

3.2. Задачи

Задача 3.1

По различным районам (i — номер района) исследуется зависимость урожайности зерновых культур от ряда переменных, характеризующих различные факторы сельскохозяйственного производства (табл. 3.3).

Таблица 3.3

**Зависимость урожайности зерновых культур y_i , ц/га
от факторов сельскохозяйственного производства:**

x_{i1} — число тракторов (приведенной мощности) на 100 га;
 x_{i2} — число зерноуборочных комбайнов на 100 га;
 x_{i3} — число орудий поверхности обработки почвы на 100 га; x_{i4} — количество удобрений, расходуемых на гектар (т/га); x_{i5} — количество химических средств защиты растений, расходуемых на гектар (ц/га)

i	y_i	x_{i1}	x_{i2}	x_{i3}	x_{i4}	x_{i5}
1	9,7	1,59	0,26	2,05	0,32	0,14
2	8,4	0,34	0,28	0,46	0,59	0,66
3	9	2,53	0,31	2,46	0,3	0,31
4	9,9	4,63	0,4	6,44	0,43	0,59
5	9,6	2,16	0,26	2,16	0,39	0,16
6	8,6	2,16	0,3	2,69	0,32	0,17
7	12,5	0,68	0,29	0,73	0,42	0,23
8	7,6	0,35	0,26	0,42	0,21	0,08
9	6,9	0,52	0,24	0,49	0,2	0,08
10	13,5	3,42	0,31	3,02	1,37	0,73
11	9,7	1,78	0,3	3,19	0,73	0,17
12	10,7	2,4	0,32	3,3	0,25	0,14
13	12,1	9,36	0,4	11,51	0,39	0,38
14	9,7	1,72	0,28	2,26	0,82	0,17
15	7	0,59	0,29	0,6	0,13	0,35

Окончание табл. 3.3

i	y_i	\hat{y}_{i1}	\hat{y}_{i2}	\hat{y}_{i3}	\hat{y}_{i4}	\hat{y}_{i5}
16	7,2	0,28	0,26	0,3	0,09	0,15
17	8,2	1,64	0,29	1,44	0,2	0,08
18	8,4	0,09	0,22	0,05	0,43	0,2
19	13,1	0,08	0,25	0,03	0,73	0,2
20	8,7	1,36	0,26	0,17	0,99	0,42

Требуется:

- Построить выборочное уравнение линейной множественной регрессии для исходных данных:
 - найти вектор коэффициентов \mathbf{b} ;
 - рассчитать общую сумму квадратов Q , сумму квадратов, объясненную регрессией Q_r , остаточную сумму квадратов Q_e , несмешанные оценки соответствующих дисперсий s^2 , s_r^2 , s_e^2 и средних квадратических отклонений s , s_r , s_e ;
 - найти стандартные отклонения коэффициентов регрессии s_b и с доверительной вероятностью $\gamma = 0,95$ оценить значимость коэффициентов;
 - рассчитать выборочный множественный коэффициент детерминации $\bar{R}_{y,X}^2$ и его скорректированное значение R_{adj}^2 ;
 - с доверительной вероятностью $\gamma = 0,95$ оценить значимость уравнения регрессии.
- Проверить полученные результаты с помощью стандартной статистической программы ЛИНЕЙН и инструмента РЕГРЕССИЯ из пакета анализа Microsoft Excel.
- Провести анализ признаков мультиколлинеарности в следующем порядке:
 - вычислить элементы матрицы выборочных парных коэффициентов корреляции R_{XX} объясняющих переменных и оценить их значения;

- найти значение определителя матрицы R_{XX} и с доверительной вероятностью $\gamma = 0,95$ проверить гипотезу о наличии мультиколлинеарности на основе статистического χ^2 -критерия.

4. С помощью метода пошагового отбора переменных провести устранение мультиколлинеарности, отобрав наиболее информативные предикторы в регрессионной модели. Построить графики зависимостей $\bar{R}^2(l)$, $\bar{R}^{*2}(l)$ и $\bar{R}_{\min}^2(l)$ от номера шага l , полагая их равными нулю при $l = 0$.

5. Построить выборочное уравнение линейной множественной регрессии при учете только отобранных предикторов:

- найти вектор коэффициентов b ;
- рассчитать общую сумму квадратов Q , сумму квадратов, объясненную регрессией Q_r , остаточную сумму квадратов Q_e , несмещенные оценки соответствующих дисперсий s^2 , s_r^2 , s_e^2 и средних квадратических отклонений s , s_r , s_e ;
- найти стандартные отклонения коэффициентов регрессии δ_b и с доверительной вероятностью $\gamma = 0,95$ оценить значимость коэффициентов;
- рассчитать выборочный множественный коэффициент детерминации $\bar{R}_{y,x}^2$ и его скорректированное значение \bar{R}_{adj}^2 ;
- с доверительной вероятностью $\gamma = 0,95$ оценить значимость уравнения регрессии.

6. Проверить полученные результаты с помощью стандартной статистической программы ЛИНЕЙН и инструмента РЕГРЕССИЯ из пакета анализа Microsoft Excel.

Решение

1. Для определения параметров выборочного уравнения линейной регрессии строим расчетную таблицу (табл. 3.4, столбцы 1–7).

Таблица 3.4

Расчетная таблица

i	y_i	x_{i1}	x_{i2}	x_{i3}	x_{i4}	x_{i5}	\hat{y}_i	$(y_i - \bar{y})^2$	$(\hat{y}_i - \bar{y})^2$	$(y_i - \hat{y}_i)^2$
1	2	3	4	5	6	7	8	9	10	11
1	9,7	1,59	0,26	2,05	0,32	0,14	8,79	0,03	0,54	0,82
2	8,4	0,34	0,28	0,46	0,59	0,66	8,62	1,27	0,82	0,05
3	9	2,53	0,31	2,46	0,3	0,31	9,02	0,28	0,25	0,00
4	9,9	4,63	0,4	6,44	0,43	0,59	10,60	0,14	1,17	0,50
5	9,6	2,16	0,26	2,16	0,39	0,16	9,06	0,01	0,22	0,30
6	8,6	2,16	0,3	2,69	0,32	0,17	9,39	0,86	0,02	0,63
7	12,5	0,68	0,29	0,73	0,42	0,23	9,30	8,85	0,05	10,22
8	7,6	0,35	0,26	0,42	0,21	0,08	8,30	3,71	1,49	0,50
9	6,9	0,52	0,24	0,49	0,2	0,08	7,96	6,89	2,46	1,11
10	13,5	3,42	0,31	3,02	1,37	0,73	12,63	15,80	9,66	0,75
11	9,7	1,78	0,3	3,19	0,73	0,17	11,28	0,03	3,10	2,51
12	10,7	2,4	0,32	3,3	0,25	0,14	9,54	1,38	0,00	1,34
13	12,1	9,36	0,4	11,51	0,39	0,38	11,57	6,63	4,18	0,28
14	9,7	1,72	0,28	2,26	0,82	0,17	11,27	0,03	3,06	2,48
15	7	0,59	0,29	0,6	0,13	0,35	7,64	6,38	3,55	0,41
16	7,2	0,28	0,26	0,3	0,09	0,15	7,55	5,41	3,90	0,12
17	8,2	1,64	0,29	1,44	0,2	0,08	8,83	1,76	0,48	0,40
18	8,4	0,09	0,22	0,05	0,43	0,2	8,28	1,27	1,56	0,02
19	13,1	0,08	0,25	0,03	0,73	0,2	10,08	12,78	0,31	9,10
20	8,7	1,36	0,26	0,17	0,99	0,42	10,76	0,68	1,54	4,26
Σ	190,5							74,16	38,36	35,80
ср.	9,5									
$\bar{\sigma}^2$								3,90	7,67	2,56
$\bar{\sigma}$								1,98	2,77	1,60

Записываем матрицу \mathbf{X} объясняющих переменных размера 20×6 и находим транспонированную матрицу \mathbf{X}^T :

$$\mathbf{X} = \begin{pmatrix} 1 & 1,59 & 0,26 & 2,05 & 0,32 & 0,14 \\ 1 & 0,34 & 0,28 & 0,46 & 0,59 & 0,66 \\ \dots & \dots & \dots & \dots & \dots & \dots \\ 1 & 1,36 & 0,26 & 0,17 & 0,99 & 0,42 \end{pmatrix};$$

$$\mathbf{X}^T = \begin{pmatrix} 1 & 1 & \dots & 1 \\ 1,59 & 0,34 & \dots & 1,36 \\ 0,26 & 0,28 & \dots & 0,26 \\ 2,05 & 0,46 & \dots & 0,17 \\ 0,32 & 0,59 & \dots & 0,99 \\ 0,14 & 0,66 & \dots & 0,42 \end{pmatrix}$$

Вычисляем произведение матриц $\mathbf{X}^T \mathbf{X}$

$$\mathbf{X}^T \mathbf{X} = \begin{pmatrix} 20 & 37,68 & 5,78 & 43,77 & 9,31 & 5,41 \\ 37,68 & 156,84 & 12,47 & 189,42 & 18,98 & 12,87 \\ 5,78 & 12,47 & 1,71 & 14,73 & 2,70 & 1,64 \\ 43,77 & 189,42 & 14,73 & 235,12 & 20,87 & 14,62 \\ 9,31 & 18,98 & 2,70 & 20,87 & 6,30 & 3,20 \\ 5,41 & 12,87 & 1,64 & 14,62 & 3,20 & 2,18 \end{pmatrix}$$

и произведение $\mathbf{X}^T \mathbf{y}$:

$$\mathbf{X}^T \mathbf{y} = \begin{pmatrix} 190,50 \\ 393,23 \\ 55,70 \\ 457,89 \\ 95,65 \\ 53,96 \end{pmatrix}$$

Рассчитываем обратную матрицу $(\mathbf{X}^T \mathbf{X})^{-1}$:

$$(\mathbf{X}^T \mathbf{X})^{-1} = \begin{pmatrix} 11,48 & -0,42 & -45,16 & 0,91 & -1,29 & 3,77 \\ -0,42 & 0,34 & 1,78 & -0,28 & -0,08 & -0,29 \\ -45,16 & 1,78 & 180,84 & -3,76 & 4,40 & -15,78 \\ 0,91 & -0,28 & -3,76 & 0,27 & 0,02 & 0,39 \\ -1,29 & -0,08 & 4,40 & 0,02 & 0,93 & -1,11 \\ 3,77 & -0,29 & -15,78 & 0,39 & -1,11 & 3,73 \end{pmatrix}.$$

Определяем вектор оценок коэффициентов регрессии \mathbf{b} по формуле (2.8):

$$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = \begin{pmatrix} b_0 \\ b_1 \\ b_2 \\ b_3 \\ b_4 \\ b_5 \end{pmatrix} = \begin{pmatrix} 3,515 \\ -0,006 \\ 15,542 \\ 0,110 \\ 4,475 \\ -2,933 \end{pmatrix}.$$

Подставляя рассчитанные значения b_j в выборочное уравнение регрессии $\hat{y}_i = b_0 + \sum_{j=1}^5 b_j x_{ij}$, находим значения

\hat{y}_i , ($i = 1, 2, \dots, n$) и сводим их в 8-й столбец табл. 3.4.

Вычисляем значения $(y_i - \bar{y})^2$, $(\hat{y}_i - \bar{y})^2$, $(y_i - \hat{y}_i)^2$ (табл. 3.4, столбцы 9–11) и по формулам из табл. 2.1, 2.2 рассчитываем соответствующие суммы квадратов, дисперсии на степень свободы и средние квадратические отклонения:

$$Q = \sum_{i=1}^n (y_i - \bar{y})^2 = 74,16; s^2 = \frac{Q}{n-1} = 3,90; s = 1,98;$$

$$Q_r = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = 38,36; s_r^2 = \frac{Q_r}{p} = 7,67; s_r = 2,77;$$

$$Q_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 35,796; s_e^2 = \frac{Q_e}{n-p-1} = 2,56; s_e = 1,599.$$

Предварительно сформировав вспомогательный вектор из диагональных элементов $[(\mathbf{X}^T \mathbf{X})^{-1}]_{jj}$ матрицы $(\mathbf{X}^T \mathbf{X})^{-1}$, по формуле (2.16) находим векторы стандартных отклонений коэффициентов регрессии:

$$s_b = s_e \sqrt{[(\mathbf{X}^T \mathbf{X})^{-1}]_{jj}} = \begin{pmatrix} s_{b_0} \\ s_{b_1} \\ s_{b_2} \\ s_{b_3} \\ s_{b_4} \\ s_{b_5} \end{pmatrix} = \begin{pmatrix} 5,42 \\ 0,93 \\ 21,50 \\ 0,83 \\ 1,54 \\ 3,09 \end{pmatrix}.$$

Записываем выборочное уравнение регрессии в общепринятом виде, указывая в скобках под коэффициентами их стандартные отклонения:

$$\hat{y}_i = 3,515 - 0,006x_{i1} + 15,542x_{i2} + 0,110x_{i3} + 4,475x_{i4} - 2,932x_{i5} \quad (5,42) \quad (0,93) \quad (21,50) \quad (0,83) \quad (1,54) \quad (3,09).$$

Как видно из уравнения, для всех коэффициентов, кроме b_4 , стандартные отклонения превышают полученные значения оценок коэффициентов регрессии. Это позволяет предположить, что за исключением четвертого, все коэффициенты регрессии по t -критерию будут не значимыми.

Согласно (2.21) формируем вектор t -статистик $t_{b_j} = \frac{b_j}{s_{b_j}}$ критерия значимости коэффициентов регрессии

$$\mathbf{t}_b = \begin{pmatrix} t_{b_0} \\ t_{b_1} \\ t_{b_2} \\ t_{b_3} \\ t_{b_4} \\ t_{b_5} \end{pmatrix} = \begin{pmatrix} 0,649 \\ -0,007 \\ 0,723 \\ 0,132 \\ 2,899 \\ -0,950 \end{pmatrix}.$$

Для заданной доверительной вероятности $\gamma = 0,95$ (уровня значимости $\alpha = 0,05$) находим значение t_{kp} с помощью стандартной статистической функции СТБЮД-РАСПОБР ($a; n-p-1$)

$$t_{kp} = t_{kp}(\alpha; k = n-p-1) = 2,145, (n-p-1 = 20-5-1 = 14).$$

Поскольку только $|t_{b_4}| > t_{kp}$, с доверительным уровнем 95% делаем вывод о том, что коэффициент β_4 значим, а остальные не значимы.

Вычисляем вектор P -значений P_{b_j} для коэффициентов с помощью статистической функции СТБЮДРАСП ($|t_{b_j}|; n-p-1; 2$)

$$\mathbf{P}_b = \begin{pmatrix} P_{b_0} \\ P_{b_1} \\ P_{b_2} \\ P_{b_3} \\ P_{b_4} \\ P_{b_5} \end{pmatrix} = \begin{pmatrix} 0,527 \\ 0,995 \\ 0,482 \\ 0,897 \\ 0,012 \\ 0,358 \end{pmatrix}.$$

В силу того, что только $P_{b_4} < \alpha$, полученный с помощью t -критерия вывод подтверждается.

По формулам (2.25), (2.34) рассчитываем величину выборочного множественного коэффициента детерминации и его скорректированного значения

$$\bar{R}_{y,x}^2 = \frac{Q_r}{Q} = 1 - \frac{Q_e}{Q} = 0,517;$$

$$\bar{R}_{adj}^2 = 1 - \frac{Q_e / (n - p - 1)}{Q / (n - 1)} = 1 - (1 - \bar{R}_{y,x}^2) \frac{n - 1}{n - p - 1} = 0,345.$$

Величина коэффициента $\bar{R}_{y,x}^2$ показывает, что около 52% вариации зависимой переменной обусловлены влиянием включенных факторов, а остальные 48% — влиянием других неучтенных в модели и случайных факторов.

Согласно (3.35) рассчитываем значение F -статистики

$$F = \frac{s_r^2}{s_e^2} = \frac{Q_r(n - p - 1)}{Q_e p} = \frac{\bar{R}_{y,x}^2(n - p - 1)}{(1 - \bar{R}_{y,x}^2)p} = 3,001.$$

Критическое значение для доверительного уровня $\gamma = 0,95$ (уровня значимости $\alpha = 0,05$) находим с помощью стандартной статистической функции FPACSPOBР ($a; p; n - p - 1$)

$$F_{kp} = F_{kp}(\alpha; k_1 = p, k_2 = n - p - 1) = 2,96.$$

В силу того, что $F > F_{kp}$, с доверительным уровнем 0,95 делаем вывод о том, что уравнение регрессии значимо.

Вычисляем величину P -значения с помощью стандартной статистической функции FPACSP ($F; p; n - p - 1$)

$$P = 0,048$$

и, поскольку $P < \alpha$, вывод о значимости уравнения регрессии подтверждается.

2. Проверяем полученные результаты с помощью стандартной статистической программы ЛИНЕЙН и инструмента РЕГРЕССИЯ из пакета анализа Microsoft Excel.

Анализ полученных результатов показывает, что имеются типичные следствия мультиколлинеарности:

- коэффициенты b_1 и b_5 , соответственно характеризующие зависимости урожайности зерновых культур от числа тракторов (приведенной мощности) на 100 га и количества химических средств защиты растений, расходуемых на гектар, имеют отрицательные знаки;
- за исключением b_4 , все коэффициенты регрессии по t -критерию не значимы, в то время как модель регрессии в целом по F -критерию является значимой.

3. Проводим анализ признаков мультиколлинеарности в следующем порядке.

Вычисляем элементы матрицы выборочных парных коэффициентов корреляции R_{XX} объясняющих переменных с помощью статистической функции КОРРЕЛ ($x_j; x_k$) ($j, k = 1, 2, \dots, p$)

$$R_{XX} = \begin{pmatrix} 1 & \bar{r}_{12} & \bar{r}_{13} & \bar{r}_{14} & \bar{r}_{15} \\ \bar{r}_{21} & 1 & \bar{r}_{23} & \bar{r}_{24} & \bar{r}_{25} \\ \bar{r}_{31} & \bar{r}_{32} & 1 & \bar{r}_{34} & \bar{r}_{35} \\ \bar{r}_{41} & \bar{r}_{42} & \bar{r}_{43} & 1 & \bar{r}_{45} \\ \bar{r}_{51} & \bar{r}_{52} & \bar{r}_{53} & \bar{r}_{54} & 1 \end{pmatrix} = \\ = \begin{pmatrix} 1 & 0,85 & 0,98 & 0,11 & 0,34 \\ 0,85 & 1 & 0,88 & 0,03 & 0,46 \\ 0,98 & 0,88 & 1 & 0,03 & 0,28 \\ 0,11 & 0,03 & 0,03 & 1 & 0,57 \\ 0,34 & 0,46 & 0,28 & 0,57 & 1 \end{pmatrix}$$

а затем проверяем полученные значения, используя инструмент КОРРЕЛЯЦИЯ из пакета анализа,

Находим значение определителя матрицы \mathbf{R}_{XX} с помощью математической функции МОПРЕД (\mathbf{R}_{XX})

$$\det \mathbf{R}_{XX} = 0,003.$$

Малое значение определителя свидетельствует о возможном наличии частичной мультиколлинеарности.

Проверяем гипотезу о наличии мультиколлинеарности, для чего согласно (3.3) формируем статистику

$$\chi^2 = - \left[n - 1 - \frac{1}{6}(2p + 5) \right] \ln \det \mathbf{R}_{XX} = 95,601$$

и для заданной доверительной вероятности $\gamma = 0,95$ (уровня значимости $\alpha = 0,05$) находим значение χ_{kp}^2 с помощью стандартной статистической функции ХИ2ОБР

$$(a; \frac{1}{2}p(p-1))$$

$$\chi_{kp}^2 = \chi_{kp}^2[\alpha; k = \frac{1}{2}p(p-1)] = 18,307,$$

$$k = \frac{1}{2}p(p-1) = \frac{5 \cdot 4}{2} = 10.$$

Поскольку $\chi^2 > \chi_{kp}^2$, с доверительным уровнем $\gamma = 0,95$ принимаем альтернативную гипотезу H_1 и делаем вывод о том, что в регрессионной модели имеется мультиколлинеарность.

Вычисляем величину P -значения с помощью стандартной статистической функции ХИ2РАСП ($\chi^2; \frac{1}{2}p(p-1)$):

$$P = 4,121 \cdot 10^{-16}.$$

В силу того, что $P < \alpha$, вывод о наличии мультиколлинеарности подтверждается.

4. С помощью метода пошагового отбора переменных проводим устранение мультиколлинеарности.

а) Определяем исходные данные при учете всех факторных переменных (при $l = p = 5$).

Вычисляем элементы матрицы выборочных парных коэффициентов корреляции \mathbf{R}_{yx} с помощью статистической функции КОРРЕЛ ($y; x_j$), ($j = 1, 2, \dots, p$) и проверяем полученные значения, используя инструмент КОРРЕЛЯЦИЯ из пакета анализа

$$\mathbf{R}_{yx} = \begin{pmatrix} 1 & r_{01} & r_{02} & r_{03} & r_{04} & r_{05} \\ r_{10} & 1 & r_{12} & r_{13} & r_{14} & r_{15} \\ r_{20} & r_{21} & 1 & r_{23} & r_{24} & r_{25} \\ r_{30} & r_{31} & r_{32} & 1 & r_{34} & r_{35} \\ r_{40} & r_{41} & r_{42} & r_{43} & 1 & r_{45} \\ r_{50} & r_{51} & r_{52} & r_{53} & r_{54} & 1 \end{pmatrix} =$$

$$= \begin{pmatrix} 1 & 0,43 & 0,37 & 0,40 & 0,58 & 0,33 \\ 0,43 & 1 & 0,85 & 0,98 & 0,11 & 0,34 \\ 0,37 & 0,85 & 1 & 0,88 & 0,03 & 0,46 \\ 0,40 & 0,98 & 0,88 & 1 & 0,03 & 0,28 \\ 0,58 & 0,11 & 0,03 & 0,03 & 1 & 0,57 \\ 0,33 & 0,34 & 0,46 & 0,28 & 0,57 & 1 \end{pmatrix}$$

С помощью математической функции МОПРЕД (\mathbf{R}_{yx}) находим значение $\det \mathbf{R}_{yx} = 0,0015$ и, учитывая, что величина $\Delta_{00} = \det \mathbf{R}_{XX} = 0,0030$, вычисляем множественный выборочный коэффициент детерминации 5-го порядка по формуле (3.12)

$$\bar{R}_{y,X}^2 = \bar{R}^2(5) = 1 - \frac{\det \mathbf{R}_{yx}}{\Delta_{00}} = 0,517.$$

Затем по формулам (3.13), (3.14) определяем скорректированный выборочный коэффициент детерминации

$$\bar{R}_{adj}^2 = \bar{R}^{*2}(5) = 1 - [1 - \bar{R}^2(5)] \frac{n-1}{n-5-1} = 0,345$$

и вычисляем нижнюю доверительную границу

$$\bar{R}_{min}^2(5) = \bar{R}^{*2}(5) - 2 \sqrt{\frac{2l(n-5-1)}{(n-1)(n^2-1)}} [1 - \bar{R}^2(5)] = 0,214.$$

Понятно, что величины $\bar{R}_{y,X}^2$ и \bar{R}_{adj}^2 совпадают со значениями коэффициентов, полученных ранее при построении выборочного уравнения регрессии.

б) В качестве оптимального числа l_{opt} предикторов регрессионной модели выбираем то значение l , при котором величина $\bar{R}_{min}^2(l)$ по мере добавления объясняющих переменных достигает своего максимума, осуществляя этот процесс по шагам.

1-й шаг ($l = 1$):

- среди всех возможных предикторов выбираем объясняющую переменную x_4 , которая имеет наибольшее значение выборочного коэффициента парной корреляции $\bar{r}_{04} = 0,58$, находящегося в матрице \mathbf{R}_{yX} на 4-й позиции в 0-й строке или столбце (это значение подчеркнуто);
- рассчитываем коэффициент детерминации 1-го порядка

$$\bar{R}^2(1) = \bar{r}_{04}^2 = 0,333,$$

его скорректированное значение

$$\bar{R}^{*2}(1) = 1 - [1 - \bar{R}^2(1)] \frac{n-1}{n-1-1} = 0,296$$

и нижнюю доверительную границу

$$\bar{R}_{min}^2(1) = \bar{R}^{*2}(1) - 2 \sqrt{\frac{2l(n-1-1)}{(n-1)(n^2-1)}} [1 - \bar{R}^2(1)] = 0,204.$$

2-й шаг ($l = 2$):

- строим подматрицы $\mathbf{R}_{yx_4x_k}$, которые находятся из матрицы \mathbf{R}_{yX} путем вычеркивания всех строк и столбцов, кроме тех, которые отвечают y , x_4 и x_k ($k = 1, 2, 3, 5$)

$$\mathbf{R}_{yx_4x_1} = \begin{pmatrix} 1 & 0,43 & 0,58 \\ 0,43 & 1 & 0,11 \\ 0,58 & 0,11 & 1 \end{pmatrix}; \quad \mathbf{R}_{yx_4x_2} = \begin{pmatrix} 1 & 0,37 & 0,58 \\ 0,37 & 1 & 0,03 \\ 0,58 & 0,03 & 1 \end{pmatrix};$$

$$\mathbf{R}_{yx_4x_3} = \begin{pmatrix} 1 & 0,40 & 0,58 \\ 0,40 & 1 & 0,03 \\ 0,58 & 0,03 & 1 \end{pmatrix}; \quad \mathbf{R}_{yx_4x_5} = \begin{pmatrix} 1 & 0,58 & 0,33 \\ 0,58 & 1 & 0,57 \\ 0,33 & 0,57 & 1 \end{pmatrix};$$

- с помощью математической функции МОПРЕД (-) находим значения соответствующих определителей и алгебраических дополнений 1-го элемента 1-й строки полученных подматриц

$$\det \mathbf{R}_{yx_4x_1} = 0,524; \quad \Delta_{11} = 0,988;$$

$$\det \mathbf{R}_{yx_4x_2} = 0,538; \quad \Delta_{11} = 0,999;$$

$$\det \mathbf{R}_{yx_4x_3} = 0,517; \quad \Delta_{11} = 0,999;$$

$$\det \mathbf{R}_{yx_4x_5} = 0,450; \quad \Delta_{11} = 0,674;$$

- по формуле $\bar{R}_{y/x_4x_k}^2 = 1 - \frac{\det \mathbf{R}_{yx_4x_k}}{\Delta_{11}}$ вычисляем соответствующие выборочные множественные коэффициенты детерминации 2-го порядка

$$\bar{R}_{y/x_4x_1}^2 = 0,470; \bar{R}_{y/x_4x_2}^2 = 0,462;$$

$$\bar{R}_{y/x_4x_3}^2 = 0,482; \bar{R}_{y/x_4x_5}^2 = 0,333$$

и выбираем объясняющую переменную x_3 , имеющую наибольшее значение коэффициента детерминации

$$\bar{R}^2(2) = \bar{R}_{y/x_4x_3}^2 = 0,482;$$

- рассчитываем соответствующий скорректированный коэффициент детерминации, нижнюю доверительную границу

$$\bar{R}^{*2}(2) = 1 - [1 - \bar{R}^2(2)] \frac{n-1}{n-2-1} = 0,421;$$

$$\bar{R}_{\min}^2(2) = \bar{R}^{*2}(2) - 2 \sqrt{\frac{2l(n-2-1)}{(n-1)(n^2-1)}} [1 - \bar{R}^2(2)] = 0,323$$

и, поскольку $\bar{R}_{\min}^2(2) > \bar{R}_{\min}^2(1)$, переходим к следующему шагу.

3-й шаг ($l = 3$):

- строим подматрицы $R_{yx_4x_3x_k}$, которые находятся из матрицы R_{yx} путем вычеркивания всех строк и столбцов, кроме тех, которые отвечают y , x_4 , x_3 и x_k ($k = 1, 2, 5$):

$$R_{yx_4x_3x_1} = \begin{pmatrix} 1 & 0,43 & 0,40 & 0,58 \\ 0,43 & 1 & 0,98 & 0,11 \\ 0,40 & 0,98 & 1 & 0,03 \\ 0,58 & 0,11 & 0,03 & 1 \end{pmatrix};$$

$$R_{yx_4x_3x_2} = \begin{pmatrix} 1 & 0,37 & 0,40 & 0,58 \\ 0,37 & 1 & 0,88 & 0,03 \\ 0,40 & 0,88 & 1 & 0,03 \\ 0,58 & 0,03 & 0,03 & 1 \end{pmatrix};$$

$$R_{yx_4x_3x_5} = \begin{pmatrix} 1 & 0,40 & 0,58 & 0,33 \\ 0,40 & 1 & 0,03 & 0,28 \\ 0,58 & 0,03 & 1 & 0,57 \\ 0,33 & 0,28 & 0,57 & 1 \end{pmatrix};$$

- с помощью математической функции МОПРЕД (-) находим значения соответствующих определителей и алгебраических дополнений 1-го элемента 1-й строки полученных подматриц

$$\det R_{yx_4x_3x_1} = 0,019; \Delta_{11} = 0,037;$$

$$\det R_{yx_4x_3x_2} = 0,115; \Delta_{11} = 0,222;$$

$$\det R_{yx_4x_3x_5} = 0,304; \Delta_{11} = 0,606;$$

- по формуле $\bar{R}_{y/x_4x_3x_k}^2 = 1 - \frac{\det R_{yx_4x_3x_k}}{\Delta_{11}}$ вычисляем со-

ответствующие выборочные множественные коэффициенты детерминации 3-го порядка

$$\bar{R}_{y/x_4x_3x_1}^2 = 0,485; \bar{R}_{y/x_4x_3x_2}^2 = 0,484; \bar{R}_{y/x_4x_3x_5}^2 = 0,498$$

и выбираем объясняющую переменную x_5 , имеющую наибольшее значение коэффициента детерминации

$$\bar{R}^2(3) = \bar{R}_{y/x_4x_3x_5}^2 = 0,498;$$

- рассчитываем соответствующий скорректированный коэффициент детерминации, нижнюю доверительную границу

$$\bar{R}^{*2}(3) = 1 - [1 - \bar{R}^2(3)] \frac{n-1}{n-3-1} = 0,404;$$

$$\bar{R}_{\min}^2(3) = \bar{R}^{*2}(3) - 2 \sqrt{\frac{2l(n-3-1)}{(n-1)(n^2-1)}} [1 - \bar{R}^2(3)] = 0,291$$

и, поскольку $\bar{R}^2_{\min}(3) < \bar{R}^2_{\min}(2)$, ограничиваемся $l_{opt} = 2$ объясняющими переменными x_3 и x_4 , отобранными на 2-м шаге;

- строим графики зависимостей $\bar{R}^2(l)$, $\bar{R}^{*2}(l)$ и $\bar{R}_{\min}(l)$ от номера шага l (рис. 3.8).

$$\bar{R}^2(l), \bar{R}^{*2}(l), \bar{R}_{\min}(l)$$

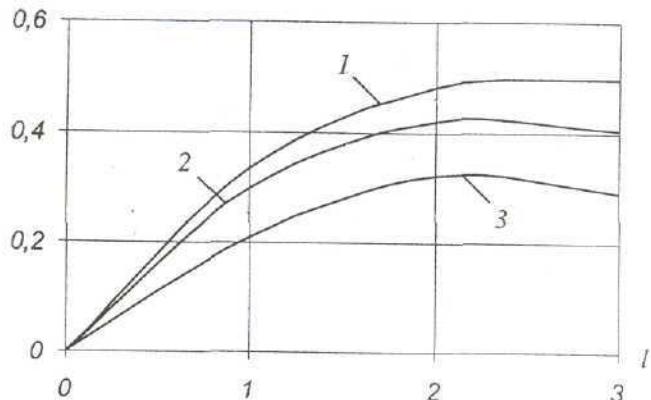


Рис. 3.8. Графики зависимостей выборочных коэффициентов детерминации от номера шага l : 1 — $\bar{R}^2(l)$; 2 — $\bar{R}^{*2}(l)$; 3 — $\bar{R}_{\min}(l)$

5. Для определения параметров выборочного уравнения линейной регрессии при учете только $l_{opt} = 2$ отобранных объясняющих переменных x_{i3} и x_{i4} строим расчетную таблицу (табл. 3.5, столбцы 1–4).

Строим матрицу \mathbf{X} объясняющих переменных размером 20×3 и транспонированную матрицу \mathbf{X}^T

$$\mathbf{X} = \begin{pmatrix} 1 & 2,05 & 0,32 \\ 1 & 0,46 & 0,59 \\ \dots & \dots & \dots \\ 1 & 0,17 & 0,99 \end{pmatrix}; \quad \mathbf{X}^T = \begin{pmatrix} 1 & 1 & \dots & 1 \\ 2,05 & 0,46 & \dots & 0,17 \\ 0,32 & 0,59 & \dots & 0,99 \end{pmatrix}.$$

Таблица 3.5

Расчетная таблица

i	y_i	x_{i3}	x_{i4}	\hat{y}_i	$(y_i - \bar{y})^2$	$(\hat{y}_i - \bar{y})^2$	$(y_i - \hat{y}_i)^2$
1	9,7	2,05	0,32	8,98	0,03	0,30	0,52
2	8,4	0,46	0,59	9,47	1,27	0,00	1,15
3	9	2,46	0,3	9,03	0,28	0,25	0,00
4	9,9	6,44	0,43	10,60	0,14	1,16	0,49
5	9,6	2,16	0,39	9,25	0,01	0,07	0,12
6	8,6	2,69	0,32	9,16	0,86	0,13	0,31
7	12,5	0,73	0,42	8,96	8,85	0,32	12,56
8	7,6	0,42	0,21	8,14	3,71	1,92	0,29
9	6,9	0,49	0,2	8,12	6,89	1,96	1,50
10	13,5	3,02	1,37	12,90	15,80	11,41	0,36
11	9,7	3,19	0,73	10,73	0,03	1,44	1,05
12	10,7	3,3	0,25	9,09	1,38	0,19	2,59
13	12,1	11,51	0,39	11,89	6,63	5,59	0,04
14	9,7	2,26	0,82	10,78	0,03	1,57	1,16
15	7	0,6	0,13	7,91	6,38	2,60	0,83
16	7,2	0,3	0,09	7,69	5,41	3,37	0,24
17	8,2	1,44	0,2	8,39	1,76	1,28	0,04
18	8,4	0,05	0,43	8,80	1,27	0,53	0,16
19	13,1	0,03	0,73	9,84	12,78	0,10	10,66
20	8,7	0,17	0,99	10,78	0,68	1,57	4,32
Σ	190,5				74,16	35,77	38,39
ср.	9,53				74,16		
$\bar{\sigma}^2$					3,90	17,89	2,26
$\bar{\sigma}$					1,98	4,23	1,50

Находим произведение матриц $\mathbf{X}^T \mathbf{X}$ и $\mathbf{X}^T \mathbf{y}$

$$\mathbf{X}^T \mathbf{X} = \begin{pmatrix} 20 & 43,77 & 9,31 \\ 43,77 & 235,12 & 20,87 \\ 9,31 & 20,87 & 6,30 \end{pmatrix}; \quad \mathbf{X}^T \mathbf{y} = \begin{pmatrix} 190,50 \\ 457,89 \\ 95,65 \end{pmatrix}.$$

Рассчитываем обратную матрицу $(\mathbf{X}^T \mathbf{X})^{-1}$

$$(\mathbf{X}^T \mathbf{X})^{-1} = \begin{pmatrix} 0,191 & -0,015 & -0,233 \\ -0,015 & 0,007 & 0,002 \\ -0,233 & -0,002 & 0,509 \end{pmatrix}.$$

По формуле (2.8) определяем вектор оценок коэффициентов регрессии \mathbf{b}

$$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y} = \begin{pmatrix} b_0 \\ b_3 \\ b_4 \end{pmatrix} = \begin{pmatrix} 7,291 \\ 0,282 \\ 3,475 \end{pmatrix}.$$

Подставляя рассчитанные значения b_j в выборочное уравнение регрессии $\hat{y}_i = b_0 + b_3 x_{i3} + b_4 x_{i4}$, находим значения \hat{y}_i , ($i = 1, 2, \dots, n$) и сводим их в 5-й столбец табл. 3.5.

Вычисляем значения $(y_i - \bar{y})^2$, $(\hat{y}_i - \bar{y})^2$, $(y_i - \hat{y}_i)^2$ (табл. 3.5, столбцы 6–8) и по формулам из табл. 2.1, 2.2 рассчитываем соответствующие суммы квадратов, дисперсии на степень свободы и средние квадратические отклонения

$$Q = \sum_{i=1}^n (y_i - \bar{y})^2 = 74,16; s^2 = \frac{Q}{n-1} = 3,90; s = 1,98;$$

$$Q_r = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = 35,77; s_r^2 = \frac{Q_r}{p} = 17,89; s_r = 4,23;$$

$$Q_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = 38,39; s_e^2 = \frac{Q_e}{n-p-1} = 2,26; s_e = 1,50.$$

Предварительно сформировав вспомогательный вектор из диагональных элементов $[(\mathbf{X}^T \mathbf{X})^{-1}]_{jj}$ матрицы $(\mathbf{X}^T \mathbf{X})^{-1}$, по формуле (2.16) находим векторы стандартных отклонений коэффициентов регрессии

$$s_b = s_e \sqrt{[(\mathbf{X}^T \mathbf{X})^{-1}]_{jj}} = \begin{pmatrix} s_{b_0} \\ s_{b_3} \\ s_{b_4} \end{pmatrix} = \begin{pmatrix} 0,66 \\ 0,13 \\ 1,07 \end{pmatrix}.$$

Записываем выборочное уравнение регрессии в общепринятом виде, указывая в скобках под коэффициентами их стандартные отклонения

$$\hat{y}_i = 7,291 + 0,282x_{i3} + 3,475x_{i4}. \quad \begin{matrix} (0,66) & (0,13) & (1,07) \end{matrix}$$

Как видно из уравнения, для всех коэффициентов стандартные отклонения меньше полученных значений оценок коэффициентов регрессии. Это позволяет предположить, что все коэффициенты регрессии по t -критерию будут значимыми.

Согласно (2.21) формируем вектор t -статистик $t_{b_j} = \frac{b_j}{s_{b_j}}$ критерия значимости коэффициентов регрессии

$$t_b = \begin{pmatrix} t_{b_0} \\ t_{b_3} \\ t_{b_4} \end{pmatrix} = \begin{pmatrix} 11,10 \\ 2,21 \\ 3,24 \end{pmatrix}.$$

Для заданной доверительной вероятности $\gamma = 0,95$ (уровня значимости $\alpha = 0,05$) находим значение t_{kp} с помощью стандартной статистической функции СТЫЮД-РАСПОБР ($a; n-p-1$)

$$t_{kp} = t_{kp}(\alpha; k = n-p-1) = 2,11, \quad (n-p-1 = 20-2-1 = 17).$$

Поскольку $|t_{b_j}| > t_{kp}$, с доверительным уровнем 95% делаем вывод о том, что все коэффициенты β_j значимы.

Вычисляем вектор P -значений P_{b_j} для коэффициентов с помощью стандартной функции СТЫЮДРАСП ($|t_{b_j}|; n-p-1; 2$)

$$\mathbf{P}_b = \begin{pmatrix} P_{b_0} \\ P_{b_3} \\ P_{b_4} \end{pmatrix} = \begin{pmatrix} 3,28 \cdot 10^{-9} \\ 0,041 \\ 0,005 \end{pmatrix}.$$

В силу того, что $P_{b_j} < \alpha$, полученный с помощью t -критерия вывод о значимости коэффициентов β_0 , β_3 и β_4 подтверждается.

По формулам (2.25), (2.34) рассчитываем величину выборочного множественного коэффициента детерминации и его скорректированного значения

$$\bar{R}_{y,x}^2 = \frac{Q_r}{Q} = 1 - \frac{Q_e}{Q} = 0,482;$$

$$\bar{R}_{adj}^2 = 1 - \frac{Q_e / (n-p-1)}{Q / (n-1)} = 1 - (1 - \bar{R}_{y,x}^2) \frac{n-1}{n-p-1} = 0,421.$$

Величина коэффициента $\bar{R}_{y,x}$ показывает, что более 48% вариации зависимой переменной обусловлены влиянием включенных факторов, а остальные 52% — влиянием других неучтенных в модели и случайных факторов.

Используя (2.35), рассчитываем значение F -статистики

$$F = \frac{s_r^2}{s_e^2} = \frac{Q_r(n-p-1)}{Q_e p} = \frac{\bar{R}_{y,x}^2 (n-p-1)}{(1-\bar{R}_{y,x}^2) p} = 7,92.$$

Критическое значение для доверительного уровня $\gamma = 0,95$ (уровня значимости $\alpha = 0,05$) находим с помощью стандартной статистической функции FPACSPB ($a; p; n-p-1$)

$$F_{kp} = F_{kp}(\alpha; k_1 = p, k_2 = n-p-1) = 3,59.$$

В силу того, что $F > F_{kp}$, с доверительным уровнем 0,95 делаем вывод о том, что уравнение регрессии значимо.

3. Различные аспекты регрессионных моделей

Вычисляем величину $P = 0,0037$ с помощью стандартной статистической функции FPACSP ($F; p; n-p-1$) и, поскольку $P < \alpha$, этот вывод подтверждается.

6. Проверяем полученные результаты с помощью стандартной статистической программы ЛИНЕЙН и инструмента РЕГРЕССИЯ из пакета анализа Microsoft Excel.

Задача 3.2

Имеются экономические данные по экономическому развитию некоторой крупной страны за определенный период (i — условный номер года) (табл. 3.6).

Таблица 3.6

Экономические данные: y_i — общее число занятых в экономике (тыс. чел.); x_{i1} — дефлятор (индекс) цен (%); x_{i2} — валовой национальный продукт (млрд дол.); x_{i3} — общее число безработных (тыс. чел.); x_{i4} — число военнослужащих (тыс. чел.); x_{i5} — неработающее население от 14 лет (тыс. чел.) $\bar{R}(l)$; 3 — $\bar{R}_{min}(l)$

i	y_i	y_{il}	y_{il}	y_{il}	y_{il}	y_{il}
1	60323	83	234,289	2356	1590	107608
2	61122	88,5	259,426	2325	1456	108632
3	60171	88,2	258,054	3682	1616	109773
4	61187	89,5	284,599	3351	1650	110929
5	63221	96,2	328,975	2099	3099	112075
6	63639	98,1	346,999	1932	3594	113270
7	64989	99	365,385	1870	3547	115094
8	63761	100	363,112	3578	3350	116219
9	66019	101,2	387,469	2904	3048	117388
10	67857	104,6	419,18	2822	2857	118734
11	68169	108,4	442,769	2936	2798	120445
12	66513	110,8	444,546	4681	2637	121950