	Отдельные варианты (наблюдения)						$\sum X_i = T_i$	T_i^2
	1	2	...	j	...	n		
1	X_{11}	X_{12}		X_{1j}		X_{1n}	$\sum X_1 = T_1$	T_1^2
2	X_{21}	X_{22}		X_{2j}		X_{2n}	$\sum X_2 = T_2$	T_2^2
:	:	:	:	:	:	:	:	:
i	X_{i1}	X_{i2}		X_{ij}		X_{in}	$\sum X_i = T_i$	T_i^2
:	:	:	:	:	:	:	:	:
a	X_{a1}	X_{a2}		X_{aj}		X_{an}	$\sum X_a = T_a$	T_a^2
							$\sum T_i = T$	$\sum T_i^2 =$
							$T^2 =$	

**Найдём сумму квадратов, составив
дополнительную таблицу ($\sum X_{ij}^2$).**

$$\sum X_i^2$$

X_{11}^2	X_{12}^2	...	X_{1j}^2	...	X_{1n}^2	
X_{21}^2	X_{22}^2	...	X_{2j}^2	...	X_{2n}^2	
...		
X_{i1}^2	X_{i2}^2	...	X_{ij}^2	...	X_{in}^2	
...		
X_{a1}^2	X_{a2}^2	...	X_{aj}^2	...	X_{an}^2	
						$\sum X_{ij}^2$

Степени свободы.

Для общей дисперсии: $k_0 = N - 1$

Для факториальной дисперсии: $k_A = a - 1$

Для остаточной дисперсии: $k_e = N - a$

$$N = a \cdot n$$

Формулы для вычисления дисперсий.

1. Общая дисперсия $\sigma_0^2 = \frac{1}{N-1} \left(\sum X_{ij}^2 - \frac{T^2}{N} \right)$

2. Факториальная дисперсия $\sigma_A^2 = \frac{1}{a-1} \left(\sum \frac{T_i^2}{n} - \frac{T^2}{N} \right)$

3. Остаточная дисперсия $\sigma_e^2 = \frac{1}{N-a} \left(\sum X_{ij}^2 - \sum \frac{T_i^2}{n} \right)$

Нулевая гипотеза: данный фактор **A** не влияет на изменчивость данного признака.

Для того, чтобы отбросить нулевую гипотезу, нужно доказать, что σ_A^2 – достоверно (т. е. с вероятностью, не меньше, чем **0.95**, или с $\alpha=0.05$) отличается от нуля.

Достоверность значения σ_A^2 может быть установлена путём деления на ошибку, т. е. на σ_e^2 :

$$F = \frac{\sigma_A^2}{\sigma_e^2}$$

Так как фактически полученное дисперсионное отношение F_{ϕ} является величиной случайной, его необходимо сравнить с табличным (стандартным) значением критерия Фишера $F_{st.}$ для принятого уровня значимости α и чисел степеней свободы K_A и K_e

При этом число степеней свободы для большей дисперсии находят в верхней строке, а для меньшей – в первом столбце таблицы.

Нулевую гипотезу H_0 отвергают и эффективность действия фактора A на результативный признак признают статистически достоверной, если $F_{\phi} \geq F_{st}$.

Если $F_{\phi} < F_{st}$, то нулевая гипотеза H_0 сохраняется, и фактор A не влияет на результативный признак.

Количественная оценка влияния отдельных факторов.

Наряду с доказательством влияния того или иного фактора на результативный признак, часто возникает необходимость установления меры этого влияния и его доли в сумме влияния всех факторов. Доля влияния фактора **A** равна:

$$P_A = \frac{\sigma_A^2 - \sigma_e^2}{\sigma_A^2 + \sigma_e^2 (n - 1)}$$

Задача. Получены следующие данные о плодовитости самок мышей при облучении их рентгеновскими лучами:

Группы	Число мышат от отдельных самок			
Доза 0 р	10	12	11	10
Доза 100 р	8	10	7	9
Доза 200р	7	9	6	4

Влияет ли облучение на плодовитость мышей?

Схема решения задачи на дисперсионный анализ:

1. Суммируют данные задачи по каждому уровню фактора A (T_i).
2. Находят общую сумму ($\sum T_i$) по всем уровням и получают значение (T) .
3. Возводят в квадрат общую сумму ($\sum T_i$) и получают значение T^2
4. Возводят полученные суммы (T_i) в квадрат и получают значения (T_i^2) по каждому уровню.
5. Находят общую сумму ($\sum T_i^2$)

a	Отдельные наблюдения (n)				$T_i = \sum X_i$	T_i^2
	1	2	3	4		
1	10	12	11	10	43	1849
2	8	10	7	9	34	1156
3	7	9	6	4	26	676
					$T=103$	$\sum T_i^2=3681$
					$T^2=10609$	

6.Находят сумму квадратов данных задачи, составив дополнительную таблицу.

1	2	3	4	ΣX_i^2
100	144	121	100	465
64	100	49	81	294
49	81	36	16	182
				$\Sigma X_{ij}^2=941$

7. Определяют число степеней свободы:

➤ Для факториальной дисперсии

$$K_A = a - 1 = 3 - 1 = 2$$

➤ Для остаточной дисперсии

$$K_e = N - a = 12 - 3 = 9$$

8. Рассчитывают дисперсии:

➤ Факториальная дисперсия

$$\sigma_A^2 = \frac{1}{a - 1} \left(\sum \frac{T_i^2}{n} - \frac{T^2}{N} \right)$$

$$\sigma_A^2 = \frac{1}{2} \cdot \left(\frac{3681}{4} - \frac{10609}{12} \right) = 18,08$$

➤ Остаточная дисперсия

$$\sigma_e^2 = \frac{1}{N-a} \left(\sum X_{ij}^2 - \sum \frac{T_i^2}{n} \right)$$

$$\sigma_e^2 = \frac{1}{9} \cdot \left(941 - \frac{3681}{4} \right) = 2,3$$

9. Находят фактическое значение F-критерия Фишера:

$$F_{\phi} = 18,08 / 2,3 = 7,86$$

10. Находят стандартное значение F-критерия Фишера (по таблице №4)

$F_{st} = 4,26$ при уровне значимости $0,05$ и числа степеней свободы для большей дисперсии ($K_A = 3 - 1 = 2$) и меньшей дисперсии ($K_e = 12 - 3 = 9$).

11. Сравнивают фактически найденное значение F-критерия Фишера со стандартным значением и делают вывод.

$F_{\text{ф}} \geq F_{\text{ст}}$, нулевую гипотезу отвергают на 5% уровне значимости.

Вывод: С вероятностью 0,95 можно заключить, что облучение рентгеновскими лучами влияет на плодовитость мышей.

12. Определяют степень влияния фактора **A** по формуле:

$$P = \frac{\sigma_A^2 - \sigma_e^2}{\sigma_A^2 + \sigma_e^2 (n - 1)}$$

$$P = \frac{18,08 - 2,3}{18,08 + 2,3(4 - 1)} = 0,63$$

Это означает, что примерно около 63% от общего варьирования плодовитости мышей обусловлено облучением.

Ответ:

1. С вероятностью 0,95 можно заключить, что облучение рентгеновскими лучами влияет на плодовитость мышей.
2. Сила влияния фактора А на результирующий признак равна $P=0,63$.