

Множественная регрессия

$$\hat{y} = f(x_1, x_2, \dots, x_p) \quad (1)$$

$$y = \alpha' + \beta_1' x_1 + \beta_2' x_2 + \dots + \beta_p' x_p + \varepsilon \quad (2)$$

$$y = a + b_1 x_1 + b_2 x_2 + \dots + b_p x_p + e \quad (3)$$

$$\hat{y} = a + b_1 x_1 + b_2 x_2 + \dots + b_p x_p \quad (4)$$

Матричный метод

$$X = \begin{bmatrix} 1 & x_{11} & x_{12} & \boxtimes & x_{1p} \\ 1 & x_{21} & x_{22} & \boxtimes & x_{2p} \\ \boxtimes & \boxtimes & \boxtimes & \boxtimes & \boxtimes \\ 1 & x_{n1} & x_{n2} & \boxtimes & x_{np} \end{bmatrix}$$

$$Y = [y_1, y_2, \dots, y_n]' \quad B = (X' X)^{-1} X' Y \quad (10)$$

$$B = [a, b_1, b_2, \dots, b_p]'$$

$$e = [e_1, e_2, \dots, e_n]'$$

Семья	Накопления, S	Доход, Y	Имущество, W
1	3	40	60
2	6	55	36
3	5	45	36
4	3,5	30	15
5	1,5	30	90

$$S=[3;6;5;3,5;1,5]'$$

$$B=[a;b_1;b_2]'$$

$$X = \begin{bmatrix} 1 & 40 & 60 \\ 1 & 55 & 36 \\ 1 & 45 & 36 \\ 1 & 30 & 15 \\ 1 & 30 & 90 \end{bmatrix} \quad X'X = \begin{bmatrix} 5 & 200 & 237 \\ 200 & 8450 & 9150 \\ 237 & 9150 & 14517 \end{bmatrix}; \quad (X'X)^{-1} = \begin{bmatrix} 5,6916 & -0,1074 & -0,0252 \\ -0,1074 & 0,0024 & 0,00024 \\ -0,0252 & 0,00024 & 0,00033 \end{bmatrix}$$

$$B = (X'X)^{-1} X'Y = (0,2787 \quad 0,1229 \quad -0,0294)$$

$$\hat{S} = 0,2787 + 0,1229Y - 0,0294W$$

Скалярный метод

$$\left\{ \begin{array}{l} an + b_1 \sum x_1 + b_2 \sum x_2 + \dots + b_p \sum x_p = \sum y \\ a \sum x_1 + b_1 \sum x_1^2 + b_2 \sum x_2 x_1 + \dots + b_p \sum x_p x_1 = \sum y x_1 \\ \boxtimes \quad \quad \quad \boxtimes \quad \quad \quad \boxtimes \quad \quad \quad \boxtimes \quad \quad \quad \boxtimes \\ a \sum x_p + b_1 \sum x_1 x_p + b_2 \sum x_2 x_p + \dots + b_p \sum x_p^2 = \sum y x_p \end{array} \right. \quad (11)$$

$$\left\{ \begin{array}{l} an + b_1 \sum Y + b_2 \sum W = \sum S \\ a \sum Y + b_1 \sum Y^2 + b_2 \sum WY = \sum SY \\ a \sum W + b_1 \sum YW + b_2 \sum W^2 = \sum SW \end{array} \right.$$

$$\begin{cases} 5a & + 200b_1 & + 237b_2 & = 19 \\ 200a & + 8450b_1 & + 9150b_2 & = 825 \\ 237a & + 9150b_1 & + 14517b_2 & = 863,5 \end{cases}$$

$$\Delta = 6842700; \quad \Delta_a = 1903325; \quad \Delta_{b_1} = 840825; \quad \Delta_{b_2} = -201225.$$

$$a = \Delta_a / \Delta = 1903325 / 6842700 = 0,2787;$$

$$b_1 = \Delta_{b_1} / \Delta = 840825 / 6842700 = 0,1229;$$

$$b_2 = \Delta_{b_2} / \Delta = -201205 / 6842700 = -0,0294.$$

Регрессионная модель в стандартизованном масштабе

$$t_y = \beta_1 t_{x_1} + \beta_2 t_{x_2} + \dots + \beta_p t_{x_p} + \varepsilon \quad (12)$$

$$t_y = \frac{y - \bar{y}}{\sigma_y}; \quad t_{x_j} = \frac{x_j - \bar{x}_j}{\sigma_{x_j}}, \quad j = \overline{1, p} \quad (13)$$

$$\bar{t}_y = \bar{t}_{x_1} = \bar{t}_{x_2} = \dots = \bar{t}_{x_p} = 0$$

$$\sigma_{t_y} = \sigma_{t_{x_j}} = 1, \quad j = \overline{1, p}$$

$$\left\{ \begin{array}{l} \beta_1 + \beta_2 r_{x_2 x_1} + \beta_3 r_{x_3 x_1} + \dots + \beta_p r_{x_p x_1} = r_{yx_1} \\ \beta_1 r_{x_1 x_2} + \beta_2 + \beta_3 r_{x_3 x_2} + \dots + \beta_p r_{x_p x_2} = r_{yx_2} \\ \boxtimes \quad \quad \quad \boxtimes \quad \quad \quad \boxtimes \quad \quad \quad \boxtimes \quad \quad \quad \boxtimes \\ \beta_1 r_{x_1 x_p} + \beta_2 r_{x_2 x_p} + \beta_3 r_{x_3 x_p} + \dots + \beta_p = r_{yx_p} \end{array} \right. \quad (14)$$

$$b_j = \beta_j \frac{\sigma_y}{\sigma_{x_j}} \quad (15)$$

$$\hat{t}_y = \beta_1 t_{x_1} + \beta_2 t_{x_2} + \boxtimes + \beta_p t_{x_p} \quad (16)$$

$$a = \bar{y} - b_1 \bar{x}_1 - b_2 \bar{x}_2 - \dots - b_p \bar{x}_p \quad (17)$$

$$R = \begin{bmatrix} 1 & -0,27149 & 0,873684 \\ -0,27149 & 1 & -0,68224 \end{bmatrix}$$

$$\begin{cases} \beta_1 + 0,27149\beta_2 = 0,873684, \\ -0,27149\beta_1 + \beta_2 = -0,68224 \end{cases}$$

$$\begin{aligned} \Delta &= 0,926291; & \Delta_1 &= 0,688461; & \Delta_2 &= -0,44504; \\ \beta_1 &= 0,688461/0,926291 = 0,743245; \\ \beta_2 &= -0,44504/0,926291 = -0,48045; \end{aligned}$$

$$\hat{t}_S = 0,743245t_Y - 0,48045t_W$$

$$\sigma_S = 1,75357; \quad \sigma_Y = 10,6066; \quad \sigma_W = 28,6496,$$

$$\bar{S} = 3,8; \quad \bar{Y} = 40; \quad \bar{W} = 47,4.$$

$$b_1 = \beta_1 \frac{\sigma_y}{\sigma_{x_1}} = 0,743245 \cdot \frac{1,75357}{10,6066} = 0,1229;$$

$$b_2 = \beta_2 \frac{\sigma_y}{\sigma_{x_2}} = -0,48045 \cdot \frac{1,75357}{28,6496} = -0,0294;$$

$$a = \bar{s} - b_1 \bar{Y} - b_2 \bar{W} = 3,8 - 0,1229 \cdot 40 + 0,0294 \cdot 47,4 = 0,2787.$$

Частные уравнения регрессии

$$\left\{ \begin{array}{l} y_{x_1 \cdot x_2, x_3, \dots, x_p} = f(x_1), \\ y_{x_2 \cdot x_1, x_3, \dots, x_p} = f(x_2), \\ \boxtimes \\ y_{x_p \cdot x_1, x_2, \dots, x_{p-1}} = f(x_p). \end{array} \right.$$

$$\begin{aligned}
y_{x_j \cdot x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_p} &= a + b_1 \bar{x}_1 + \dots \\
&+ b_{j-1} \bar{x}_{j-1} + b_j x_j + b_{j+1} \bar{x}_{j+1} + \dots \\
&+ b_p \bar{x}_p + e, \quad j = \overline{1, p}
\end{aligned}$$

$$\hat{y}_{x_j \cdot x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_p} = A_j + b_j x_j, \quad j = \overline{1, p}$$

$$\begin{aligned}
A_j &= a + b_1 \bar{x}_1 + \dots + b_{j-1} \bar{x}_{j-1} + \\
&+ b_{j+1} \bar{x}_{j+1} + \dots + b_p \bar{x}_p, \quad j = \overline{1, p}
\end{aligned}$$

$$\Theta_j = b_j \frac{x_j}{\hat{y}_{x_j \cdot x_1, \dots, x_{j-1}, x_{j+1}, \dots, x_p}} \quad (18)$$

$$\bar{\Theta}_j = b_j \frac{\bar{x}_j}{\bar{y}} \quad (19)$$

Анализ качества эмпирического уравнения множественной линейной регрессии

$$t_{b_j} = \frac{b_j}{m_{b_j}} \left(t_a = \frac{a}{m_a} \right) \quad (20)$$

$$H_0 : \beta'_j = 0; \quad H_1 : \beta'_j \neq 0$$

$$\left| t_{b_j} \right| < t_{табл}(\alpha; n - p - 1)$$

H_0 не отклоняется,
параметр не значим

$$\left| t_{b_j} \right| \geq t_{табл}(\alpha; n - p - 1)$$

H_0 отклоняется, параметр
значим

$$b_j - t(\alpha; n - p - 1) \cdot m_{b_j} < \beta'_j < b_j + t(\alpha; n - p - 1) \cdot m_{b_j} \quad (24)$$

$$a - t(\alpha; n - p - 1) \cdot m_a < \alpha' < a + t(\alpha; n - p - 1) \cdot m_a \quad (24')$$

$$R^2 = 1 - \frac{\sum e_i^2}{\sum (y_i - \bar{y})^2} \quad (25)$$

$$\bar{R}^2 = 1 - \frac{\sum e_i^2 / (n - p - 1)}{\sum (y_i - \bar{y})^2 / (n - 1)} \quad (26)$$

$$\begin{aligned} \bar{R}^2 &= 1 - \left(1 - R^2\right) \frac{n - 1}{n - p - 1} = \\ &= \frac{n - 1}{n - p - 1} R^2 - \frac{p}{n - p - 1} = R^2 - \frac{p}{n - p - 1} (1 - R^2) \end{aligned} \quad (27)$$

$$F = \frac{R^2}{1 - R^2} \cdot \frac{n - p - 1}{p} \quad (28)$$

$$H_0 : R^2 = 0 \quad H_1 : R^2 > 0$$

$$F < F_{\text{табл}}(\alpha; p; n - p - 1)$$

- H_0 не отклоняется, на уровне α уравнение не значимо

$$F \geq F_{\text{табл}}(\alpha; p; n - p - 1)$$

- H_0 отклоняется, на уровне α уравнение значимо

Исключение к факторов:

$$\hat{y} = c + d_1x_1 + d_2x_2 + \dots + d_{p-k}x_{p-k} \quad (30)$$

$H_0 : R_1^2 - R_2^2 = 0$ исключение оправдано

$H_1 : R_1^2 > R_2^2$ исключение не оправдано

$$F = \frac{R_1^2 - R_2^2}{1 - R_1^2} \cdot \frac{n - p - 1}{k} \quad (31) \quad F_{кр} = F(\alpha; k; n - p - 1)$$

$F < F_{кр}$ H_0 не отклоняется, исключение оправдано

$F > F_{кр}$ H_0 отклоняется, исключение не оправдано

Включение к факторов:

$H_0 : R_1^2 - R_2^2 = 0$ включение не оправдано

$H_1 : R_2^2 > R_1^2$ включение оправдано

$$F = \frac{R_2^2 - R_1^2}{1 - R_2^2} \cdot \frac{n - p - 1}{k} \quad (32) \quad F_{кр} = F(\alpha; k; n - p - 1)$$

$F < F_{кр}$ H_0 не отклоняется, включение не оправдано

$F > F_{кр}$ H_0 отклоняется, включение оправдано

Частный случай: добавление одного фактора

$$F_{x_j} = \frac{R^2_{yx_1x_2\dots x_p} - R^2_{yx_1x_2\dots x_{j-1}x_{j+1}\dots x_p}}{1 - R^2_{yx_1x_2\dots x_p}} \frac{n - p - 1}{1} \quad (50)$$

- частный F – критерий

$$F_{kp} = F_{tabl}(\alpha; 1; n - p - 1)$$

$$t_{b_j} = \sqrt{F_{x_j}} \quad (51)$$

Показатель множественной корреляции

$$R = \sqrt{1 - \frac{\sum (y - \hat{y})^2}{\sum (y - \bar{y})^2}} \quad (33)$$

$$R = \sqrt{\sum_{j=1}^p \beta_j r_{yx_j}} \quad (34)$$

Показатель частной корреляции

$$r_{yx_j \cdot x_1 x_2 \dots x_{j-1} \dots x_{j+1} \dots x_p}$$

$$r_{x_i x_j \cdot y x_1 x_2 \dots x_{i-1} \dots x_{i+1} \dots x_{j-1} \dots x_{j+1} \dots x_p}$$

$$r_{yx_j \cdot x_1 x_2 \dots x_p} = \frac{r_{yx_j \cdot x_1 x_2 \dots x_{p-1}} - r_{yx_p \cdot x_1 x_2 \dots x_{p-1}} \cdot r_{x_j x_p \cdot x_1 x_2 \dots x_{p-1}}}{\sqrt{\left(1 - r_{yx_p \cdot x_1 x_2 \dots x_{p-1}}^2\right) \left(1 - r_{x_j x_p \cdot x_1 x_2 \dots x_{p-1}}^2\right)}} \quad (46)$$

Для двухфакторной модели

$$r_{yx_1 \cdot x_2} = \frac{r_{yx_1} - r_{yx_2} \cdot r_{x_1 x_2}}{\sqrt{(1 - r_{yx_2}^2)(1 - r_{x_1 x_2}^2)}}$$

$$r_{yx_2 \cdot x_1} = \frac{r_{yx_2} - r_{yx_1} \cdot r_{x_1 x_2}}{\sqrt{(1 - r_{yx_1}^2)(1 - r_{x_1 x_2}^2)}}$$

Процедуры пошагового отбора переменных

- процедура последовательного присоединения
- процедура последовательного присоединения – удаления
- процедура последовательного удаления

Процедура «всех возможных регрессий»:

Для заданного значения k ($k=1,2,\dots,p-1$) проводится полный перебор всех возможных комбинаций из k факторов (которые отобраны из исходного набора x_1, x_2, \dots, x_p). Определяются такие переменные

$$x_{i_1}, x_{i_2}, \dots, x_{i_k}$$

для которых коэффициент детерминации с результатом был бы максимальным.

Таким образом:

- на первом шаге ($k=1$) находим **один** наиболее информативный фактор (при условии, что в модель можно включать только **один** фактор из первоначального набора)
- на втором шаге ($k=2$) определяется уже наиболее информативная **пара** факторов (из первоначального набора), имеющая наиболее тесную связь с результатом
- на третьем шаге ($k=3$) будет отображена наиболее информативная **тройка** факторов
- и т.д.

Критерий останова (завершения) процедуры:

- выбирается такое оптимальное число k_0 факторов, на котором нижняя доверительная граница коэффициента детерминации достигает своего **максимума**. Эта граница вычисляется по формуле:

$$R_{\min}^2 = \bar{R}^2(k) - 2 \sqrt{\frac{2k(n-k-1)}{(n-1)(n^2-1)}} \cdot (1 - R^2(k)),$$

Гетероскедастичность

-тест ранговой корреляции Спирмена

$$r_{x,e} = 1 - 6 \cdot \frac{\sum d_i^2}{n(n^2 - 1)} \quad (53)$$

$$H_0 : r_{x,e} = 0 \quad H_1 : r_{x,e} \neq 0 \quad t = \frac{r_{x,e} \sqrt{n-2}}{\sqrt{1-r_{x,e}^2}} \quad (54)$$

$$|t| > t_{\alpha/2; n-2}$$

H_0 отклоняется, гетероскедастичность имеет место

-тест Голдфелда-Квандта

$$\sigma_i^2 = \sigma^2 x_{ji}^2, \quad i = \overline{1, n}$$

$$s_1 = \sum_{i=1}^k e_i^2 \quad s_3 = \sum_{i=n-k+1}^n e_i^2$$

$$F_{\text{íráë}} = \frac{s_3 / (k - p - 1)}{s_1 / (k - p - 1)} = \frac{s_3}{s_1} \quad (53)$$

$$H_0 : \sigma_1^2 = \sigma_2^2 = \dots = \sigma_n^2,$$

$$F_{\text{набл}} > F_{\text{кр}} = F_{\text{табл}}(\alpha; k - p - 1; k - p - 1)$$

-метод «взвешенных наименьших квадратов»

1. Дисперсии известны

$$y_i = a + bx_i + \varepsilon_i \quad (57)$$

$$\frac{y_i}{\sigma_i} = a \frac{1}{\sigma_i} + b \frac{x_i}{\sigma_i} + \frac{\varepsilon_i}{\sigma_i} \quad (58)$$

$$y_i^* = \frac{y_i}{\sigma_i}; \quad x_i^* = \frac{x_i}{\sigma_i}; \quad z_i = \frac{1}{\sigma_i}; \quad v_i = \frac{\varepsilon_i}{\sigma_i}; \quad (59)$$

$$y_i^* = az_i + bx_i^* + v_i \quad (60)$$

2. Дисперсии неизвестны

$$\sigma_i^2 = \sigma^2 x_i \quad (61)$$

$$\frac{y_i}{\sqrt{x_i}} = \frac{a}{\sqrt{x_i}} + b \frac{x_i}{\sqrt{x_i}} + \frac{\varepsilon_i}{\sqrt{x_i}}$$

$$\frac{y_i}{\sqrt{x_i}} = a \frac{1}{\sqrt{x_i}} + b \sqrt{x_i} + v_i \quad (62)$$

$$\hat{y} = a + b_1 x_1 + b_2 x_2 + \dots + b_p x_p$$

$$\frac{y_i}{\sqrt{\hat{y}_i}} = a \frac{1}{\sqrt{\hat{y}_i}} + b_1 \frac{x_{i1}}{\sqrt{\hat{y}_i}} + \dots + b_p \frac{x_{ip}}{\sqrt{\hat{y}_i}} + \frac{\varepsilon_i}{\sqrt{\hat{y}_i}} \quad (63)$$

$$\sigma_i^2 = \sigma^2 x_i^2$$

$$\frac{y_i}{x_i} = \frac{a}{x_i} + b + \frac{\varepsilon_i}{x_i}$$

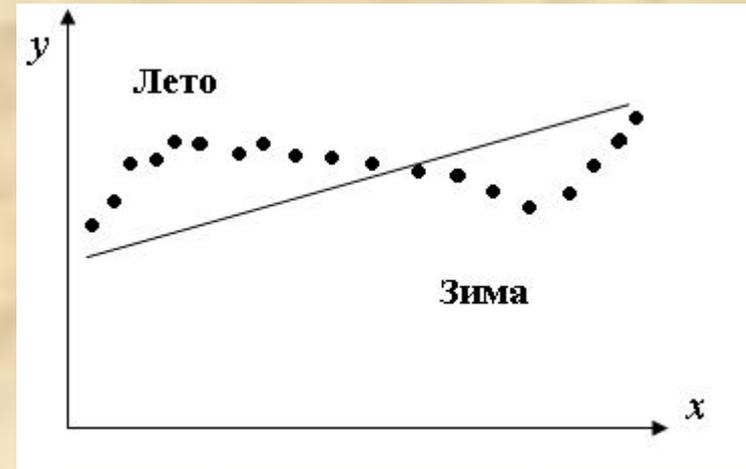
$$\frac{y_i}{x_i} = a \frac{1}{x_i} + b + v_i \quad (64)$$

$$y_i^* = \frac{y_i}{x_i}; \quad z_i = \frac{1}{x_i}$$

Автокорреляция остатков

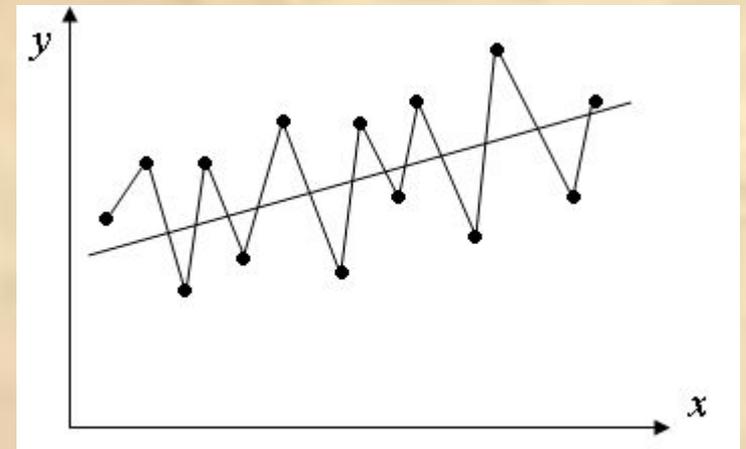
$$(\text{cov}(\varepsilon_{i-1}, \varepsilon_i) > 0)$$

-положительная автокорреляция



$$(\text{cov}(\varepsilon_{i-1}, \varepsilon_i) < 0)$$

-отрицательная автокорреляция



-МЕТОД РЯДОВ

$$M(k) = \frac{2n_1n_2}{n_1 + n_2} + 1;$$

$$D(k) = \frac{2n_1n_2(2n_1n_2 - n_1 - n_2)}{(n_1 + n_2)^2(n_1 + n_2 - 1)}$$

$$M(k) - u_{\alpha/2} \cdot \sqrt{D(k)} < k < M(k) + u_{\alpha/2} \cdot \sqrt{D(k)}$$

-нет автокорреляции

$$k \leq M(k) - u_{\alpha/2} \cdot \sqrt{D(k)}$$

-положительная автокорреляция

$$k \geq M(k) + u_{\alpha/2} \cdot \sqrt{D(k)}$$

-отрицательная автокорреляция

-критерий Дарбина - Уотсона

$$DW = \frac{\sum_{t=2}^n (e_t - e_{t-1})^2}{\sum_{t=1}^n e_t^2} \quad (65)$$

$0 \leq DW \leq d_l$ - положительная автокорреляция

$d_l < DW < d_u$ - зона неопределенности

$d_u \leq DW \leq 4 - d_u$ - автокорреляция
отсутствует;

$4 - d_u < DW < 4 - d_l$ - зона
неопределенности;

$4 - d_l \leq DW \leq 4$ - отрицательная
автокорреляция.

$$DW \approx 2(1 - r_{e_{t-1}e_t}) \quad (67)$$

-авторегрессионная схема 1-го порядка AR(1)

$$e_t = \rho e_{t-1} + v_t \quad (68) \quad \hat{\rho} = 1 - DW / 2$$

$$y = a + bx + e \quad (71)$$

$$y_t = a + bx_t + e_t \quad (72)$$

$$y_{t-1} = a + bx_{t-1} + e_{t-1} \quad (73)$$

$$y_t - \rho y_{t-1} = a(1 - \rho) + b(x_t - \rho x_{t-1}) + (e_t - \rho e_{t-1}) \quad (74)$$

$$y_t^* = y_t - \rho y_{t-1}; \quad x_t^* = x_t - \rho x_{t-1}; \quad a^* = a(1 - \rho) \quad (75)$$

$$y_t^* = a^* + bx_t^* + v_t \quad (76)$$

$\rho = 1$:

$$y_t - y_{t-1} = b(x_t - x_{t-1}) + (e_t - e_{t-1})$$

$$\Delta y_t = b\Delta x_t + v_t$$

$$\Delta y_t = y_t - y_{t-1}, \quad \Delta x_t = x_t - x_{t-1}$$

$\rho = -1$:

$$y_t + y_{t-1} = 2a + b(x_t + x_{t-1}) + v_t$$

$$\frac{y_t + y_{t-1}}{2} = a + b \frac{(x_t + x_{t-1})}{2} + v_t$$

Фиктивные переменные в регрессионных моделях

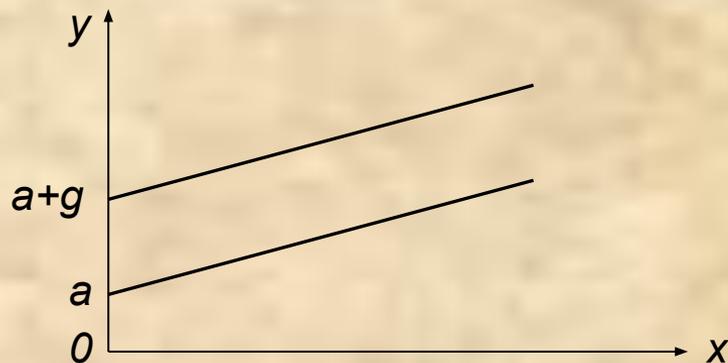
$$y = a + gD + e \quad \hat{y} = a + g \cdot 0 = a \quad \hat{y} = a + g \cdot 1 = a + g$$

$$y = a + bx + gD + e, \quad (80)$$

$$D = \begin{cases} 0, & \text{если сотрудник – женщина} \\ 1, & \text{если сотрудник – мужчина.} \end{cases}$$

$$\hat{y} = a + bx,$$

$$\hat{y} = a + bx + g = (a + g) + bx.$$



$$D_1 = \begin{cases} 0, & \text{страна не является развитой} \\ 1, & \text{страна развитая} \end{cases}$$

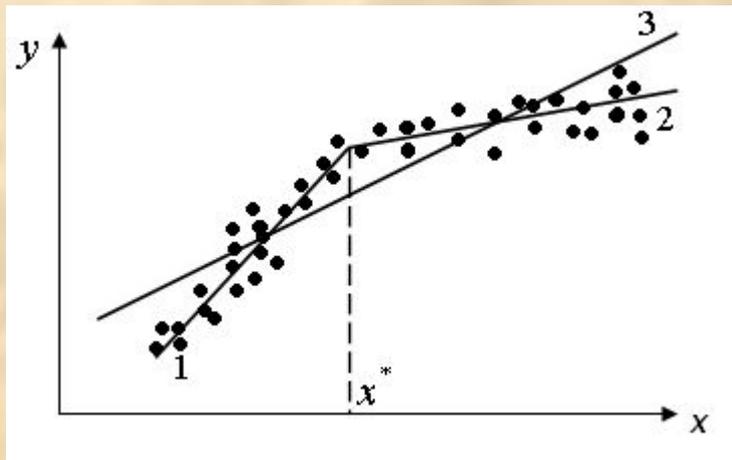
$$D_2 = \begin{cases} 0, & \text{страна не является развивающейся} \\ 1, & \text{страна развивающаяся} \end{cases}$$

$$y = a + bx + g_1D + g_2Dx + e \quad (81)$$

$$D = \begin{cases} 0, & \text{до изменения условий,} \\ 1, & \text{после изменения условий.} \end{cases}$$

$$\hat{y} = a + bx, \quad D = 0$$

$$\hat{y} = (a + g_1) + (b + g_2)x, \quad D = 1$$



-тест Чоу

$$F_{\text{iráë}} = \frac{s_3 - (s_1 + s_2)}{s_1 + s_2} \cdot \frac{n - 2p - 2}{p + 1} \quad (82)$$

$$F_{\text{набл}} < F(\alpha; p + 1; n - 2p - 2)$$

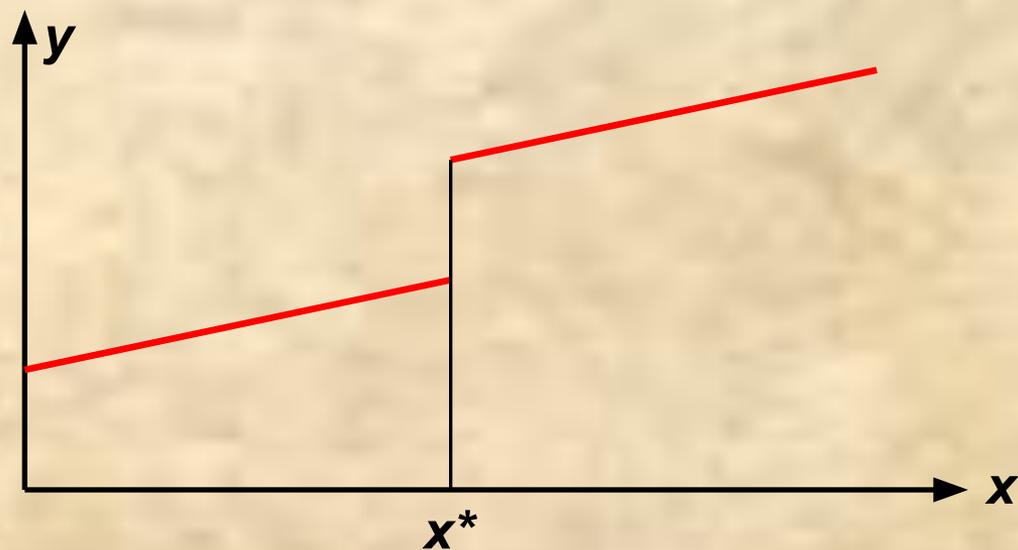
$$F_{\text{набл}} > F(\alpha; p + 1; n - 2p - 2)$$

Данные в подвыборках описываются двумя уравнениями регрессии:

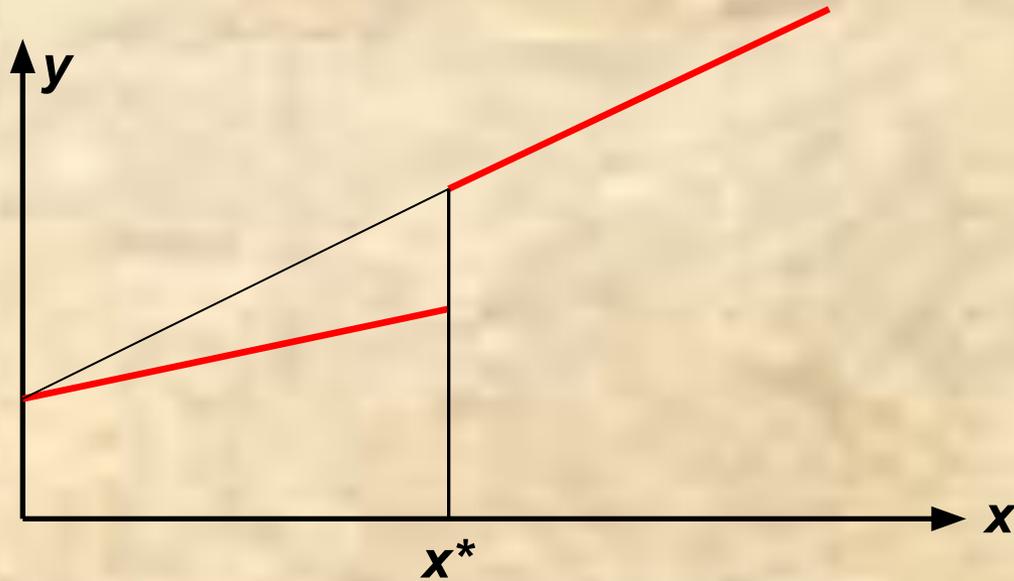
$$\hat{y} = a_1 + b_1x,$$

$$\hat{y} = a_2 + b_2x.$$

1. Различие между a_1 и a_2 значимо, между b_1 и b_2 – нет:



2. Различие между b_1 и b_2 значимо, между a_1 и a_2 – нет:



3. Различия между b_1 и b_2 , а также между a_1 и a_2 значимы:



- методика Гуйарати:

$$y = a + bD + cx + dDx + e$$

$$a_1 = (a + b); \quad b_1 = (c + d) \quad (D = 1)$$

$$a_2 = a; \quad b_2 = c \quad (D = 0)$$