

Множественная регрессия

Пусть имеются случайные величины ξ_1, \dots, ξ_n с совместной плотностью $f(x_1, x_2, \dots, x_n)$. Регрессией или условным математическим ожиданием случайной величины ξ_1 при фиксированных значениях случайных величин ξ_i , $i = 2, \dots, n$, называется функция, зависящая от переменных x_2, \dots, x_n , вида

$$E(\xi_1 | \xi_2 = x_2, \dots, \xi_n = x_n) = \frac{\int_{-\infty}^{\infty} x_1 f(x_1, \dots, x_n) dx_1}{\int_{-\infty}^{\infty} f(x_1, \dots, x_n) dx_1}$$

Поверхность регрессии описывается уравнением $x_1 = m_1(x_2, \dots, x_n)$.

Линейная среднеквадратичная регрессия

Для упрощения выводов будем считать $E\xi_i = 0$. Формулы для произвольного центра тяжести будут получаться простой заменой ξ_i на $\xi_i - m_i$. Среднеквадратичская регрессия величины ξ_1 относительно ξ_2, \dots, ξ_n определяется как гиперплоскость

$$\xi_1 = \beta_{12}\xi_2 + \dots + \beta_{1n}\xi_n, \quad (1)$$

дающая наилучшую аппроксимацию математического ожидания квадрата разности

$$E(\xi_1 - \beta_{12}\xi_2 - \dots - \beta_{1n}\xi_n)^2 \rightarrow \min,$$

т.е. правая часть (1) является наилучшей линейной оценкой ξ_1 величинами ξ_2, \dots, ξ_n в смысле минимума (??).

Коэффициенты β_{1i} называются частными коэффициентами регрессии.

Вычисление частных коэффициентов регрессии

Для их вычисления продифференцируем

$E(\xi_1 - \beta_{12}\xi_2 - \dots - \beta_{1n}\xi_n)^2$ по β_{1i} .

$$\begin{cases} \frac{d}{d\beta_{12}} : & -2E\xi_2(\xi_1 - \beta_{12}\xi_2 - \dots - \beta_{1n}\xi_n) = 0 \\ & \dots \\ \frac{d}{d\beta_{1n}} : & -2E\xi_n(\xi_1 - \beta_{12}\xi_2 - \dots - \beta_{1n}\xi_n) = 0 \end{cases}$$

Это равносильно при $\lambda_{ij} = E\xi_i\xi_j$ системе уравнений

$$\begin{cases} \lambda_{22}\beta_{12} + \dots + \lambda_{2n}\beta_{1n} = \lambda_{21} \\ \dots \\ \lambda_{n2}\beta_{12} + \dots + \lambda_{nn}\beta_{1n} = \lambda_{n1} \end{cases} \quad (2)$$

Определитель этой системы равен алгебраическому дополнению Λ_{11} матрицы вторых моментов

$$\Lambda = \begin{bmatrix} \lambda_{11} & \lambda_{12} & \dots & \lambda_{1n} \\ \lambda_{21} & \lambda_{22} & \dots & \lambda_{2n} \\ & & \dots & \\ \lambda_{n1} & \lambda_{n2} & \dots & \lambda_{nn} \end{bmatrix}$$

По теореме Крамера, β_{12} равно отношению определителя

$$\begin{vmatrix} \lambda_{21} & \lambda_{23} & \dots & \lambda_{2n} \\ & & \dots & \\ \lambda_{n1} & \lambda_{n3} & \dots & \lambda_{nn} \end{vmatrix},$$

который равен $-\Lambda_{12}$, к определителю Λ_{11} , т.е.

$$\beta_{12} = -\Lambda_{12}/\Lambda_{11}.$$

Коэффициент β_{13} равен отношению определителя

$$\begin{vmatrix} \lambda_{22} & \lambda_{21} & \lambda_{24} & \dots & \lambda_{2n} \\ & & & \dots & \\ \lambda_{n2} & \lambda_{n1} & \lambda_{n4} & \dots & \lambda_{nn} \end{vmatrix}, \quad (3)$$

полученного в результате замены в матрице Λ_{11} второго столбца на столбец свободных членов системы (2), к определителю Λ_{11} . Поменяем местами первые два столбца. Определитель (3) равен

$$- \begin{vmatrix} \lambda_{21} & \lambda_{22} & \lambda_{24} & \dots & \lambda_{2n} \\ & & & \dots & \\ \lambda_{n1} & \lambda_{n2} & \lambda_{n4} & \dots & \lambda_{nn} \end{vmatrix} = -\Lambda_{13}, \quad (4)$$

т.е.

$$\beta_{13} = -\frac{\Lambda_{13}}{\Lambda_{11}}.$$

Аналогично получаем, что

$$\beta_{1k} = -\frac{\Lambda_{1k}}{\Lambda_{11}}. \quad (5)$$

Простой перестановкой индексов получаем

$$\beta_{ik} = -\frac{\Lambda_{ik}}{\Lambda_{ii}}. \quad (6)$$

Остатки и остаточная дисперсия

Ограничимся рассмотрением случая, когда $|\Lambda_{11}| \neq 0$ и все $E\xi_i = 0$. Случайная величина вида

$$\eta_{1 \cdot 23 \dots n} = \xi_1 - \beta_{12}\xi_2 - \dots - \beta_{1n}\xi_n \quad (7)$$

называется остатком величины ξ_1 относительно ξ_2, \dots, ξ_n .

Покажем, что остаток не коррелирован ни с одной из "вычитаемых" случайных величин. Из $\beta_{1k} = -\frac{\Lambda_{1k}}{\Lambda_{11}}$ и из того, что $1 = \Lambda_{11}/\Lambda_{11}$ имеем выражение остатка через линейную комбинацию случайных величин

$$\eta_{1 \cdot 23 \dots n} = \frac{1}{\Lambda_{11}} \sum_{k=1}^n \Lambda_{1k} \xi_k. \quad (8)$$

Отсюда, с учетом того, что $E\xi_i = 0$, получаем

$$E\eta_{1 \cdot 23 \dots n} = 0. \quad (9)$$

$$\begin{aligned} E\xi_i\eta_{1\cdot 23\dots n} &= \frac{1}{\Lambda_{11}} \sum_{k=1}^n E\xi_i\xi_k\Lambda_{1k} = \\ &= \frac{1}{\Lambda_{11}} \sum_{k=1}^n \lambda_{ik}\Lambda_{1k} = \begin{cases} \frac{\Lambda}{\Lambda_{11}}, & i = 1, \\ 0, & i \neq 1, \end{cases} \end{aligned} \quad (10)$$

Так как $\sum_{k=1}^n \lambda_{1k}\Lambda_{1k} = \Lambda$, а $\sum_{k=1}^n \lambda_{ik}\Lambda_{1k} = 0$. Дисперсия остатка

$$\sigma_{1\cdot 23\dots n}^2 = E(\eta_{1\cdot 23\dots n}^2).$$

Заменяем одну из η на $\eta_{1\cdot 23\dots n} = \frac{1}{\Lambda_{11}} \sum_{k=1}^n \Lambda_{1k}\xi_k$. В силу (10)

$$\sigma_{1\cdot 23\dots n}^2 = E\left(\frac{1}{\Lambda_{11}} \sum_{i=1}^n \Lambda_{1i}\xi_i\eta_{1\cdot 23\dots n}\right) = E(\xi_1\eta_{1\cdot 23\dots n}) = \frac{\Lambda}{\Lambda_{11}}. \quad (11)$$

Коэффициент корреляции между остатками

$$\rho_{12 \cdot 34 \dots n} = \text{cor}(\eta_{1 \cdot 34 \dots n}, \eta_{2 \cdot 34 \dots n}) = \frac{E(\eta_{1 \cdot 34 \dots n} \eta_{2 \cdot 34 \dots n})}{\sqrt{E(\eta_{1 \cdot 34 \dots n})^2 E(\eta_{2 \cdot 34 \dots n})^2}} \quad (12)$$

$$E\eta_{1 \cdot 34 \dots n}^2 = E(\xi_1 \eta_{1 \cdot 34 \dots n}) = \frac{\Lambda_{22}}{\Lambda_{22 \cdot 11}}, \quad E\eta_{2 \cdot 34 \dots n}^2 = \frac{\Lambda_{11}}{\Lambda_{11 \cdot 22}},$$

$$E(\eta_{1 \cdot 34 \dots n} \eta_{2 \cdot 34 \dots n}) = E(\xi_1 \eta_{2 \cdot 34 \dots n}), \quad (13)$$

так как $\eta_{1 \cdot 34 \dots n} = \frac{1}{\Lambda_{22 \cdot 11}} \sum_{k=1, k \neq 2}^n \Lambda_{22 \cdot 1k} \xi_k,$

$$E\xi_k \eta_{2 \cdot 34 \dots n} \begin{cases} = 0, & k = 3, 4, \dots, n \\ \neq 0, & k = 2 \\ \neq 0, & k = 1 \end{cases}$$

Так как $\eta_{2.34\dots n} = \frac{1}{\Lambda_{11.22}} \sum_{k=2}^n \Lambda_{11.2k} \xi_k$, то (13) имеет вид

$$\begin{aligned} E(\xi_1 \eta_{2.34\dots n}) &= \frac{1}{\Lambda_{11.22}} \sum_{k=2}^n \Lambda_{11.2k} E \xi_1 \xi_k = \\ &= \frac{1}{\Lambda_{11.22}} \sum_{k=2}^n \Lambda_{11.2k} \lambda_{1k} = -\frac{\Lambda_{12}}{\Lambda_{11.22}}. \end{aligned}$$

Таким образом,

$$\rho_{12.34\dots n} = -\frac{\Lambda_{12}}{\sqrt{\Lambda_{11}\Lambda_{22}}} \quad (14)$$

Между частной корреляцией и соответствующим частным коэффициентом регрессии имеет место линейная зависимость. Согласно (14) и (5) имеем

$$\varrho_{12 \cdot 34 \dots n} = -\frac{\Lambda_{12}}{\sqrt{\Lambda_{11}\Lambda_{22}}} = -\frac{\Lambda_{12}}{\Lambda_{11}} \sqrt{\frac{\Lambda_{11}}{\Lambda_{22}}} = \beta_{12 \cdot 34 \dots n} \sqrt{\frac{\Lambda_{11}}{\Lambda_{22}}}. \quad (15)$$

Для случая $n = 3$ матрица вторых моментов Λ имеет вид

$$\Lambda = \begin{bmatrix} \sigma_1^2 & \sigma_1\sigma_2\varrho_{12} & \sigma_1\sigma_3\varrho_{13} \\ \sigma_1\sigma_2\varrho_{12} & \sigma_2^2 & \sigma_2\sigma_3\varrho_{23} \\ \sigma_1\sigma_3\varrho_{13} & \sigma_2\sigma_3\varrho_{23} & \sigma_3^2 \end{bmatrix}$$

$$\begin{aligned} \varrho_{12 \cdot 3} &= -\frac{\Lambda_{12}}{\sqrt{\Lambda_{11}\Lambda_{22}}} = \frac{\sigma_1\sigma_2\varrho_{12}\sigma_3^2 - \sigma_1\sigma_3\varrho_{13}\sigma_2\sigma_3\varrho_{23}}{\sigma_2\sigma_3\sqrt{1 - \varrho_{23}^2}\sigma_1\sigma_3\sqrt{1 - \varrho_{13}^2}} = \\ &= \frac{\varrho_{12} - \varrho_{13}\varrho_{23}}{\sqrt{1 - \varrho_{23}^2}\sqrt{1 - \varrho_{13}^2}} \end{aligned}$$

ПРИМЕР

j	Годы	Продолж-ть жизни ξ_1	Нац.богатство (млрд.дол.) ξ_2	Водка (бут.в год) ξ_3
1	1970	68.9	2372*	25.3
2	1975	68.1	2372*	28
3	1980	67.6	2489	30
4	1985	69.2	3379	23.5
5	1990	69.2	4130	18
6	1995	64.6	1171	38.4
7	1998	67	689	29.6

$$\rho_{12} = 0.78, \rho_{13} = -0.93, \rho_{23} = -0.82. \sigma_{1.23}^2 = \frac{\Lambda}{\Lambda_{11}} = 0.29.$$

$$\beta_{12} = -\frac{\Lambda_{12}}{\Lambda_{11}} = -\frac{-368}{13214148} = 2.8 \cdot 10^{-5}, \quad \rho_{12.3} = -\frac{\Lambda_{12}}{\sqrt{\Lambda_{11}\Lambda_{22}}} = 0.032,$$

$$\beta_{13} = -\frac{\Lambda_{13}}{\Lambda_{11}} = -\frac{138823}{13214148} = -0.24, \quad \rho_{13.2} = -\frac{\Lambda_{13}}{\sqrt{\Lambda_{11}\Lambda_{33}}} = -0.82,$$

Корреляция $\rho_{12} = 0.78$ объясняется тем, что при снижении национального богатства увеличивается продажа водки, что влечет снижение продолжительности жизни.

Множественный коэффициент корреляции

Множественным коэффициентом корреляции $\varrho_{1(23\dots n)}$ называется коэффициент корреляции между ξ_1 и $\xi_1^* = \beta_{12}\xi_2 + \dots + \beta_{1n}\xi_n = \xi_1 - \eta_{1\cdot 23\dots n}$. При $E\xi_i = 0$

$$\varrho_{1(23\dots n)} = \frac{E(\xi_1 \xi_1^*)}{\sqrt{E\xi_1^2 E(\xi_1^*)^2}}, \quad (16)$$

$$E(\xi_1 \xi_1^*) = E(\xi_1 (\xi_1 - \eta_{1\cdot 23\dots n})) = E\xi_1^2 - E\xi_1 \eta_{1\cdot 23\dots n} = \lambda_{11} - \frac{\Lambda}{\Lambda_{11}},$$
$$E(\xi_1^*)^2 = E(\xi_1^2 - 2\xi_1 \eta_{1\cdot 23\dots n} + \eta_{1\cdot 23\dots n}^2) = \lambda_{11} - \frac{\Lambda}{\Lambda_{11}}.$$

Следовательно,

$$\varrho_{1(23\dots n)} = \frac{\sqrt{\lambda_{11} - \frac{\Lambda}{\Lambda_{11}}}}{\sqrt{\lambda_{11}}} = \sqrt{1 - \frac{\Lambda}{\Lambda_{11} \lambda_{11}}}. \quad (17)$$

Для численных вычислений оказывается полезной формула

$$\rho_{1(23\dots n)}^2 = 1 - \frac{\sigma_{1 \cdot 23\dots n}^2}{\sigma_1^2} = \frac{\sigma_1^2 - \sigma_{1 \cdot 23\dots n}^2}{\sigma_1^2}, \quad (18)$$

так как по (11) $\sigma_{1 \cdot 23\dots n}^2 = \frac{\Lambda}{\Lambda_{11}}$, а $\lambda_{11} = \sigma_1^2$.

Квадрат множественного коэффициента корреляции или коэффициент детерминации равен доле дисперсии, объясняемой регрессией, то есть влиянием случайных величин ξ_2, \dots, ξ_n на ξ_1 .

ПРИМЕР (продолжение). Коэффициент детерминации равен

$$R^2 = \rho_{1(23)}^2 = \frac{\sigma_1^2 - \sigma_{1 \cdot 23}^2}{\sigma_1^2} = \frac{2.31 - 0.29}{2.31} = 0.87.$$

Отношение дисперсий и частный коэффициент корреляции

$$\frac{\beta_{12}^2 \sigma_{2 \cdot 34 \dots n}^2}{\sigma_{1 \cdot 234 \dots n}^2} = \frac{\varrho_{12 \cdot 34 \dots n}^2}{1 - \varrho_{12 \cdot 34 \dots n}^2} \quad (19)$$

Равенство Якоби: $\Lambda \cdot \Lambda_{11 \cdot 22} = \Lambda_{11} \cdot \Lambda_{22} - \Lambda_{12} \cdot \Lambda_{21}$

$$\beta_{12} = \frac{\Lambda_{12}}{\Lambda_{11}}, \quad \sigma_{1 \cdot 23 \dots n}^2 = \frac{\Lambda}{\Lambda_{11}}, \quad \sigma_{2 \cdot 34 \dots n}^2 = \frac{\Lambda_{11}}{\Lambda_{11 \cdot 22}}, \quad \varrho_{12 \cdot 34 \dots n}^2 = \frac{\Lambda_{12}^2}{\Lambda_{11} \Lambda_{22}}.$$

получаем левую часть в виде:

$$\frac{\beta_{12}^2 \sigma_{2 \cdot 34 \dots n}^2}{\sigma_{1 \cdot 234 \dots n}^2} = \frac{\Lambda_{12}^2}{\Lambda_{11}^2} \cdot \frac{\Lambda_{11}}{\Lambda_{11 \cdot 22}} \cdot \frac{\Lambda_{11}}{\Lambda} = \frac{\Lambda_{12}^2}{\Lambda \cdot \Lambda_{11 \cdot 22}} = \frac{\Lambda_{12}^2}{\Lambda_{11} \cdot \Lambda_{22} - \Lambda_{12} \cdot \Lambda_{21}}.$$

Правая часть совпадает с левой, так как

$$\frac{\varrho_{12 \cdot 34 \dots n}^2}{1 - \varrho_{12 \cdot 34 \dots n}^2} = \frac{\Lambda_{12}^2}{\Lambda_{11} \Lambda_{22} \left(1 - \frac{\Lambda_{12}^2}{\Lambda_{11} \Lambda_{22}}\right)}.$$

Равенство Якоби получается из произведения определителей $(\Lambda_{11}\Lambda_{22} - \Lambda_{12}\Lambda_{21})|\Lambda| = |\Lambda|^2\Lambda_{11,22}$ соответствующих матриц

$$\left[\begin{array}{cc|ccc} \Lambda_{11} & \Lambda_{12} & \Lambda_{13} & \dots & \Lambda_{1n} \\ \Lambda_{21} & \Lambda_{22} & \Lambda_{23} & \dots & \Lambda_{2n} \\ \hline & \textcircled{0} & & & \textcircled{\text{II}} \end{array} \right] \begin{bmatrix} \lambda_{11} & \lambda_{12} & \dots & \lambda_{1n} \\ \lambda_{21} & \lambda_{22} & \dots & \lambda_{2n} \\ \dots & \dots & \dots & \dots \\ \lambda_{n1} & \lambda_{n2} & \dots & \lambda_{nn} \end{bmatrix} =$$

$$= \begin{bmatrix} |\Lambda| & 0 & 0 & \dots & 0 \\ 0 & |\Lambda| & 0 & \dots & 0 \\ \lambda_{31} & \lambda_{32} & \lambda_{33} & \dots & \lambda_{3n} \\ \dots & \dots & \dots & \dots & \dots \\ \lambda_{n1} & \lambda_{n2} & \lambda_{3n} & \dots & \lambda_{nn} \end{bmatrix}$$

Функции в R:

LM <- lm(suicide ~ vodka + auto + manager, life)

	suicide	vodka	auto	manager
1	58027	25.30	5.50	1060
2	58027	28.00	15.30	1101
3	48195	30.00	30.20	1147
4	44562	23.50	44.50	1204
5	39150	18.00	58.60	1602
6	60953	38.40	93.30	1893
7	97276	29.60	122.00	2777

summary(LM)

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	-43103.03	20327.72	-2.12	0.12
vodka	1195.65	516.44	2.32	0.10
auto	-787.56	246.07	-3.20	0.05
manager	71.25	16.14	4.41	0.02

Multiple R-squared: 0.9269, Adjusted R-squared: 0.8539 F-statistic: 12.69
on 3 and 3 DF, p-value: 0.03278

Задача предсказания переменной зависимой y с помощью p независимых переменных x_1, \dots, x_p

y	x_1	\dots	x_p
y_1	x_{11}	\dots	x_{p1}
y_2	x_{12}	\dots	x_{p2}
\vdots	\vdots	\dots	\vdots
y_n	x_{1n}	\dots	x_{pn}

$$y = f(x_1, \dots, x_p; \beta_1, \dots, \beta_m) + e,$$

где β_1, \dots, β_m – неизвестные параметры, e – ошибка аппроксимации. В частности, если $m = p + 1$

$$f(x_1, \dots, x_p; \beta_1, \dots, \beta_m) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p, \quad (20)$$

то мы имеем модель множественной линейной регрессии.

К линейной модели сводятся многие другие варианты моделей, если независимые переменные являются функциями, например, $y = \beta_0 + \beta_1 \sin z_1 + \beta_2 \sin z_2 + e$ является моделью множественной линейной регрессии с $x_i = \sin z_i$, или $x_i = x^i$, в этом случае к модели множественной линейной регрессии сводится полиномиальная модель.

Переменные x_1, \dots, x_p считаются детерминированными.

$$y_i = \alpha + \beta_1(x_{1i} - \bar{x}_1) + \dots + \beta_p(x_{pi} - \bar{x}_p) + \delta_i, \quad i = 1, \dots, n, \quad (21)$$

независимые $\delta_i \sim \mathcal{N}(0, \sigma)$. Минимизирующие

$$S = \sum_{i=1}^n (y_i - \alpha - \beta_1(x_{1i} - \bar{x}_1) - \dots - \beta_p(x_{pi} - \bar{x}_p))^2, \quad (22)$$

$\hat{\alpha}, \hat{\beta}_1, \dots, \hat{\beta}_p$, называются частными коэффициентами регрессии. Модель (21) сводится к (20) выражением $\beta_0 = \alpha - \beta_1\bar{x}_1 - \dots - \beta_p\bar{x}_p$.

Обозначим через

$$l_{ij} = \frac{1}{n} \sum_{\nu=1}^n (x_{i\nu} - \bar{x}_i)(x_{j\nu} - \bar{x}_j), \quad (23)$$

$$l_{0j} = \frac{1}{n} \sum_{\nu=1}^n (y_{\nu} - \bar{y})(x_{j\nu} - \bar{x}_j) \quad (24)$$

оценки вторых центральных моментов, а через L и L_{ij} будем обозначать определитель матрицы вторых выборочных центральных моментов

$$\begin{bmatrix} l_{11} & \dots & l_{1p} \\ \dots & \dots & \dots \\ l_{p1} & \dots & l_{pp} \end{bmatrix}$$

и его алгебраические дополнения. Будем предполагать, что $L \neq 0$.

По методу наименьших квадратов оценки параметров имеют вид

$$\hat{\alpha} = \bar{y}, \quad \hat{\beta}_i = \frac{1}{L} \sum_{j=1}^p l_{0j} L_{ij}, \quad (25)$$

а оценкой максимального правдоподобия дисперсии является выражение:

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{\nu=1}^n (y_{\nu} - \hat{y}_{\nu})^2, \quad (26)$$

где через $\hat{y}_{\nu} = \hat{\alpha} - \hat{\beta}_1(x_{1\nu} - \bar{x}_1) - \dots - \hat{\beta}_p(x_{p\nu} - \bar{x}_p)$ обозначено наилучшее линейное предсказание переменной y .

- 1 $E\hat{\alpha} = \alpha$. Покажем, что

$$\hat{\alpha} = \alpha + \bar{\delta}, \quad (27)$$

В самом деле,

$$\hat{\alpha} = \bar{y} = \frac{1}{n} \sum_{\nu=1}^n \left(\alpha + \sum_{i=1}^p \beta_i (x_{i\nu} - \bar{x}_i) + \delta_{\nu} \right) = \alpha + \bar{\delta},$$
$$E\hat{\alpha} = E(\alpha + \bar{\delta}) = \alpha$$

- 2 $E(\hat{\alpha} - \alpha)^2 = \frac{\sigma^2}{n}$ (очевидно).

$$E\hat{\beta}_i = \beta_i$$

Покажем, что из $y_\nu = \alpha + \sum_{k=1}^P \beta_k(x_{k\nu} - \bar{x}_k) + \delta_\nu$ и $\bar{y} = \alpha + \bar{\delta}$

$$y_\nu - \bar{y} = \sum_{k=1}^P \beta_k(x_{k\nu} - \bar{x}_k) + \delta_\nu - \bar{\delta}.$$

$$\begin{aligned} E\hat{\beta}_i &= E \frac{1}{L} \sum_{j=1}^P l_{0j} L_{ij} = E \frac{1}{L} \sum_{j=1}^P L_{ij} \frac{1}{n} \sum_{\nu=1}^n (y_\nu - \bar{y})(x_{j\nu} - \bar{x}_j) = \\ &= E \frac{1}{L} \sum_{j=1}^P L_{ij} \frac{1}{n} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j) \left(\sum_{k=1}^P \beta_k(x_{k\nu} - \bar{x}_k) + \delta_\nu - \bar{\delta} \right) = \\ &= \frac{1}{L} \sum_{j=1}^P L_{ij} \sum_{k=1}^P \beta_k \frac{1}{n} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j)(x_{k\nu} - \bar{x}_k) = \\ &= \frac{1}{L} \sum_{j=1}^P L_{ij} \sum_{k=1}^P \beta_k l_{kj} = \frac{1}{L} \sum_{k=1}^P \beta_k \sum_{j=1}^P L_{ij} l_{kj} = \beta_i, \end{aligned}$$

$$\text{так как } \sum_{j=1}^P L_{ij} l_{kj} = \begin{cases} 0, & k \neq i, \\ L, & k = i \end{cases}$$

$$E(\hat{\alpha} - \alpha)(\hat{\beta}_i - \beta_i) = 0.$$

С одной стороны, $\hat{\alpha} - \alpha = \bar{\delta}$, с другой, $y_\nu - \bar{y} - E(y_\nu - \bar{y}) = \delta_\nu - \bar{\delta}$,

$$\begin{aligned} l_{0j} - El_{0j} &= \frac{1}{n} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j)(y_\nu - \bar{y} - E(y_\nu - \bar{y})) = \\ &= \frac{1}{n} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j)(\delta_\nu - \bar{\delta}) = \frac{1}{n} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j)\delta_\nu. \end{aligned}$$

Таким образом,

$$\hat{\beta}_i - \beta_i = \frac{1}{L} \sum_{j=1}^P L_{ij}(l_{0j} - El_{0j}) = \frac{1}{L} \sum_{j=1}^P L_{ij} \frac{1}{n} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j)\delta_\nu, \quad (28)$$

следовательно,

$$\begin{aligned} E(\hat{\alpha} - \alpha)(\hat{\beta}_i - \beta_i) &= \frac{1}{Ln} \sum_{j=1}^P L_{ij} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j)E(\bar{\delta}\delta_\nu) = \\ &= \frac{\sigma^2}{Ln^2} \sum_{j=1}^P L_{ij} \sum_{\nu=1}^n (x_{j\nu} - \bar{x}_j) = 0. \end{aligned}$$

$$E(\hat{\beta}_1 - \beta_1)(\hat{\beta}_2 - \beta_2) = \frac{\sigma^2 L_{12}}{nL}.$$

Действительно,

$$\begin{aligned} E \frac{1}{L} \sum_{j=1}^p L_{1j} \frac{1}{n} \sum_{\mu=1}^n (x_{j\mu} - \bar{x}_j) \delta_{\mu} &\cdot \frac{1}{L} \sum_{i=1}^p L_{2i} \frac{1}{n} \sum_{\nu=1}^n (x_{i\nu} - \bar{x}_i) \delta_{\nu} = \\ &= \frac{\sigma^2}{n^2 L^2} \sum_{\mu=1}^n \sum_{j=1}^p L_{1j} (x_{j\mu} - \bar{x}_j) \sum_{i=1}^p L_{2i} (x_{i\mu} - \bar{x}_i) = \\ &= \frac{\sigma^2}{n^2 L^2} \sum_{j=1}^p L_{1j} \sum_{i=1}^p L_{2i} \sum_{\mu=1}^n (x_{j\mu} - \bar{x}_j)(x_{i\mu} - \bar{x}_i) = \\ &= \frac{\sigma^2}{n^2 L^2} \sum_{j=1}^p L_{1j} \sum_{i=1}^p L_{2i} n l_{ij} = \frac{\sigma^2 L_{12}}{nL}. \end{aligned}$$

В частности,

$$D(\hat{\beta}_1) = \frac{\sigma^2 L_{11}}{nL} = \frac{\sigma^2}{ns_{1 \cdot 234 \dots p}^2}. \quad (29)$$

Разложение суммы квадратов ошибок

$$\begin{aligned}\sum_{\mu=1}^n \delta_{\mu}^2 &= \sum_{\mu=1}^n \left(y_{\mu} - \alpha - \sum_{k=1}^p \beta_k (x_{k\mu} - \bar{x}_k) \right)^2 = \\ &= \sum_{\mu=1}^n \left(y_{\mu} - \alpha - \sum_{k=1}^p \beta_k (x_{k\mu} - \bar{x}_k) + \right. \\ &+ \hat{\alpha} - \hat{\alpha} + \sum_{k=1}^p \hat{\beta}_k (x_{k\mu} - \bar{x}_k) - \sum_{k=1}^p \hat{\beta}_k (x_{k\mu} - \bar{x}_k) \left. \right)^2 = \\ &= \sum_{\mu=1}^n \left((y_{\mu} - \hat{\alpha} - \sum_{k=1}^p \hat{\beta}_k (x_{k\mu} - \bar{x}_k)) + \right. \\ &+ (\hat{\alpha} - \alpha) + \sum_{k=1}^p (\hat{\beta}_k - \beta_k) (x_{k\mu} - \bar{x}_k) \left. \right)^2 = \\ &= n\hat{\sigma}^2 + n(\hat{\alpha} - \alpha)^2 + n \sum_{k=1}^p \sum_{t=1}^p l_{kt} (\hat{\beta}_k - \beta_k) (\hat{\beta}_t - \beta_t). \quad (30)\end{aligned}$$

$$\begin{aligned} & \sum_{\mu=1}^n \left(\sum_{k=1}^p (\hat{\beta}_k - \beta_k)(x_{k\mu} - \bar{x}_k) \right)^2 = \\ = & \sum_{\mu=1}^n \left(\sum_{k=1}^p (\hat{\beta}_k - \beta_k)(x_{k\mu} - \bar{x}_k) \right) \left(\sum_{t=1}^p (\hat{\beta}_t - \beta_t)(x_{t\mu} - \bar{x}_t) \right) = \\ = & \sum_{k=1}^p \sum_{t=1}^p (\hat{\beta}_k - \beta_k)(\hat{\beta}_t - \beta_t) \sum_{\mu=1}^n (x_{k\mu} - \bar{x}_k)(x_{t\mu} - \bar{x}_t) = \\ = & \sum_{k=1}^p \sum_{t=1}^p (\hat{\beta}_k - \beta_k)(\hat{\beta}_t - \beta_t) n l_{kt} \end{aligned}$$

Перекрестные суммы равны нулю

$$\begin{aligned} & \sum_{\mu=1}^n \left(y_{\mu} - \hat{\alpha} - \sum_{k=1}^p \hat{\beta}_k (x_{k\mu} - \bar{x}_k) \right) \left(\sum_{t=1}^p (\hat{\beta}_t - \beta_t) (x_{t\mu} - \bar{x}_t) \right) = \\ & = \sum_{t=1}^p (\hat{\beta}_t - \beta_t) \left(\sum_{\mu=1}^n (y_{\mu} - \bar{y})(x_{t\mu} - \bar{x}_t) - \sum_{k=1}^p \hat{\beta}_k \sum_{\mu=1}^n (x_{k\mu} - \bar{x}_k)(x_{t\mu} - \bar{x}_t) \right) \end{aligned}$$

$$\sum_{t=1}^p (\hat{\beta}_t - \beta_t) n \left(l_{0t} - \sum_{k=1}^p \hat{\beta}_k l_{kt} \right) = 0, \text{ так как}$$

$$\sum_{k=1}^p \hat{\beta}_k l_{kt} = \sum_{k=1}^p l_{kt} \frac{1}{L} \sum_{j=1}^p L_{kj} l_{0j} = \frac{1}{L} \sum_{j=1}^p l_{0j} \sum_{k=1}^p l_{kt} L_{kj} = l_{0t}.$$

$$\sum_{\mu=1}^n \left(\sum_{t=1}^p (\hat{\beta}_t - \beta_t)(x_{t\mu} - \bar{x}_t) \right) (\hat{\alpha} - \alpha) = 0,$$

$$\begin{aligned} & \sum_{\mu=1}^n \left(y_{\mu} - \hat{\alpha} - \sum_{k=1}^p \hat{\beta}_k (x_{k\mu} - \bar{x}_k) \right) (\hat{\alpha} - \alpha) = \\ & = (\hat{\alpha} - \alpha) \left(n\bar{y} - n\hat{\alpha} - \sum_{k=1}^p \hat{\beta}_k \sum_{\mu=1}^n (x_{k\mu} - \bar{x}_k) \right) = 0, \end{aligned}$$

Распределения частных коэффициентов регрессии: Соотношения ортогональности для статистик

Оценкой σ^2 является выборочное значение остаточной дисперсии величины y относительно x_1, \dots, x_p

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{\nu=1}^n \left(y_{\nu} - \hat{\alpha} - \sum_{k=1}^p \hat{\beta}_k (x_{k\nu} - \bar{x}_k) \right)^2 = s_{0.12\dots p}^2. \quad (31)$$

Покажем, что $\hat{\sigma}^2$ независима от $\hat{\alpha}$ и $\hat{\beta}_i$, и что $\frac{n\hat{\sigma}^2}{\sigma^2}$ имеет распределение хи-квадрат с $n - p - 1$ степенями свободы.

Случай диагональной матрицы вторых моментов L.

$$l_{ij} = 0, \quad L_{ij} = 0 \quad \text{при } i \neq j. \quad (32)$$

т.е. $s_i^2 = l_{ii} = \frac{L}{Ln}$, $D(\beta_i) = \frac{\sigma^2}{ns_i^2}$. Выражения $\sqrt{n}(\hat{\alpha} - \alpha)$ и $s_i\sqrt{n}(\hat{\beta}_i - \beta_i)$ есть линейные комбинации от δ_ν . Действительно, согласно (27) и (28),

$$\begin{aligned} \sqrt{n}(\hat{\alpha} - \alpha) &= \frac{1}{\sqrt{n}} \sum_{\nu=1}^n \delta_\nu \text{ и} \\ s_i\sqrt{n}(\hat{\beta}_i - \beta_i) &= s_i\sqrt{n} \left(\frac{1}{L} \sum_{j=1}^p L_{ij} \frac{1}{n} \sum_{\mu=1}^n (x_{j\mu} - \bar{x}_j) \delta_\mu \right) = \\ &= s_i\sqrt{n} \left(\frac{L_{ii}}{Ln} \sum_{\mu=1}^n (x_{i\mu} - \bar{x}_i) \delta_\mu \right) = \frac{1}{s_i\sqrt{n}} \sum_{\mu=1}^n (x_{i\mu} - \bar{x}_i) \delta_\mu \end{aligned}$$

Эти линейные комбинации от δ_ν удовлетворяют условиям ортогональности:

$$\sum_{\mu=1}^n \left(\frac{1}{\sqrt{n}} \right)^2 = 1,$$
$$\sum_{\mu=1}^n \left(\frac{x_{i\mu} - \bar{x}_i}{s_i \sqrt{n}} \right)^2 = 1,$$
$$\sum_{\mu=1}^n \left(\frac{x_{i\mu} - \bar{x}_i}{s_i \sqrt{n} \sqrt{n}} \right) = 0.$$

$$\sum_{\mu=1}^n \delta_{\mu}^2 = n\hat{\sigma}^2 + n(\hat{\alpha} - \alpha)^2 + n \sum_{k=1}^p \sum_{t=1}^p l_{kt}(\hat{\beta}_k - \beta_k)(\hat{\beta}_t - \beta_t)$$

В случае диагональной матрицы вторых моментов (32)

$$n \sum_{k=1}^p \sum_{t=1}^p l_{kt}(\hat{\beta}_k - \beta_k)(\hat{\beta}_t - \beta_t) = \sum_{k=1}^p ns_k^2(\hat{\beta}_k - \beta_k)^2, \text{ поэтому}$$

$$\sum_{\mu=1}^n \delta_{\mu}^2 = n\hat{\sigma}^2 + n(\hat{\alpha} - \alpha)^2 + \sum_{k=1}^p ns_k^2(\hat{\beta}_k - \beta_k)^2$$

C ортогональная матрица со специальными $p + 1$ строками

$$C = \begin{bmatrix} \frac{1}{\sqrt{n}} & \cdots & \frac{1}{\sqrt{n}} \\ \frac{x_{11} - \bar{x}_1}{s_1 \sqrt{n}} & \cdots & \frac{x_{1n} - \bar{x}_1}{s_1 \sqrt{n}} \\ \vdots & \cdots & \vdots \\ \frac{x_{p1} - \bar{x}_p}{s_p \sqrt{n}} & \cdots & \frac{x_{pn} - \bar{x}_p}{s_p \sqrt{n}} \\ \vdots & \cdots & \vdots \end{bmatrix}$$

Рассмотрим вектор $\eta = (\eta_1, \dots, \eta_n)^T$, который получен из $\eta = C\delta$, где $\delta = (\delta_1, \dots, \delta_n)^T$, очевидно,
 $\eta_1 = \sqrt{n}(\hat{\alpha} - \alpha)$, $\eta_k = \sqrt{n}s_k(\hat{\beta}_k - \beta_k)$, $k = 2, \dots, p + 1$.

$$\sum_{j=1}^n \eta_j^2 = \eta^T \eta = (C\delta)^T C\delta = \delta^T C^T C\delta = \delta^T \delta = \sum_{j=1}^n \delta_j^2,$$

$$\frac{n\hat{\sigma}^2}{\sigma^2} = \frac{1}{\sigma^2} \left(\sum_{j=1}^n \delta_j^2 - \eta_1^2 - \sum_{k=2}^{p+1} \eta_k^2 \right) \sim \chi^2(n - p - 1).$$

В общем случае, когда матрица вторых моментов не является диагональной, величины x_i следует при помощи ортогонального преобразования заменить на величины x'_i , для которых матрица вторых моментов будет диагональной. К параметрам β_i следует применить контргradientное преобразование. Т.е. если $Y = A + B^T(X - \bar{X})$ и $(X - \bar{X}) = CZ$, где Z – вектор с некоррелированными компонентами, то $Y = A + B^T CZ = A + (C^T B)^T Z$ и $B_1 = C^T B$, $B = CB_1$.

Отсюда следует, что величины

$$t_0 = \frac{(\hat{\alpha} - \alpha)\sqrt{n}}{\sigma\sqrt{\frac{1}{n-p-1}\frac{n\hat{\sigma}^2}{\sigma^2}}} = \frac{\hat{\alpha} - \alpha}{s_{0.12\dots p}}\sqrt{n-p-1},$$
$$t_1 = \frac{(\hat{\beta}_1 - \beta_1)\sqrt{n}s_{1.23\dots p}}{\sigma\sqrt{\frac{1}{n-p-1}\frac{n\hat{\sigma}^2}{\sigma^2}}} = \frac{(\hat{\beta}_1 - \beta_1)s_{1.23\dots p}}{s_{0.12\dots p}}\sqrt{n-p-1}, \quad (33)$$

и аналогичные величины с β_2, \dots, β_p имеют распределение Стьюдента с $n - p - 1$ степенями свободы.

Значимость частных коэффициентов корреляции

Гипотеза $H_0 : \beta_1 = 0$ может быть использована для проверки равенства нулю частного коэффициента корреляции, но вместо статистики (33), согласно (19) используется эквивалентная ей статистика вида

$$\frac{\hat{\varrho}_{01 \cdot 234 \dots p}}{\sqrt{1 - \varrho_{01 \cdot 234 \dots p}^2}} \sqrt{n - p - 1} \sim T(n - p - 1). \quad (34)$$

Обозначим через $Q_2 = \sum_{\nu=1}^n \left(y_{\nu} - \hat{\alpha} - \sum_{k=1}^p \hat{\beta}_k (x_{k\nu} - \bar{x}_k) \right)^2$. Если использовать несмещенную оценку дисперсии $S^2 = \frac{1}{n-p-1} Q_2$, то

$$t_0 = \frac{\hat{\alpha} - \alpha}{S} \sqrt{n},$$
$$t_1 = \frac{(\hat{\beta}_1 - \beta_1) s_{1 \cdot 23 \dots p}}{S} \sqrt{n} = \frac{(\hat{\beta}_1 - \beta_1)}{\hat{\sigma}_{\beta_1}}.$$

Выражение $\frac{S}{\sqrt{ns_{1 \cdot 2, 3, \dots, p}}}$ соответствует оценке стандартного отклонения σ_{β_1} оценки $\hat{\beta}_1$ из (29). Поэтому при вычислениях используются дисперсии оценок частных коэффициентов регрессии, на корни из которых делятся оценки параметров для получения нужных статистик Стьюдента.

Проверка значимости прогноза

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_p = 0$$

Убедимся в том, что $\frac{n}{\sigma^2} \sum_{k=1}^p \sum_{t=1}^p l_{kt} (\hat{\beta}_k - \beta_k)(\hat{\beta}_t - \beta_t)$ имеет распределение хи-квадрат с p степенями свободы. При диагональной матрице вторых моментов (32) это очевидно,

$$n \sum_{k=1}^p \sum_{t=1}^p l_{kt} (\hat{\beta}_k - \beta_k)(\hat{\beta}_t - \beta_t) = \sum_{k=1}^p n s_k^2 (\hat{\beta}_k - \beta_k)^2,$$

где $\sqrt{n} s_k (\hat{\beta}_k - \beta_k) \sim \mathcal{N}(0, \sigma)$.

В общем случае используем утверждение о том, что для любого нормального вектора Z с нулевым средним и ковариационной матрицей $\Sigma = EZZ^T$ справедливо $Z^T \Sigma^{-1} Z \sim \chi^2(p)$.

Пусть $Y = BZ$ вектор с независимыми компонентами, так что $Y^T Y \sim \chi^2(p)$. С другой стороны,

$$Y^T Y = Z^T (B^T B) Z \sim \chi^2(p),$$

а ковариационная матрица вектора Z с коррелируемыми компонентами имеет тот же вид

$$\Sigma = EZZ^T = EB^{-1}YY^T(B^{-1})^T = B^{-1}(B^{-1})^T = (B^T B)^{-1}.$$

Поскольку ковариационная матрица вектора параметров имеет вид:

$$\text{cov}(\beta) = \left\{ \frac{\sigma^2 L_{ij}}{nL} \right\}_{i,j=1}^p = \frac{\sigma^2}{n} L^{-1}, \quad \text{то}$$

$$\begin{aligned} (\hat{\beta} - \beta)^T \left(\frac{\sigma^2}{n} L^{-1} \right)^{-1} (\hat{\beta} - \beta) &= \frac{n}{\sigma^2} (\hat{\beta} - \beta)^T L (\hat{\beta} - \beta) = \\ &= \frac{n}{\sigma^2} \sum_{k=1}^p \sum_{t=1}^p l_{kt} (\hat{\beta}_k - \beta_k) (\hat{\beta}_t - \beta_t) \sim \chi^2(p). \end{aligned}$$

Следовательно, статистика

$$F = \frac{n - p - 1}{p} \cdot \frac{\sum_{k=1}^p \sum_{t=1}^p l_{kt} (\hat{\beta}_k - \beta_k) (\hat{\beta}_t - \beta_t)}{s_{0.12\dots p}^2} \sim F(p, n - p - 1). \quad (35)$$

Статистику F можно выразить через множественный коэффициент корреляции. Для этого, используя то, что при $\beta_1 = \dots = \beta_p = 0$

выражение $l_{00} = \frac{1}{n} \sum_{\nu=1}^n (y_\nu - \bar{y})^2$ за счет

$y_\nu - \bar{y} = \alpha + \sum_{k=1}^p \beta_k (x_{k\nu} - \bar{x}_k) + \delta_\nu - \alpha - \bar{\delta}$ превращается в

$$l_{00} = \frac{1}{n} \sum_{\nu=1}^n (\delta_\nu - \bar{\delta})^2 = \frac{1}{n} \sum_{\nu=1}^n \delta_\nu^2 - \bar{\delta}^2, \text{ из (30) получаем}$$

$$\sum_{k=1}^p \sum_{t=1}^p l_{kt} \hat{\beta}_k \hat{\beta}_t = \frac{1}{n} \sum_{\nu=1}^n \delta_\nu^2 - \hat{\sigma}^2 - (\hat{\alpha} - \alpha)^2 =$$

$$= l_{00} - \hat{\sigma}^2 = l_{00} \left(1 - \frac{s_{0 \cdot 12 \dots p}^2}{l_{00}} \right) = l_{00} r_{0(12 \dots p)}^2.$$

А так как $s_{0 \cdot 12 \dots p}^2 = l_{00}(1 - r_{0(12 \dots p)}^2)$, то статистику (35) представим в виде:

$$F = \frac{n - p - 1}{p} \cdot \frac{r_{0(12 \dots p)}^2}{1 - r_{0(12 \dots p)}^2} \sim F(p, n - p - 1). \quad (36)$$

Таблица анализа дисперсий

Пусть $\hat{Y} = Xb$ вектор наилучшего в среднеквадратичном смысле линейного предсказания переменной Y по переменным X_1, \dots, X_p .

Источник дисперсии	Сумма квадратов	степени свободы	средний квадрат
Регрессия	$SS_R = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$	$\nu_R = p$	$MS_R = SS_R/\nu_R$
Откл.от регр.	$SS_E = \sum_{i=1}^n (y_i - \hat{y}_i)^2$	$\nu_E = n - p - 1$	$MS_E = SS_E/\nu_E$
полная	$SS_T = \sum_{i=1}^n (y_i - \bar{y})^2$	$\nu_T = n - 1$	$MS_T = SS_T/\nu_T$

Оценка коэффициента детерминации $R^2 = \frac{SS_R}{SS_T}$

При справедливости нулевой гипотезы о равенстве нулю всех частных коэффициентов регрессии статистика $F = \frac{MS_R}{MS_E}$ имеет распределение Фишера с p и $n - p - 1$ степенями свободы.

Задача регрессии в матричном виде

Уравнения линейной регрессии представим в виде $Y = X\beta + e$, где зависимая переменная задается вектором $Y = (y_1, \dots, y_n)^T$, матрица

$$X = \begin{bmatrix} 1 & x_{11} & \dots & x_{p1} \\ 1 & x_{12} & \dots & x_{p2} \\ & & \dots & \\ 1 & x_{1n} & \dots & x_{pn} \end{bmatrix} \quad (37)$$

называется матрицей плана, $\beta = (\beta_0, \dots, \beta_p)^T$ – вектор параметров, e – нормально распределенный вектор с нулевым средним и ковариационной матрицей вида $\sigma^2 I$.

Дифференцирование по вектору параметров

$$A\beta = \begin{bmatrix} a_{11} & \dots & a_{1m} \\ \dots & \dots & \dots \\ a_{n1} & \dots & a_{nm} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \dots \\ \beta_m \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^m a_{1i}\beta_i \\ \dots \\ \sum_{i=1}^m a_{ni}\beta_i \end{bmatrix}$$

$$\frac{\partial A\beta}{\partial \beta} = \begin{bmatrix} \frac{\partial A\beta}{\partial \beta_1} & \dots & \frac{\partial A\beta}{\partial \beta_m} \end{bmatrix} = \begin{bmatrix} a_{11} & \dots & a_{1m} \\ \dots & \dots & \dots \\ a_{n1} & \dots & a_{nm} \end{bmatrix} = A$$

$$\mathcal{L}_1 = (A\beta)'(A\beta) = \left(\sum_{i=1}^m a_{1i}\beta_i \right)^2 + \dots + \left(\sum_{i=1}^m a_{ni}\beta_i \right)^2.$$

Система нормальных уравнений имеет вид

$$\begin{cases} \frac{\partial \mathcal{L}_1}{\partial \beta_1} = 2 \left(a_{11} \left(\sum_{i=1}^m a_{1i}\beta_i \right) + \dots + a_{n1} \left(\sum_{i=1}^m a_{ni}\beta_i \right) \right) = 0, \\ \dots \\ \frac{\partial \mathcal{L}_1}{\partial \beta_m} = 2 \left(a_{1m} \left(\sum_{i=1}^m a_{1i}\beta_i \right) + \dots + a_{nm} \left(\sum_{i=1}^m a_{ni}\beta_i \right) \right) = 0, \end{cases}$$

$$\frac{\partial (A\beta)'(A\beta)}{\partial \beta} = 0 \iff 2 \frac{\partial (A'\beta)}{\partial \beta} A\beta = 2A'A\beta = 0.$$

Оценки МНК с ограничением на параметры

$$\begin{aligned}\mathcal{L}_2 &= \lambda'(1, s)H'(s, m)\beta(m, 1) = \\ &= (\lambda_1, \dots, \lambda_s) \begin{bmatrix} h_{11} & \dots & h_{m1} \\ \dots & \dots & \dots \\ h_{1s} & \dots & h_{ms} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \dots \\ \beta_m \end{bmatrix} = \\ &= (\lambda_1, \dots, \lambda_s) \begin{bmatrix} \sum_{i=1}^m h_{i1}\beta_i \\ \dots \\ \sum_{i=1}^m h_{is}\beta_i \end{bmatrix} = \sum_{j=1}^s \lambda_j \left(\sum_{i=1}^m h_{ij}\beta_i \right).\end{aligned}$$

Система нормальных уравнений

$$\begin{cases} \frac{\partial \mathcal{L}_2}{\partial \beta_1} = \sum_{j=1}^s \lambda_j h_{1j} = 0, \\ \dots \\ \frac{\partial \mathcal{L}_2}{\partial \beta_m} = \sum_{j=1}^s \lambda_j h_{mj} = 0, \end{cases} \iff \iff$$
$$\iff \begin{bmatrix} h_{11} & \dots & h_{1s} \\ \dots & \dots & \dots \\ h_{m1} & \dots & h_{ms} \end{bmatrix} \begin{bmatrix} \lambda_1 \\ \dots \\ \lambda_s \end{bmatrix} = H\lambda = 0.$$

При минимизации квадратичной формы $S = (Y - X\beta)^T(Y - X\beta)$ вектор оценок $b = (b_0, \dots, b_p)^T$ является решением системы нормальных уравнений

$$(X^T X)\beta = X^T Y \quad (38)$$

Действительно, дифференцирование по вектору параметров приводит к

$$2X^T(Y - X\beta) = 0 \iff X^T Y = X^T X\beta.$$

Следовательно,

$$b = \hat{\beta} = (X^T X)^{-1} X^T Y. \quad (39)$$

$$\mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{Y}, \quad \mathbb{E} \mathbf{b} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbb{E} \mathbf{Y}$$

Ковариационная матрица оценок частных коэффициентов регрессии можно представить в виде:

$$\begin{aligned} \text{Cov}(\mathbf{b}) &= \mathbb{E}(\mathbf{b} - \mathbb{E} \mathbf{b})(\mathbf{b} - \mathbb{E} \mathbf{b})^T = \\ &= \mathbb{E}((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\mathbf{Y} - \mathbb{E} \mathbf{Y}))((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T (\mathbf{Y} - \mathbb{E} \mathbf{Y}))^T = \\ &= (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \text{Cov}(\mathbf{Y}) ((\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T)^T = \\ &= \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{X} (\mathbf{X}^T \mathbf{X})^{-1} = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}. \end{aligned}$$

$$\hat{\sigma}^2 = \frac{1}{n} (\mathbf{Y} - \mathbf{X} \hat{\boldsymbol{\beta}})^T (\mathbf{Y} - \hat{\boldsymbol{\beta}} \mathbf{X})$$

Разложение определителя матрицы блочной структуры

$$|U| = |D|(a - b^T D^{-1} c) = a|D| - \sum_i b_i \sum_k D_{ki} c_k,$$

где
$$U = \begin{bmatrix} a & b^T \\ c & D \end{bmatrix}.$$

Остаточная дисперсия через матрицу вторых моментов $\sigma_{1 \cdot 23 \dots n}^2 = \frac{\Lambda}{\Lambda_{11}}$ в предположении центрированности.

$$\begin{aligned} (Y - X\hat{\beta})^T (Y - X\hat{\beta}) &= Y^T Y - Y^T X \hat{\beta} = \\ &= Y^T Y - Y^T X (X^T X)^{-1} X^T Y = \\ &= \begin{vmatrix} Y^T Y & Y^T X \\ X^T Y & X^T X \end{vmatrix} / |X^T X| = \frac{1}{G_{11}}, \end{aligned} \tag{40}$$

где $G = S^{-1}$, $S = Z^T Z$ матрица вторых выборочных моментов с точностью до множителя n , $Z = [Y, X]$ – матрица размерности n на $p + 1$, X – матрица центрированного плана размерности n на p .

График соотношения эмпирических и теоретических квантилей

$x < -rnorm(n, mean = 1, sd = 2)$

`plot(ecdf(x))` эмпирическая функция распределения

`curve(pnorm, -3, 3)` график функции распределения $F(x)$

Q_e эмпирические и Q_t теоретические квантили для всех значений

$$a = F^{-1}\left(\frac{i-0.5}{n}\right)$$








График квантиль-квантиль $qqnorm(x)$

По вертикальной оси откладываются упорядоченные значения x_1, \dots, x_n , по горизонтальной $F^{-1}\left(\frac{i-0.5}{n}\right)$, в случае нормального распределения $qnorm((seq(n) - 0.5)/n)$.



QQ – plot при несогласованных распределениях



Примеры графиков квантиль-квантиль с теоретическими нормальными квантилями и эмпирическими квантилями равномерного и экспоненциального распределений