

1 Контрольная работа 2

На выполнение заданий отводится 50 минут. Разрешается пользоваться калькуляторами, компьютерами, любыми материалами. Не разрешается совместное (коллективное) решение задач. Для зачтения контрольной нужно получить не менее 6 баллов из 10.

1.1 Разбор пробного варианта

Задача 1 (16). 110 точек вида (y, x_1, x_2) описано зависимостью вида $y = ax_1 + bx_2 + c$. Рассчитайте число степеней свободы. Найдите коэффициенты f_1 и f_2 в $F_{\text{crit}}(p, f_1, f_2)$.

Решение. Число коэффициентов модели $k = 3$, число точек $n = 110$. Число степеней свободы $f = n - k = 107$.

Выражение для F_{emp} выглядит следующим образом:

$$F_{\text{emp}} = \frac{ESS/f_1}{RSS/f_2} < F_{\text{crit}}(p, f_1, f_2) \quad (1)$$

В нашем случае $f_1 = k - 1 = 2$ и $f_2 = n - k = 107$.

Задача 2 (16). Что такое мультиколлинеарность и как она влияет на результаты многомерной линейной регрессии?

Решение. Мультиколлинеарность — наличие линейной зависимости между объясняющими переменными (факторами) регрессионной модели. Выраженная мультиколлинеарность может приводить к плохой обусловленности системы линейных уравнений в МНК и вести к большим погрешностям в коэффициентах модели и их неустойчивости по отношению к небольшим изменениям в исходных данных.

Задача 3 (26). Пусть в нелинейной регрессии функция имеет вид $y = \beta_1 + \beta_2 \ln(\beta_3 x)$. Запишите якобиан $J_{ij} = \frac{\partial f(x_i)}{\partial \beta_j}$.

Решение. Найдём производные функции $y(\beta)$ по переменным β_i :

$$\begin{cases} \frac{\partial y}{\partial \beta_1} = 1 \\ \frac{\partial y}{\partial \beta_2} = \ln(\beta_3 x) \\ \frac{\partial y}{\partial \beta_3} = \beta_2 \left(\frac{1}{x\beta_3} \cdot x \right) = \frac{\beta_2}{\beta_3} \end{cases} \quad (2)$$

Запишем матрицу Якоби

$$J = \begin{pmatrix} 1 & \ln(\beta_3 x_1) & \frac{\beta_2}{\beta_3} \\ 1 & \ln(\beta_3 x_2) & \frac{\beta_2}{\beta_3} \\ \vdots & \ddots & \vdots \\ 1 & \ln(\beta_3 x_n) & \frac{\beta_2}{\beta_3} \end{pmatrix} \quad (3)$$

Задача 4 (16). Линеаризовать функцию $y = a \exp(bx)$. Указать независимую и зависимую переменную после преобразования.

Решение. Прологарифмируем функцию:

$$\ln y = \ln a + bx \quad (4)$$

Новые переменные: $\ln y$ (зависимая) и x (независимая).

Задача 5 (16). Линеаризовать функцию $C_p(T) = AT + B/T + C$. Выписать матрицы X и y из системы уравнений $X\hat{\beta} + e = y$.

Решение. Перейдём от одномерной нелинейной регрессии к многомерной линейной, используя следующие подстановки:

$$\begin{cases} y = C_p \\ x_1 = T \\ x_2 = T^{-1} \end{cases} \quad (5)$$

Матрицы X , y и $\hat{\beta}$ из переопределённой системы уравнений $X\hat{\beta} + e = y$ (столбец из единиц соответствует константе C):

$$X = \begin{pmatrix} T_1 & T_1^{-1} & 1 \\ T_2 & T_2^{-1} & 1 \\ \vdots & \ddots & \vdots \\ T_n & T_n^{-1} & 1 \end{pmatrix}; \quad y = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}; \quad \hat{\beta} = \begin{pmatrix} \hat{A} \\ \hat{B} \\ \hat{C} \end{pmatrix} \quad (6)$$

Задача 6 (46). Описать данные методом наименьших квадратов, используя зависимость $y = ax$. Записать сумму квадратов отклонений RSS в явном виде и решением уравнения $\frac{\partial RSS}{\partial a} = 0$ получить выражения и численные значения для a (значения коэффициента регрессии) и s_a (его стандартного отклонения).

$$X = [-2, -1, 0, 1, 2] \\ Y = [-3.93, -1.55, -0.60, 3.59, 4.43]$$

Решение. Записать сумму квадратов отклонений RSS в явном виде и решением уравнения $\frac{\partial RSS}{\partial a} = 0$ получить выражение для a .

Найдём производную суммы квадратов отклонений по параметру модели:

$$\begin{aligned} \frac{\partial RSS}{\partial a} &= \frac{\partial \sum_i (\hat{y}_i - y_i)^2}{\partial a} = \frac{\partial \sum_i (ax_i - y_i)^2}{\partial a} = \sum_i 2(ax_i - y_i) x_i = 0 \Leftrightarrow \\ & a \sum_i x_i^2 - \sum_i x_i y_i = 0 \Leftrightarrow a = \frac{\sum_i x_i y_i}{\sum_i x_i^2} = \frac{\overline{xy}}{\overline{x^2}} \quad (7) \end{aligned}$$

Рассчитаем значения $\overline{x^2}$, \overline{xy} и коэффициента a

$$\overline{x^2} = \frac{1}{5} ((-2)^2 + (-1)^2 + 0^2 + 1^2 + 2^2) = \frac{2 \cdot 4 + 2 \cdot 1}{5} = \frac{10}{5} = 2 \quad (8)$$

$$\begin{aligned} \overline{xy} &= \frac{1}{5} (-2 \cdot (-3.93) - 1 \cdot (-1.55) + 0 \cdot (-0.60) + 1 \cdot (3.59) + 2 \cdot (4.43)) = \\ & \frac{2 \cdot 3.93 + 1.55 + 3.59 + 2 \cdot 4.43}{5} = 4.372 \quad (9) \end{aligned}$$

$$a = \frac{\overline{xy}}{\overline{x^2}} = \frac{4.372}{2} = 2.186 \quad (10)$$

Найдём стандартное отклонение s_a :

$$s_a^2 = \hat{\sigma}^2 (X^\top X)^{-1} = \frac{\sum_i (\hat{y}_i - y_i)^2}{n-1} \cdot \left((x_1 \quad x_2 \quad \cdots \quad x_n) \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{pmatrix} \right)^{-1} =$$
$$\frac{\sum_i (\hat{y}_i - y_i)^2}{(n-1) \sum_i x_i^2} = \frac{(0.442^2 + 0.636^2 + 0.60^2 + 1.404^2 + 0.058^2)}{4 \cdot 10} = \frac{2.934}{40} = 0.07335 \Rightarrow s_a = 0.271$$
(11)

1.2 Полный список теоретических вопросов (задача 2)

- Что такое мультиколлинеарность и как она влияет на результаты многомерной линейной регрессии?
- Означает ли нулевой коэффициент корреляции отсутствие зависимости между величинами? Ответ проиллюстрируйте графиком.
- Как проверить, является ли регрессионная зависимость статистически значимой?
- Как связаны коэффициент корреляции и коэффициент детерминации?
- Как проверить, является ли один из коэффициентов регрессии статистически значимым?
- Докажите, что формула для ковариационной матрицы коэффициентов регрессии $C = \text{cov}(\hat{\beta}, \hat{\beta}) = \hat{\sigma}^2 (J^\top J)^{-1}$ (нелинейная регрессия) переходит в $C = \hat{\sigma}^2 (X^\top X)^{-1}$ в случае линейной регрессии.
- В чём преимущество метода Левенберга-Марквардта по сравнению с методом Гаусса-Ньютона?
- В чём разница между доверительным (confidence interval) и предсказательным (prediction interval) интервалом значения \hat{y} ? Ответ проиллюстрируйте графиком.