



Статистическое моделирование и прогнозирование

Лекция 5. Дисперсионный анализ

Семёнов Михаил Евгеньевич
к. ф.-м. н., доцент ОЭФ ИЯТШ

Томский политехнический университет
15 апреля 2020 г.

Основные определения

Качественные и количественные признаки

Дисперсионный анализ

Однофакторный дисперсионный анализ

Условия проведения дисперсионного анализа

Гипотеза

Лабораторная работа 5

Список использованных источников

Качественные и количественные признаки

Качественным признаком называют признак отдельные варианты которого выражаются в виде понятий или наименований. Он может быть представлен в виде альтернативного или формального признака:

- Альтернативный признак – признак имеющий два противоположных значения.
- Формальный признак – признак, по сути относимый к качественному, но представленный числом (например, успеваемость студентов можно представить в виде формального признака).

Количественным признаком называют признак отдельные варианты которого имеют числовое выражение и отличаются по величине, то есть варьируются.

Дисперсионный анализ предназначен для оценки влияния одного или нескольких факторов (качественных величин) на количественную случайную величину.

В случае, когда рассматривается влияние только одного качественного признака, имеющего конечное число уровней градаций, дисперсионный анализ называется *однофакторным*.

Однако очень редко тот или иной процесс определяется только одним фактором. Напротив, обычно наблюдается одновременное влияние многих факторов. *Двухфакторный дисперсионный анализ* (англ. two-way analysis of variance, или two-way ANOVA) позволяет установить одновременное влияние двух факторов, а также взаимодействие между этими факторами.

Предположим, что одна и та же случайная величина X с одинаковой точностью измеряется при k различных значениях фактора. Если анализируемый фактор оказывает существенное влияние на X , то наблюдения на одном уровне будут значительно отличаться от наблюдений на других уровнях, и, следовательно, средние значения на разных уровнях будут различными. И наоборот, если фактор не оказывает влияние на рассматриваемую случайную величину, то средние значения X на различных уровнях будут статистически незначимо отличаться друг от друга.

Однофакторный дисперсионный анализ

Представим результаты наблюдений в виде таблицы:

i	n_i	x_{ij}
1	n_1	$x_{11}, x_{12}, \dots, x_{1n_1}$
2	n_2	$x_{21}, x_{22}, \dots, x_{2n_2}$
...
k	n_k	$x_{k1}, x_{k2}, \dots, x_{kn_k}$

где i – уровни фактора; $j = 1, 2, \dots, n_i$ – номера наблюдений на i -ом уровне; n_i – количество наблюдений на i -ом уровне; x_{ij} – наблюдаемые значения.

Условия проведения дисперсионного анализа

При проведении дисперсионного анализа предполагается выполнение следующих условий:

1. Результаты наблюдений x_{ij} – это независимые случайные величины, то есть $cov(x_{ij}, x_{lm}) = 0$, где $i \neq l$ и/или $j \neq m$.
2. Совокупности наблюдаемых значений $\{x_{i1}, x_{i2}, \dots, x_{in_i}\}$ на каждом уровне i нормально распределены: $N(a_i, \sigma_i)$, где a_i, σ_i – среднее и дисперсия i -го уровня.
3. Дисперсии распределений на всех уровнях $i = 1, 2, \dots, k$ одинаковы:
 $\sigma_1^2 = \sigma_2^2 = \dots = \sigma_k^2 = const.$

Гипотеза: С учётом выдвинутых условий формулируется нулевая гипотеза о равенстве средних всех уровней $H_0 : a_1 = a_2 = \dots = a_k$ при альтернативной, что хотя бы одно из указанных равенств нарушается $H_1 : \exists a_l \neq a_m$, где $l \neq m$.

Статистика: Рассмотрим следующие величины:

$$\bar{x}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{ij}, \quad \bar{x} = \frac{1}{n} \sum_{i=1}^k \sum_{j=1}^{n_i} x_{ij} = \frac{1}{n} \sum_{i=1}^k n_i \bar{x}_i, \quad n = \sum_{i=1}^k n_i, \quad (1)$$

где \bar{x}_i – средние значения i -го уровня; \bar{x} – общее среднее значение всех n величин.

$$Q_t = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x})^2, \quad Q_d = \sum_{i=1}^k n_i (\bar{x}_i - \bar{x})^2, \quad Q_r = \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2, \quad (2)$$

где Q_t - сумма квадратов отклонений отдельных наблюдений x_{ij} от общего среднего \bar{x} ; Q_d - сумма квадратов отклонений средних значений уровней \bar{x}_i от общей средней \bar{x} , которая характеризует различия между средними значениями отдельных уровней и определяется влиянием рассматриваемого фактора; Q_r - сумма квадратов отклонений отдельных наблюдений x_{ij} от средних значений своего уровня \bar{x}_i , которая обусловлена наличием неучтённых факторов и называется остаточным рассеянием или суммой квадратов внутри групп.

Можно доказать, что имеет место равенство $Q_t = Q_d + Q_r$, причём, левая часть равенства имеет $n - 1$ степень свободы, первое слагаемое в правой части – $(k - 1)$ степень свободы, а второе – $(n - k)$, и каждая сумма квадратов, делённая на соответствующее число степеней свободы, будет представлять несмещённую оценку дисперсии случайной величины X . При этом, величина $\frac{1}{n-1}Q_t$ в любом случае является несмещённой оценкой дисперсии X , а величины $\frac{1}{k-1}Q_d$ и $\frac{1}{n-k}Q_r$ – только в рамках гипотезы о равенстве средних значений уровней фактора, то есть при отсутствии влияния исследуемого фактора на случайную величину X .

Тогда при согласии с нулевой гипотезой $H_0 : a_1 = a_2 = \dots = a_k$ статистика F_s будет иметь распределение Фишера с числами степеней свободы числителя $k - 1$, и знаменателя $n - k$:

$$F_s = \frac{\frac{1}{k-1} Q_d}{\frac{1}{n-k} Q_r} = \frac{(n-k) \sum_{i=1}^k n_i (\bar{x}_i - \bar{x})^2}{(k-1) \sum_{i=1}^k \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2} \sim F_{\frac{k-1}{n-k}}. \quad (3)$$

Критерий: Гипотеза H_0 принимается, если $F_s < F_{\alpha, \frac{k-1}{n-k}}$; и отвергается в противном случае, где $F_{\alpha, \frac{k-1}{n-k}}$ – квантиль уровня α .

Вышеуказанный выбор критической области $F_s \geq F_{\alpha, \frac{k-1}{n-k}}$ определяется тем, что при выполнении альтернативной гипотезы H_1 статистика F_s неограниченно возрастает с ростом объёма выборки n .

1. В ходе исследования были получены значения количественного признака для трёх различных уровней качественного признака (фактора).

$D = (4,0; 4,5; 4,3; 5,6; 4,9; 5,4; 3,8; 3,7; 4,0),$

$B = (4,5; 4,9; 5,0; 5,7; 5,5; 5,6; 4,7; 4,5; 4,7),$

$S = (5,4; 4,9; 5,6; 5,8; 6,1; 6,3; 5,5; 5,0; 5,0).$

Используя методику однофакторного дисперсионного анализа, определите: значимо ли влияние изменения качественного признака на величину признака количественного.

Сохранить скрипт в файле (*.r).

- 2 Установите пакет HSAUR2. Используя методику двухфакторного дисперсионного анализа, установите для экспериментальных данных *weightgain*: одновременное влияние двух факторов, а также взаимодействие между этими факторами. Сохраните скрипт в файле (*.r). Сохраните экспериментальные данные *weightgain* в файле (*.csv).
- 3 Представьте результаты дисперсионного анализа в виде классической таблицы ANOVA.
- 4 Выполните дисперсионный анализ при помощи базовых функций `aov()` и `lm()` и сравните результаты [Мастицкий, 2020].

Алгоритм 1 Проверка значимости влияния изменений качественного признака на величину количественного признака с помощью методики однофакторного анализа

Вход: D , B , S – значения количественного признака, наблюдаемые на каждом из уровней качественного признака

1: $D = c(4,0; 4,5; 4,3; 5,6; 4,9; 5,4; 3,8; 3,7; 4,0)$

2: $B = c(4,5; 4,9; 5,0; 5,7; 5,5; 5,6; 4,7; 4,5; 4,7)$

3: $S = c(5,4; 4,9; 5,6; 5,8; 6,1; 6,3; 5,5; 5,0; 5,0)$

4: $adhf = stack(data.frame(D, B, S))$

5: $print(anova(lm(values \sim ind, data=adhf)))$

Выход: Таблица ANOVA

```
Analysis of Variance Table
Response: values
      Df Sum Sq Mean Sq F value Pr(>F)
ind      2 4.9119  2.45593   7.7578 0.002519 **
Residuals 24 7.5978  0.31657
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Рисунок 1 – Результат выполнения алгоритма 1 в виде таблицы ANOVA

Алгоритм 2 Проверка одновременного влияния двух факторов и взаимодействия между этими факторами

Вход: *weightgain* – экспериментальные данные; *type*, *source* – проверяемые факторы.

- 1: `install.packages("HSAUR2")`
- 2: `data(weightgain, package="HSAUR2")`
- 3: `M2 <- lm(weightgain ~ type*source, data=weightgain)`
- 4: `anova(M2) # summary(M2)`

Выход: Таблица ANOVA




Analysis of Variance Table

Response: weightgain

	Df	Sum Sq	Mean Sq	F value	Pr(>F)	
type	1	1299.6	1299.60	5.8123	0.02114	*
source	1	220.9	220.90	0.9879	0.32688	
type:source	1	883.6	883.60	3.9518	0.05447	.
Residuals	36	8049.4	223.59			

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Рисунок 2 – Результат выполнения алгоритма 2 в виде таблицы ANOVA

-  Буховец, , Москалев, , Богатова, , and Бирючинская, (2010).
Статистический анализ данных в системе R. Учебное пособие.
ВГАУ, Воронеж.
-  Мастицкий, (2020).
Однофакторный дисперсионный анализ.
<https://r-analytics.blogspot.com/2013/01/blog-post.html>.
[Онлайн; дата доступа 15 апреля 2020].
-  Мастицкий, and Шитиков, (2014).
Статистический анализ и визуализация данных с помощью R.