

Лекция № 2. Модель множественной линейной регрессии

- **Вопросы**

- **1. Задача построения множественной линейной регрессии.**
- **2. Оценка качества модели множественной линейной регрессии.**
- **3. Прогнозирование по модели множественной линейной регрессии.**

- 1. В общем случае зависимая переменная y может быть функцией нескольких переменных: x_1, x_2, \dots, x_m .
- В каждом наблюдении (i) получают совокупность значений независимой переменной: $x_{i1}, x_{i2}, \dots, x_{im}$ и совокупность значений зависимой переменной y_i . Итак, допустим,
- $$y_i = \alpha_1 x_{i1} + \alpha_2 x_{i2} + \dots + \alpha_m x_{im} + \varepsilon_i \quad (1)$$

- Введем матричные обозначения.
- Пусть $\{\alpha_j\}, j = 1, \dots, m$ – вектор неизвестных параметров; $Y = \{y_i\}, i = 1, \dots, n$
- - вектор зависимой переменной; $X = (x_{ij})$ – матрица независимых переменных размером $n \times m$; $\varepsilon = \{\varepsilon_i\}$ - вектор ошибок.
- Тогда линейная модель (1) переписывается в виде

$$\bullet Y = X\alpha + \varepsilon \quad (2)$$

- Относительно ошибок ε сделаем следующие *предположения*:
- 1) возмущение ε является случайной величиной;
- 2) $M(\varepsilon) = 0$;
- 3) $D(\varepsilon) = \text{const}$;
- 4) последовательные значения ε не зависят друг от друга;
- 5) матрица X состоит из линейно-независимых векторов-столбцов.

- **Последнее обстоятельство эквивалентно тому, что ранг матрицы X равен m , а это, в свою очередь, означает, что $|X'X| \neq 0$, т.е. матрица $X'X$ обратима (X' - транспонированная для X).**
- **Матрица X не содержит ошибок.**

- **Оценку выражения (1), полученную по выборочным данным, запишем в виде**
 - $y_i = a_1 x_{i1} + a_2 x_{i2} + \dots + a_m x_{im} + e_i \quad (3)$
- **или в матричном виде $Y = Xa + e$.**
- **Сумму квадратов отклонений теперь можно определить как**
- $Q = \sum e_i^2 = e'e = (Y - Xa)' (Y - Xa) =$
- $= Y'Y - a'X'Y - Y'Xa + a'X'Xa.$
- **Так как $a'X'Y = Y'Xa$, то**
- $Q = Y'Y - 2a'X'Y + X'Xa^2 \quad (4).$

- Продифференцируем Q по a , получим

$$\frac{\partial Q}{\partial a} = -2X'Y + 2(X'X)a = 0,$$

$$X'Y = X'Xa,$$

$$a = (X'X)^{-1} X'Y \quad (5).$$

- Оценку a , найденную по формуле (5), будем называть оценкой МНК.

- Таким образом, для определения вектора a необходимо по данным наблюдений найти матрицу, обратную к матрице $X'X$, и вектор $X'Y$:

$$X'X = \begin{pmatrix} \sum_i x_{i1}^2 & \sum_i x_{i1}x_{i2} & \dots & \sum_i x_{i1}x_{im} \\ \sum_i x_{i2}x_{i1} & \sum_i x_{i2}^2 & \dots & \sum_i x_{i2}x_{im} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \sum_i x_{im}x_{i1} & \sum_i x_{im}x_{i2} & \dots & \sum_i x_{im}^2 \end{pmatrix} \quad (6)$$

$$X'Y = \begin{pmatrix} \sum_{i=1}^n y_i x_{i1} \\ \sum_{i=1}^n y_i x_{i2} \\ \cdot \\ \cdot \\ \cdot \\ \sum_{i=1}^n y_i x_{im} \end{pmatrix} \quad (7)$$

- Обычно предполагается, что уравнение регрессии имеет свободный член, т.е. a_0 . Чтобы получить оценку этого параметра, расширим матрицу (6), введя в нее переменную $X_{i0} = 1$.

-

- Тогда матрицу X в развернутом виде можно записать так:

$$X = \begin{pmatrix} 1 & x_{11} & x_{12} & \dots & x_{1m} \\ 1 & x_{21} & x_{22} & \dots & x_{2m} \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ 1 & x_{n1} & x_{n2} & \dots & x_{nm} \end{pmatrix},$$

- Тогда

$$X'X = \begin{pmatrix} n & \sum_i x_{i1} & \dots & \sum_i x_{im} \\ \sum_i x_{i1} & \sum_i x_{i1}^2 & \dots & \sum_i x_{i1}x_{im} \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \dots & \cdot \\ \sum_i x_{im} & \sum_i x_{i1}x_{im} & \dots & \sum_i x_{im}^2 \end{pmatrix} \quad (8)$$

• И

$$X'Y = \begin{pmatrix} \sum_i y_i \\ \sum_i y_i x_{i1} \\ \cdot \\ \cdot \\ \cdot \\ \sum_i y_i x_{im} \end{pmatrix} \quad (9).$$

- В частном случае, когда $m=2$, имеем

$$X'X = \begin{pmatrix} n & \sum x_{i1} & \sum x_{i2} \\ \sum x_{i1} & \sum x_{i1}^2 & \sum x_{i1}x_{i2} \\ \sum x_{i2} & \sum x_{i1}x_{i2} & \sum x_{i2}^2 \end{pmatrix} \quad (10).$$

Условный пример

i	y_i	x_{i1}	x_{i2}
1	10	2	1
2	12	2	2
3	17	8	10
4	13	2	4
5	15	6	8
6	10	3	4
7	14	5	7
8	12	3	3
9	16	9	10
10	18	10	11

- Таким образом,

$$Y = \begin{pmatrix} 10 \\ 12 \\ 17 \\ 13 \\ 15 \\ 10 \\ 14 \\ 12 \\ 16 \\ 18 \end{pmatrix}, X = \begin{pmatrix} 1 & 2 & 1 \\ 1 & 2 & 2 \\ 1 & 8 & 10 \\ 1 & 2 & 4 \\ 1 & 6 & 8 \\ 1 & 3 & 4 \\ 1 & 5 & 7 \\ 1 & 3 & 3 \\ 1 & 9 & 10 \\ 1 & 10 & 11 \end{pmatrix}, \text{тогда}$$

$$\mathcal{X}\mathcal{X} = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 2 & 2 & 8 & 2 & 6 & 3 & 5 & 3 & 9 & 10 \\ 1 & 2 & 10 & 4 & 8 & 4 & 7 & 3 & 10 & 11 \end{pmatrix} \cdot \begin{pmatrix} 1 & 2 & 1 \\ 1 & 2 & 2 \\ 1 & 8 & 10 \\ 1 & 2 & 4 \\ 1 & 6 & 8 \\ 1 & 3 & 4 \\ 1 & 5 & 7 \\ 1 & 3 & 3 \\ 1 & 9 & 10 \\ 1 & 10 & 11 \end{pmatrix} =$$

$$\begin{pmatrix} 10 & 50 & 60 \\ 50 & 336 & 398 \\ 60 & 398 & 480 \end{pmatrix}.$$

- Далее

$$XY = \begin{pmatrix} 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 2 & 2 & 8 & 2 & 6 & 3 & 5 & 3 & 9 & 10 \\ 1 & 2 & 10 & 4 & 8 & 4 & 7 & 3 & 10 & 11 \end{pmatrix} \cdot \begin{pmatrix} 10 \\ 12 \\ 17 \\ 13 \\ 15 \\ 10 \\ 14 \\ 12 \\ 16 \\ 18 \end{pmatrix} = \begin{pmatrix} 137 \\ 756 \\ 908 \end{pmatrix}.$$

Замечание

- Матрицу $X'X$ и вектор $X'Y$ можно получить и по формулам (8) и (9), предварительно подсчитав необходимые суммы:

$$\sum y_i = 137; \quad \sum x_{i1} = 50; \quad \sum x_{i2} = 60;$$

$$\sum y_i^2 = 1947; \quad \sum x_{i1}^2 = 336; \quad \sum x_{i2}^2 = 480;$$

$$\sum y_i x_{i1} = 756; \quad \sum x_{i1} x_{i2} = 398; \quad \sum y_i x_{i2} = 908.$$

Результат, естественно, будет одинаковым.

- Определив $X'X$ и $X'Y$, находим a :

- $a = (X'X)^{-1}X'Y =$

$$= \frac{1}{7160} \begin{pmatrix} 2876 & -120 & -260 \\ -120 & 1200 & -980 \\ -260 & -980 & 860 \end{pmatrix} \cdot \begin{pmatrix} 137 \\ 756 \\ 908 \end{pmatrix} = \begin{pmatrix} 9,3871 \\ 0,1285 \\ 0,61174 \end{pmatrix}.$$

- Таким образом, искомое уравнение

$$\hat{y} = 9,3871 + 0,1285x_1 + 0,61174x_2.$$

- Приведем рассчитанные по данному уравнению регрессии значения независимой переменной (y_i) и соответствующие ошибки (e_i):

- Имеем:

i	y_i	\hat{y}_i	e_i
1	10	10,2559	-0,2559
2	12	10,8676	1,1324
3	17	16,5324	0,4676
4	13	12,0910	0,9090
5	15	15,0520	-0,0520
6	10	12,2195	-2,2195
7	14	14,3117	-0,3117
8	12	11,6078	0,3922
9	16	16,6609	-0,6609
10	18	17,4012	0,5988.

- Здесь $\sum y_i = \sum \hat{y}_i = 137$; $\sum e_i = 0$.
- Как можно заключить из примера, наиболее трудоемкой операцией здесь является обращение матрицы.
- Уравнение (5) позволяет в принципе решить задачу оценивания для любого конечного числа независимых переменных (на ЭВМ).