

20. ДИСПЕРСИОННЫЙ АНАЛИЗ: МАТРИЧНЫЙ ПОДХОД

20.1. Система нормальных уравнений

Пусть имеются результаты наблюдений за 18 животными в 3-х группах или градациях фактора А (см. также [70,122,138,152]):

Градация	Значения наблюдений								Сумма	n_i	Среднее
A ₁	3	5	6	2	-	-	-	-	16	4	4
A ₂	5	6	2	7	8	3	9	8	48	8	6
A ₃	7	6	4	3	6	4	-	-	30	6	5
Сумма									90	18	5,2222

Каждое наблюдение можно записать в виде биометрической модели:

$$y_{ij} = \mu + a_i + e_{ij},$$

$$\text{причем } i = 1, 2, \dots, a (=3); j = 1, 2, \dots, 18;$$

где y_{ij} - наблюдение над j -ым животным в i -ой градации фактора А (может быть возраст, год, порода, отец, и т.д.); μ - общее среднее при равных частотах градаций фактора А; a_i - эффект i -ой градации фактора А, выраженный как отклонение от общего среднего μ ; e_{ij} - случайная ошибка наблюдения (=остаток, эффект неучтенных факторов) для ij -го животного (предполагают, что e_{ij} имеет нормальное распределение со средней 0 и дисперсией σ_e^2).

Элементы модели, справа от знака равенства, являются параметрами или константами. Оценки этих параметров обозначают знаком «^» над символом. Например, $\hat{\mu}$ является оценкой μ ; \hat{a}_i является оценкой a_i и $\hat{\sigma}_e^2$ является оценкой σ_e^2 . Если a_i - это рандомизированные эффекты, то дисперсию a_i (σ_a^2) оценивают значением $\hat{\sigma}_a^2$.

Каждое наблюдение можно записать в виде уравнения:

$$\begin{aligned} 3 &= y_{11} = \mu + a_1 && + e_{11} \\ 5 &= y_{12} = \mu + a_1 && + e_{12} \\ 6 &= y_{13} = \mu + a_1 && + e_{13} \\ 2 &= y_{14} = \mu + a_1 && + e_{14} \\ 5 &= y_{21} = \mu &+ a_2 & + e_{21} \\ 6 &= y_{22} = \mu &+ a_2 & + e_{22} \end{aligned}$$

$$\begin{aligned}
 2 &= y_{23} = \mu && + a_2 && + e_{23} \\
 7 &= y_{24} = \mu && + a_2 && + e_{24} \\
 8 &= y_{25} = \mu && + a_2 && + e_{25} \\
 3 &= y_{26} = \mu && + a_2 && + e_{26} \\
 9 &= y_{27} = \mu && + a_2 && + e_{27} \\
 8 &= y_{28} = \mu && + a_2 && + e_{28} \\
 7 &= y_{31} = \mu && && + a_3 + e_{31} \\
 6 &= y_{32} = \mu && && + a_3 + e_{32} \\
 4 &= y_{33} = \mu && && + a_3 + e_{33} \\
 3 &= y_{34} = \mu && && + a_3 + e_{34} \\
 6 &= y_{35} = \mu && && + a_3 + e_{35} \\
 4 &= y_{36} = \mu && && + a_3 + e_{36}
 \end{aligned}$$

или в матричной записи:

$$y = Xb + e,$$

где y - вектор наблюдений; X - матрица из 0 и 1; b - вектор параметров; e - вектор случайных ошибок (=остатки).

Уравнение в «развернутом» виде:

$$\begin{array}{c}
 y \\
 \left[\begin{array}{c} 3 \\ 5 \\ 6 \\ 2 \\ 5 \\ 6 \\ 2 \\ 7 \\ 8 \\ 3 \\ 9 \\ 8 \\ 7 \\ 6 \\ 4 \\ 3 \\ 6 \\ 4 \end{array} \right] = \left[\begin{array}{c} y_{11} \\ y_{12} \\ y_{13} \\ y_{14} \\ y_{21} \\ y_{22} \\ y_{23} \\ y_{24} \\ y_{25} \\ y_{26} \\ y_{27} \\ y_{28} \\ y_{31} \\ y_{32} \\ y_{33} \\ y_{34} \\ y_{35} \\ y_{36} \end{array} \right] = \left[\begin{array}{cccc} 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 1 & 0 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 1 \end{array} \right] \times \left[\begin{array}{c} \mu \\ a_1 \\ a_2 \\ a_3 \end{array} \right] + \left[\begin{array}{c} e_{11} \\ e_{12} \\ e_{13} \\ e_{14} \\ e_{21} \\ e_{22} \\ e_{23} \\ e_{24} \\ e_{25} \\ e_{26} \\ e_{27} \\ e_{28} \\ e_{31} \\ e_{32} \\ e_{33} \\ e_{34} \\ e_{35} \\ e_{36} \end{array} \right].
 \end{array}$$

Матрицу X называют *инцидентной* (матрица плана). Она отражает структуру данных - показывает к какой градации (группе) относится соответствующее наблюдение.

Эффекты a_i оценивают LS-методом через минимизацию остаточной суммы квадратов (ошибки):

$$SS_e = \sum_{ij} e_{ij}^2 = \sum_{ij} (y_{ij} - \mu - a_i)^2$$

или в матричной записи

$$\sum_{ij} e_{ij}^2 = ee' = (y - Xb)'(y - Xb).$$

Выражение выводится из параметров μ и a_i , т.е. вектора b . Их оценки принимают за *константы*. Для минимизации ошибки частные производные приравнивают к 0, что приводит уравнение к виду

$$X'Xb = X'y.$$

Систему $X'Xb = X'y$ называют «*системой нормальных уравнений*». Она похожа на систему нормальных уравнений для множественной регрессии. Однако имеет некоторые существенные различия:

- независимые переменные не являются настоящими, а только сигнализируют о том, относится ли наблюдение к данной градации (1) или нет (0);
- параметры меняют свое содержание - они не соответствуют коэффициентам уравнения множественной регрессии.

В данном случае важны оценки, основанные на наблюдениях, по формуле:

$$X'X\hat{b} = X'y,$$

где \hat{b} - вектор оценок, который получают из решения системы нормальных уравнений LS-методом.

20.2. Решение

Однозначное решение возможно только в том случае, если для матрицы $X'X$ существует обратная матрица $(X'X)^{-1}$, т.к.

$$\hat{b} = (X'X)^{-1} X'y.$$

Если $(X'X)^{-1}$ не существует, то возможно бесконечное число решений.

Система нормальных уравнений для однофакторной модели:

$$\begin{bmatrix} n & n_1 & n_2 & \dots & n_p \\ n_1 & n_1 & 0 & \dots & 0 \\ n_2 & 0 & n_2 & \dots & 0 \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ n_p & 0 & 0 & \dots & n_p \end{bmatrix} \begin{bmatrix} \hat{\mu} \\ \hat{a}_1 \\ \hat{a}_2 \\ \vdots \\ \hat{a}_p \end{bmatrix} = \begin{matrix} \text{RHM} \\ \left[\begin{array}{l} \sum_i \sum_j y_{ij} \\ \sum_j y_{1j} \\ \sum_j y_{2j} \\ \vdots \\ \sum_j y_{pj} \end{array} \right] \end{matrix}.$$

Каждой константе соответствует свое уравнение. Свойства нормальных уравнений:

- элементы $(X'X)$ симметричны относительно главной диагонали;
- элементы в уравнении для $\hat{\mu}$ соответствуют диагональным элементам в уравнениях для \hat{a}_i ;
- все недиагональные элементы как по строкам, так и по столбцам для \hat{a}_i равны 0;
- сумма коэффициентов для \hat{a}_i в уравнении для $\hat{\mu}$ равна коэффициенту для $\hat{\mu}$ в этом же уравнении;
- сумма членов правой части (RHM) уравнений для \hat{a}_i равна члену правой части уравнения для $\hat{\mu}$.

Для числового примера имеем:

$$\begin{bmatrix} 18 & 4 & 8 & 6 \\ 4 & 4 & 0 & 0 \\ 8 & 0 & 8 & 0 \\ 6 & 0 & 0 & 6 \end{bmatrix} \begin{bmatrix} \hat{\mu} \\ \hat{a}_1 \\ \hat{a}_2 \\ \hat{a}_3 \end{bmatrix} = \begin{bmatrix} 94 \\ 16 \\ 48 \\ 30 \end{bmatrix}.$$

Значения коэффициентов первого столбца матрицы $X'X$ равно сумме значений коэффициентов по остальным столбцам. Аналогично по строкам. Таким образом, колонки и строки взаимозависимы. Поэтому матрица $X'X$ неполного ранга. Для нее не существует обратной матрицы $(X'X)^{-1}$. В данном случае ранг матрицы равен числу уравнений минус 1 ($=p$), т.е. существует только « p » независимых уравнений.

Так как число неизвестных параметров равно числу уравнений ($=p+1$), то чтобы решить систему нормальных уравнений необходимо ввести *допущение* (constraint). Обычное допущение при получении оценок a_i , как отклонение от μ , это $\sum \hat{a}_i = 0$, но возможны и $\hat{\mu} = 0$ или $\hat{a}_p = 0$.

Независимо от выбора допущения, в однофакторной модели суммы квадратов будут аналогичны. Решение не влияет на *остаточную* сумму квадратов. Так как в большинстве случаев остальные суммы квадратов получают через разность остаточных сумм квадратов двух моделей, то они также являются схожими (исключения возможны).

После выбора допущения, система нормальных уравнений *дополняется* еще одним уравнением или, что практичнее, нормальные уравнения *редуцируются* до независимого уровня.

Допущение $\sum \hat{a}_i = 0$ означает, что отдельные a_i - это отклонения от невзвешенного $\hat{\mu}$. Если при $p=3$ известно 2 элемента, то третий может быть рассчитан. Так, при известных \hat{a}_1 и \hat{a}_2 ,

$$\hat{a}_3 = -(\hat{a}_1 + \hat{a}_2).$$

Поэтому \hat{a}_3 и соответствующее уравнение можно исключить путем вычитания коэффициентов для \hat{a}_3 из остальных коэффициентов в рядах и столбцах (кроме ряда и колонки для μ). Ниже даны этапы решения *системы нормальных уравнений*.

Этап 1. Из коэффициентов всех рядов, кроме первого, вычитают коэффициенты для \hat{a}_3 ([6 0 0 6] см. стр. 340):

	$\hat{\mu}$	\hat{a}_1	\hat{a}_2	\hat{a}_3
$\hat{\mu}$	18	4	8	6
\hat{a}_1	-2	4	0	-6
\hat{a}_2	2	0	8	-6

Этап 2. Из всех столбцов, кроме первого, вычитают коэффициенты последнего столбца ([6 -6 -6]' см. этап 1):

	$\hat{\mu}$	\hat{a}_1	\hat{a}_2
$\hat{\mu}$	18	-2	2
\hat{a}_1	-2	10	6
\hat{a}_2	2	6	14

В результате этих операций формируется *редуцированная* матрица $X'X$ (субиндекс «r» означает «редуцированная»):

$$(X'X)_r = \begin{bmatrix} 18 & -2 & 2 \\ -2 & 10 & 6 \\ 2 & 6 & 14 \end{bmatrix}.$$

Подобным образом вычитают соответствующий элемент в векторе $X'y$:

$$(X'y)_r = \begin{bmatrix} 94 \\ -14 \\ 18 \end{bmatrix}.$$

Редуцированную матрицу $X'X$ можно получить также путем редукции матрицы X с последующим умножением на X' . При допущении $\sum \hat{a}_i = 0$, значения столбца a_3 в матрице X вычитают из столбцов a_1 и a_2 . (Как известно, каждое наблюдение можно записать с помощью оценок параметров и остатка, например, $y_{31} = \hat{\mu} + \hat{a}_3 + \hat{e}_{31}$. При $\hat{a}_3 = -(\hat{a}_1 + \hat{a}_2)$ после редукции получим $y_{31} = \hat{\mu} - \hat{a}_1 - \hat{a}_2 + \hat{e}_{31}$.) Эта процедура легче, чем редуцировать матрицу $X'X$. Редуцированная матрица X :

$$X'_r = \begin{bmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & -1 & -1 & -1 & -1 \\ 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & -1 & -1 & -1 & -1 \end{bmatrix}.$$

После принятия одного из допущения можно, таким образом, получить единственное решение:

$$\hat{b}_r = (X'X)_r^{-1} (X'y)_r.$$

Инверсия матрицы $(X'X)_r$:

$$\begin{bmatrix} 18 & -2 & 2 \\ -2 & 10 & 6 \\ 2 & 6 & 14 \end{bmatrix}^{-1} = \begin{bmatrix} 0,0602 & 0,0231 & -0,0185 \\ 0,0231 & 0,1435 & -0,0648 \\ -0,0185 & -0,0648 & 0,1019 \end{bmatrix}.$$

При допущении $\sum \hat{a}_i = 0$ решение будет (в рамочке даны элементы субматрицы Z ; см. ниже):

$$\hat{b}_r = \begin{bmatrix} \hat{\mu} \\ \hat{a}_1 \\ \hat{a}_2 \end{bmatrix} = \begin{bmatrix} 0,0602 & 0,0231 & -0,0185 \\ 0,0231 & \boxed{0,1435} & \boxed{-0,0648} \\ -0,0185 & \boxed{-0,0648} & \boxed{0,1019} \end{bmatrix} \begin{bmatrix} 94 \\ -14 \\ 18 \end{bmatrix},$$

что дает:

$$\hat{\mu} = (0,0602)(94) + (0,0231)(-14) + (-0,0185)(18) = 5;$$

$$\hat{a}_1 = (0,0231)(94) + (0,1435)(-14) + (-0,0648)(18) = -1;$$

$$\hat{a}_2 = (-0,0185)(94) + (-0,0648)(-14) + (0,1019)(18) = +1.$$

Так как допускалось, что $\sum \hat{a}_i = \hat{a}_1 + \hat{a}_2 + \hat{a}_3 = 0$,

то

$$\begin{aligned} \hat{a}_3 &= -(\hat{a}_1 + \hat{a}_2) = \\ &= -(-1+1) = 0. \end{aligned}$$

20.3. Разложение суммы квадратов

В однофакторном дисперсионном анализе общую сумму квадратов (SS_y) раскладывают на сумму квадратов модели, т.е. между градациями фактора (SS_a) и на остаточную сумму квадратов (SS_e).

Для сбалансированных данных существует только один способ разложения суммы квадратов. Для *несбалансированных* данных возможны различные способы, большинство из которых не аддитивны, т.е. $SS_y \neq SS_a + SS_e$.

В любом случае, общую некорректированную сумму квадратов ($SS_y = y'y = \sum_{ij} y_{ij}^2$) можно разложить на некорректированную сумму квадратов модели (факторную), $SS_a'' = \hat{b}'X'y = \hat{b}'X'X\hat{b}$ и остаточную сумму квадратов $SS_e = y'y - \hat{b}'X'y$.

Факторную сумму квадратов, *скорректированную на среднее*, получают из выражения

$$SS_a = \hat{b}'X'y - n\hat{\mu}^2,$$

где $n\hat{\mu}^2$ - сумма квадратов для среднего (SS_μ).

Расчет SS_a в компьютерной программе Harvey'я осуществляется следующим образом.

Пусть Z - это субматрица в редуцированной матрице $(X'X)_r$, соответствующая строкам и столбцам оцениваемых эффектов (на стр. 342 эта субматрица обведена)

$$Z = \begin{bmatrix} 0,1435 & -0,0648 \\ -0,0648 & 0,1019 \end{bmatrix}.$$

Тогда

$$SS_a = \hat{b}'_z Z^{-1} \hat{b}_z,$$

где \hat{b}_z - часть вектора оценок \hat{b}_r , которая соответствует субматрице Z .

Для числового примера имеем:

$$\begin{aligned} SS_a = \hat{b}'_z Z^{-1} \hat{b}_z &= [-1 \ 1] \begin{bmatrix} 0,1435 & -0,0648 \\ -0,0648 & 0,1019 \end{bmatrix}^{-1} \begin{bmatrix} -1 \\ 1 \end{bmatrix} = \\ &= [-1 \ 1] \begin{bmatrix} 9,7778 & 6,2222 \\ 6,2222 & 13,7778 \end{bmatrix}^{-1} \begin{bmatrix} -1 \\ 1 \end{bmatrix} = \\ &= [-3,5556 \ 7,5556] \begin{bmatrix} -1 \\ 1 \end{bmatrix} = 11,1112. \end{aligned}$$

Некорректированная сумма квадратов для модели после редукции:

$$SS''_a = \hat{b}'_r (X'y)_r = [5 \ -1 \ 1] \begin{bmatrix} 94 \\ -14 \\ 18 \end{bmatrix} = 502.$$

Следует отметить, что аналогичное значение будет и без редукции:

$$\hat{b}' X'y = [5 \ -1 \ 1 \ 0] \begin{bmatrix} 94 \\ 16 \\ 48 \\ 30 \end{bmatrix} = 502.$$

Общая не скорректированная на среднее сумма квадратов (SS_y):

$$SS_y = y'y = 568.$$

Остаточная сумма квадратов:

$$SS_e = y'y - \hat{b}' X'y = 568 - 502 = 66.$$

Сумма квадратов для общего среднего (корректировка на среднее)

$$SS_\mu = 502 - 11,1112 = 490,8888.$$

Результаты разложения суммы квадратов сведены в таблицу:

Источник	df	SS	MS	F-критерий
Общая, в т.ч.	18	568,0000		
Среднее	1	490,8888		
Фактор А	2	11,1112	5,5556	1,263 n.s.
Остаток	15	66,0000	4,4000	

Критерий Фишера $F = MS_a / MS_e = 5,5556 / 4,4000 = 1,263$.

Расчеты по стандартной процедуре:

- общая некорректированная сумма квадратов:

$$SS_y = \sum_i \sum_j y_{ij}^2 = 3^2 + 5^2 + \dots + 4^2 = 568;$$

- сумма квадратов для средних:

$$SS_\mu = (\sum_i \sum_j y_{ij})^2 / n = 490,8888;$$

- факторная сумма квадратов:

$$\begin{aligned} SS_a &= \sum_i [(\sum_j y_{ij})^2 / n_i] - SS_\mu = \\ &= 16^2 / 4 + 48^2 / 8 + 30^2 / 6 - 490,8888 = \\ &= 502 - 490,8888 = 11,1112; \end{aligned}$$

- остаточная сумма квадратов:

$$SS_e = SS_y - \sum_i [(\sum_j y_{ij})^2 / n_i] = 568 - 502 = 66.$$

Таким образом, оба способа расчета дают идентичные результаты.

20.4. Допущения и оценки эффектов

Для решения системы нормальных уравнений было принято допущение, что $\sum_i \hat{a}_i = 0$. В результате были получены следующие оценки:

$$\hat{\mu} = 5, \quad \hat{a}_1 = -1, \quad \hat{a}_2 = +1 \quad \text{и} \quad \hat{a}_3 = 0$$

или

$$\hat{b}' = [5 \quad -1 \quad +1 \quad 0].$$

Другие допущения приводят к иным оценкам. Например, при $\hat{\mu} = 0$ вектор оценок будет

$$\hat{b}' = [0 \quad +4 \quad +6 \quad +5].$$

Выше отмечалось, что допущения не влияют на суммы квадратов. Но какие допущения следует выбрать, если необходимо оценить вектор параметров b ?

Ответ на этот вопрос нет, т.к. параметры определяются неоднозначно. Имеется $p+1$ параметров, но только « p » градаций фактора. Для того чтобы выяснить содержание параметров, необходимо ввести *ограничение* (restriktion). Разница между ограничением и допущением состоит в том, что допущения вводят только для того, чтобы решить систему нормальных уравнений. А ограничения вводят на параметры, которые входят в модель, для того чтобы придать им однозначность.

Несмещенные оценки параметров получают только тогда, когда ограничения соответствуют допущениям. При ограничении $\sum_i \hat{a}_i = 0$, μ приобретает содержание *невзвешенной средней* из средних по каждой градации фактора $(\mu + a_i)$. При этом $a_i = (\mu + a_i) - \mu$. В этом случае допущение $\sum_i \hat{a}_i = 0$ верно, в том смысле, что помогает вычислить оценки вектора b .

Общее среднее μ оценивается как *невзвешенное среднее всех средних оценок градаций* фактора. Общее среднее $\sum_i \sum_j y_{ij} / n$ является несмещенной оценкой только при ограничении $\sum_i n_i \hat{a}_i = 0$. В программе Harvey,я используется допущение $\sum_i \hat{a}_i = 0$. Значения \hat{a}_i называют «*оценки констант*» (constant estimate), а $\hat{\mu}$ и $\hat{\mu} + \hat{a}_i$ - как «*средние наименьших квадратов*» (least-squares means).

Для числового примера имеем:

$$\begin{array}{l} \text{Общее среднее с} \\ \text{ограничением} \\ \sum_i n_i \hat{a}_i = 0 \end{array} = \sum_{i=1}^a \sum_{j=1}^{n_i} y_{ij} / n = 94/18 = 5,2222.$$

$$\begin{array}{l} \text{Среднее наименьших} \\ \text{квадратов с} \\ \text{ограничением} \\ \sum_i \hat{a}_i = 0 \end{array} = \sum_i (\sum_j y_{ij} / n_i) / p = (16/4 + 48/8 + 30/6) / 3 = 5,0000.$$

Таким образом, средние градаций с небольшим числом наблюдений имеют тот же «вес» в *общей* средней наименьших квадратов, что и средние градаций с большим числом наблюдений. Поэтому среднее наименьших квадратов считается *невзвешанным*. Оно зависит как от оценок эффектов, включенных в модель, так и от степени сбалансированности данных.

Для рассматриваемого числового примера $R(\mu, a)$ -запись некорректированной суммы квадратов есть:

$$R(\mu, a) = SS_a'' = \hat{b}'_r (X' y)_r = \hat{b}' X' y = 502,$$

причем модель имела вид

$$y_{ij} = \mu + a_i + e_{ij}.$$

При использовании модели

$$y_{ij} = \mu + e_{ij}$$

сумма квадратов по модели есть:

$$R(\mu) = SS_\mu = 490,8888.$$

Скорректированную на среднее сумму квадратов по фактору А (SS_a) рассчитывают из выражения

$$R(\mu, a) - R(\mu) = R(a | \mu) = 11,1112.$$

$R(a | \mu)$ соответствует той редукции, которая происходит при введении в модель, в которой уже имеется μ , фактора А.

Вышескорректированная сумма квадратов между градациями фактора А выражалась как

$$b'_z Z^{-1} b_z.$$

Используя $R(\mu, a)$ -запись, имеем следующие суммы квадратов для таблицы однофакторного дисперсионного анализа:

- общая $y' y$
- среднее $R(\mu)$
- факторная $R(a | \mu)$
- остаточная $y' y - R(\mu, a)$.