

第十一讲 最小二乘法II

2023.12.1

$$A^\perp{}^\top B^\perp = A^\perp{}^\top B = A^\top B^\perp$$
$$\Sigma(a_i - \bar{a})(b_i - \bar{b}) = \Sigma(a_i - \bar{a})b_i = \Sigma a_i(b_i - \bar{b})$$

例子：体重指数

例1. 第7讲例6(P24) 使用简单回归模型研究了 $\log(W) \sim \log(H)$ 的关系, 得到了体重指数 $W/H^{2.27}$, W = 体重, H = 身高。因为 W, H 都与性别有关, 因此我们考虑控制性别因素 $Sex(1 = male; 0 = female)$:

$$\log(W) = a + b \times \log(H) + c \times Sex + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2),$$

$$\text{标准化: } z = \frac{\log(W) - (a + b \times \log(H) + c \times Sex)}{\sigma} \sim N(0, 1)$$

$$z \geq z_0 \Leftrightarrow W/H^b > e^{a+z_0\sigma+c \times sex} \quad (\text{Lab2, 练习3(e)})$$

```
> lm(formula = log(weight) ~ log(height) + sex, data = hw)
Coefficients:
(Intercept)  log(height)  sex
          3.0          2.0          0.124
Residual standard error: 0.1145
```

$$\hat{b} = 2, \hat{a} = 3, \hat{c} = 0.124, \hat{\sigma} = 0.1145$$

$z \geq 1.645$ (标准正态上5%)

$$\Leftrightarrow BMI = W/H^2 \geq e^{3+0.124 \times sex + 1.645 \times 0.1145} = \begin{cases} 28 & \text{male} \\ 24 & \text{female} \end{cases}$$


BMI的阈值应该区分性别。

(可加)模型 $\log(W) = a + b \times \log(H) + c \times Sex + \varepsilon$ 意味着对于男性和女性模型分别为

$$sex = 1 \text{ (绿线)}: \log(W) = (a + c) + b \times \log(H)$$

$$sex = 0 \text{ (红线)}: \log(W) = a + b \times \log(H)$$

即 $\log(H)$ 的系数 b 与性别无关：男性和女性的 $\log(H)$ 的系数都是 b ，但截距不同。这意味着，男性和女性数据具有大致平行的形状，才能应用线性可加模型。



男性组内（绿）、
女性组内（红）

的斜率 b 相同，即 W - H 关系平行，差别体现在截距上（即模型中 $c \times sex$ 一项）。

如果两组数据不平行即男性组和女性组斜率不同，可引入交互作用项：

$$\log(W) = a + b \log(H) + c \text{Sex} + d \text{Sex} \times \log(H) + error$$

此时两组的斜率分别是 $b, b + d$

中心化

β 的整体LS估计 $\hat{\beta} = (X^T X)^{-1} X^T y$ 。下面考虑 β 分量的LS估计。

$$X = (\mathbf{1}, Z), \quad \beta = \begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix}$$

因为截距 β_0 的特殊性，我们常常需要考虑将 $\mathbf{1}$ 与 Z 独立开来（正交化），令 Z 关于 $\mathbf{1}$ 的正交化（称为 Z 的中心化矩阵）：

$$Z_c = Z - P_1 Z = Z - \frac{\mathbf{1}\mathbf{1}^T}{n} Z = Z - \mathbf{1}\bar{\mathbf{x}}^T$$

其中 $\bar{\mathbf{x}} = Z^T \mathbf{1}/n$ 是所有自变量的样本平均值组成的向量（ Z 的列平均），则样本方差矩阵

$$S = Z_c^T Z_c / (n - 1)$$

我们将反复应用投影分解

$$P_X = P_1 + P_{Z_c} = \mathbf{1}\mathbf{1}^T/n + Z_c(Z_c^T Z_c)^{-1} Z_c^T$$

一元情形

- 样本: $y_1, \dots, y_n \in R$; $\mathbf{y} = (y_1, \dots, y_n)^\top$
- 样本均值 $\bar{y} = (y_1 + \dots + y_n) / n = \mathbf{1}^\top \mathbf{y} / n$, 其中 $\mathbf{1} = (1, \dots, 1)^\top$
- 中心化: $\mathbf{y}_c = (y_1 - \bar{y}, \dots, y_n - \bar{y})^\top = \mathbf{y} - \mathbf{1}\bar{y} = \mathbf{y} - P_1\mathbf{y}$
- 样本方差: $s^2 = \frac{1}{n-1} \sum_{i=1}^n (y_i - \bar{y})^2 = \frac{1}{n-1} \mathbf{y}_c^\top \mathbf{y}_c = \frac{1}{n-1} \mathbf{y}^\top (I_n - P_1)\mathbf{y}$.
- 标准化: $\mathbf{y}_c = (y_1 - \bar{y}, \dots, y_n - \bar{y})^\top / s = (\mathbf{y} - \mathbf{1}\bar{y}) / s$

多元情形

- 样本: $\mathbf{x}_1, \dots, \mathbf{x}_n \in R^m$; 数据矩阵: $Z = (\mathbf{x}_1, \dots, \mathbf{x}_n)^\top$
- 样本均值: $\bar{\mathbf{x}} = (\mathbf{x}_1 + \dots + \mathbf{x}_n) / n = Z^\top \mathbf{1} / n$.
- 中心化: $Z_c = (\mathbf{x}_1 - \bar{\mathbf{x}}, \dots, \mathbf{x}_n - \bar{\mathbf{x}})^\top = Z - \mathbf{1}\bar{\mathbf{x}}^\top = Z - P_1Z$
- 样本协方差: $S = \frac{1}{n-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top = \frac{1}{n-1} Z_c^\top Z_c = \frac{1}{n-1} Z^\top (I_n - P_1)Z$
- 标准化: $Z_s = D^{-1/2} Z_c$, 其中 $D = \text{diag}(S)$,
- 相关系数矩阵 $R = Z_s^\top Z_s / (n-1)$

线性模型 的中心化

模型: $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon}$, $\mathbf{X}_{n \times p} = (\mathbf{1}_{n \times 1}, \mathbf{Z}_{n \times (p-1)})$, $\boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix}$

- Z中心化: $\mathbf{Z}_c = \mathbf{Z} - \mathbf{1}\bar{\mathbf{x}}^\top = \mathbf{Z} - \mathbf{P}_1\mathbf{Z}$, 模型改写为

$$\mathbf{y} = \mathbf{1}\beta_0 + (\mathbf{Z}_c + \mathbf{1}\bar{\mathbf{x}}^\top)\mathbf{b} + \boldsymbol{\varepsilon} = \mathbf{1}(\beta_0 + \bar{\mathbf{x}}^\top\mathbf{b}) + \mathbf{Z}_c\mathbf{b} + \boldsymbol{\varepsilon} \stackrel{\Delta}{=} \mathbf{1}\beta_0^* + \mathbf{Z}_c\mathbf{b} + \boldsymbol{\varepsilon},$$

其中 $\beta_0^* = \beta_0 + \bar{\mathbf{x}}^\top\mathbf{b}$ 。 $P_X = P_{\mathbf{1}, \mathbf{Z}_c} = P_1 + P_{\mathbf{Z}_c}$ 。

- \mathbf{y}, \mathbf{Z} 都中心化: $\mathbf{y}_c = \mathbf{y} - \mathbf{1}\bar{y}$, $\mathbf{Z}_c = \mathbf{Z} - \mathbf{1}\bar{\mathbf{x}}^\top$, 模型改写为

$$\mathbf{y}_c = \mathbf{1}(\beta_0 + \bar{\mathbf{x}}^\top\mathbf{b} - \bar{y}) + \mathbf{Z}_c\mathbf{b} + \boldsymbol{\varepsilon} \stackrel{\Delta}{=} \mathbf{1}\beta_0^{**} + \mathbf{Z}_c\mathbf{b} + \boldsymbol{\varepsilon}$$

其中 $\beta_0^{**} = \beta_0 + \bar{\mathbf{x}}^\top\mathbf{b} - \bar{y}$

后面将看到, $\hat{\beta}_0 = \bar{y} - \bar{\mathbf{x}}^\top\hat{\mathbf{b}}$, $\hat{\beta}_0^* = \bar{y}$, $\hat{\beta}_0^{**} \equiv 0$, 故第二个模型中 β_0^{**} 通常不用写出来。

注1: 中心化不影响回归系数 \mathbf{b} , 但改变了截距项。

注2: 我们一般采用第一种中心化 (Z中心化)

拟合优度：决定系数 R^2

模型： $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim (0, \sigma^2 \mathbf{I}_n)$

拟合值： $\hat{\mathbf{y}} = P_X \mathbf{y} \in C(X)$; 残差： $\mathbf{e} = \mathbf{y}^\perp = \mathbf{y} - \hat{\mathbf{y}} = (\mathbf{I}_n - P_X) \mathbf{y} \perp C(X)$

$\mathbf{e} \perp C(X)$, 特别地 $\mathbf{e} \perp \mathbf{1} \Rightarrow \sum e_i = \sum (y_i - \hat{y}_i) = 0 \Rightarrow \bar{y} = \sum y_i / n = \sum \hat{y}_i / n = \bar{\hat{y}}$ 。

或： 因为 $P_X \mathbf{1} = \mathbf{1}$, 所以 $\hat{\mathbf{y}} = (\hat{y}_1, \dots, \hat{y}_n)^\top$ 的样本均值：

$$\bar{\hat{y}} = \mathbf{1}^\top \hat{\mathbf{y}} / n = \mathbf{1}^\top P_X \mathbf{y} / n = \mathbf{1}^\top \mathbf{y} / n = \bar{y}$$

定义： 总平方和 $SS_{\text{总}} = s_{yy} = \sum_{i=1}^n (y_i - \bar{y})^2 = \|\mathbf{y} - \mathbf{1}\bar{y}\|^2$

回归平方和 $SS_{\text{回}} = s_{\hat{y}\hat{y}} = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2$


决定系数 $R^2 = \frac{SS_{\text{回}}}{SS_{\text{总}}} = \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2} = \frac{\text{VAR}(\hat{\mathbf{y}})}{\text{VAR}(\mathbf{y})}$, VAR 表示样本方差。

决定系数度量了模型拟合的程度(拟合优度)/自变量对响应的解释能力。

因为 $\mathbf{e} \perp \hat{\mathbf{y}}$, $\mathbf{e} \perp \mathbf{1}$, 所以 $\mathbf{e} \perp (\hat{\mathbf{y}} - \mathbf{1}\bar{y}) \Rightarrow \mathbf{y} - \mathbf{1}\bar{y} = (\hat{\mathbf{y}} - \mathbf{1}\bar{y}) \oplus \mathbf{e}$,
 (下图红色三角形) 有平方分解:

$$\begin{aligned} \|\mathbf{y} - \mathbf{1}\bar{y}\|^2 &= \|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2 + \|\mathbf{e}\|^2 \\ \text{SS}_{\text{总}} &= \text{SS}_{\text{回}} + \text{RSS} \end{aligned}$$

所以, $\text{SS}_{\text{回}} \leq \text{SS}_{\text{总}}, 0 \leq R^2 \leq 1$ 。



上图表明 $R^2 = \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2} = \cos^2(\phi) = (r_{y\hat{y}})^2$

命题1. $R^2 = (r_{y\hat{y}})^2 = S_{yx}S_{xx}^{-1}S_{xy} / S_{yy}$, 其中 $r_{y\hat{y}}$ 为 $(y_i, \hat{y}_i), i = 1, \dots, n$ 的样本相关系数, $S_{xx} = \frac{1}{n-1} \sum (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top$, $S_{xy} = \frac{1}{n-1} \sum (\mathbf{x}_i - \bar{\mathbf{x}})(y_i - \bar{y})$.

证明: (1) 因为 $\mathbf{e} = \mathbf{y} - \hat{\mathbf{y}} \perp \hat{\mathbf{y}}$, $\mathbf{e} \perp \mathbf{1} \Rightarrow \langle \mathbf{e}, \hat{\mathbf{y}} - \mathbf{1}\bar{y} \rangle = 0$

$$\langle \mathbf{y} - \mathbf{1}\bar{y}, \hat{\mathbf{y}} - \mathbf{1}\bar{y} \rangle = \langle \hat{\mathbf{y}} - \mathbf{1}\bar{y}, \hat{\mathbf{y}} - \mathbf{1}\bar{y} \rangle = \|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2$$

$$\text{所以 } r_{y\hat{y}} = \frac{\langle \mathbf{y} - \mathbf{1}\bar{y}, \hat{\mathbf{y}} - \mathbf{1}\bar{y} \rangle}{\|\mathbf{y} - \mathbf{1}\bar{y}\| \|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|} = \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|}{\|\mathbf{y} - \mathbf{1}\bar{y}\|} \Rightarrow r_{y\hat{y}}^2 = R^2$$

$$A^\perp{}^\top B^\perp = A^\perp{}^\top B$$

其中 A, B 为矩阵或向量

$$A^\perp = A - P_C A$$

$$B^\perp = B - P_C B$$

$$Z_c^\top \mathbf{y} = Z_c^\top \mathbf{y}_c$$

(2) 因为 $\hat{\mathbf{y}} = P_{\mathbf{1}, Z} \mathbf{y} = P_{\mathbf{1}, Z_c} \mathbf{y} = P_{\mathbf{1}} \mathbf{y} + P_{Z_c} \mathbf{y} = \mathbf{1}\bar{y} + Z_c (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y}$,

所以由 $Z_c^\top Z_c / (n-1) = S_{xx}, Z_c^\top \mathbf{y} / (n-1) = S_{xy}$,

$$\text{SS}_{\text{回}} = \|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2 = \|Z_c (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y}\|^2 = \mathbf{y}^\top Z_c (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y} = (n-1) S_{yx} S_{xx}^{-1} S_{xy},$$

而 $\text{SS}_{\text{总}} = (n-1) S_{yy}$, 所以 $R^2 = S_{yx} S_{xx}^{-1} S_{xy} / S_{yy}$

命题2. $R^2 = \max_{\mathbf{u} \in L(X)} (r_{\mathbf{u}, \mathbf{y}})^2$, 其中 $r_{\mathbf{u}, \mathbf{y}}$ 为样本相关系数,

且最大值在 $\mathbf{u} = \hat{\mathbf{y}} = X\hat{\boldsymbol{\beta}}$ 处达到, 其中 $\hat{\boldsymbol{\beta}} = (X^T X)^{-1} X^T \mathbf{y}$ 。

第3讲命题3的
特殊情形

证明: 记 $\mathbf{y}_c \triangleq \mathbf{y} - \mathbf{1}\bar{y}$ 。对任何 $\mathbf{u} = X\boldsymbol{\beta} = \mathbf{1}\beta_0 + Z\mathbf{b} \in C(X)$,

记 \mathbf{u} 的中心化 $\mathbf{u}_c = \mathbf{u} - P_1 \mathbf{u} = \mathbf{1}\beta_0 + Z\mathbf{b} - (P_1 \mathbf{1}\beta_0 + P_1 Z\mathbf{b}) = Z\mathbf{b} - P_1 Z\mathbf{b} = Z_c \mathbf{b}$

$$\text{则 } (r_{\mathbf{u}, \mathbf{y}})^2 = \frac{(\mathbf{u}_c^T \mathbf{y}_c)^2}{\|\mathbf{u}_c\|^2 \|\mathbf{y}_c\|^2} = \frac{(\mathbf{b}^T Z_c^T \mathbf{y}_c)^2}{\mathbf{b}^T Z_c^T Z_c \mathbf{b} \times \|\mathbf{y}_c\|^2} = \frac{(\mathbf{w}^T [(Z_c^T Z_c)^{-1/2} Z_c^T \mathbf{y}_c])^2}{\mathbf{w}^T \mathbf{w} \cdot \|\mathbf{y}_c\|^2}$$

$$\begin{aligned} \mathbf{w} &= (Z_c^T Z_c)^{1/2} \mathbf{b} \\ \mathbf{b} &= (Z_c^T Z_c)^{-1/2} \mathbf{w} \end{aligned}$$

$$\leq \frac{\mathbf{w}^T \mathbf{w} \times \mathbf{y}_c^T Z_c (Z_c^T Z_c)^{-1} Z_c^T \mathbf{y}_c}{\mathbf{w}^T \mathbf{w} \times \|\mathbf{y}_c\|^2} \quad (\text{Cauchy-Schwartz不等式})$$

$$= \frac{\mathbf{w}^T \mathbf{w} \times \|P_{Z_c} \mathbf{y}_c\|^2}{\mathbf{w}^T \mathbf{w} \times \|\mathbf{y}_c\|^2} = \frac{\|P_{Z_c} \mathbf{y}_c\|^2}{\|\mathbf{y}_c\|^2} = \frac{\|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2}{\|\mathbf{y} - \mathbf{1}\bar{y}\|^2} = R^2$$

$$P_{Z_c} \mathbf{y}_c = P_{Z_c} \mathbf{y} = \hat{\mathbf{y}} - \mathbf{1}\bar{y}$$

当 $\mathbf{w} \propto (Z_c^T Z_c)^{-1/2} Z_c^T \mathbf{y}_c \Leftrightarrow \mathbf{b} = (Z_c^T Z_c)^{-1/2} \mathbf{w} \propto (Z_c^T Z_c)^{-1} Z_c^T \mathbf{y}_c$ 时, 等号成立。

此时 $\mathbf{u}_c = Z_c \mathbf{b} \propto Z_c (Z_c^T Z_c)^{-1} Z_c^T \mathbf{y}_c = Z_c \hat{\mathbf{b}}$, 特别地在 $\mathbf{u} = Z_c \hat{\mathbf{b}} + \mathbf{1}\bar{y} = X\hat{\boldsymbol{\beta}}$ 达到极大。

回归系数**b**的LS估计

我们将假设X列满秩。自变量的回归系数**b**的LS估计仅依赖于样本协方差矩阵，截距项LS估计与样本均值有关。

命题3. 假设模型 $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + \mathbf{Z}\mathbf{b} + \boldsymbol{\varepsilon}$, $\boldsymbol{\varepsilon} \sim (0, \sigma^2 I_n)$ 与 X 独立。

假设 $X = (\mathbf{1}, \mathbf{Z})$ 列满秩, $\boldsymbol{\beta} = \begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix}$, $\mathbf{Z} = (\mathbf{x}_1, \dots, \mathbf{x}_n)^\top$, $\mathbf{Z}_c = \mathbf{Z} - \mathbf{1}\bar{\mathbf{x}}^\top$. 则

(1) LS估计 $\hat{\mathbf{b}} = (\mathbf{Z}_c \mathbf{Z}_c^\top)^{-1} \mathbf{Z}_c^\top \mathbf{y} = S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}$, $\hat{\beta}_0 = \bar{y} - \bar{\mathbf{x}}^\top \hat{\mathbf{b}}$.

(2) $\text{var}(\hat{\mathbf{b}} | X) = \sigma^2 (\mathbf{Z}_c \mathbf{Z}_c^\top)^{-1} = \sigma^2 S_{\mathbf{xx}}^{-1} / (n-1)$.

(3) $\hat{\sigma}^2 = \frac{n-1}{n-p} S_{yy \cdot \mathbf{x}} \approx S_{yy \cdot \mathbf{x}} = S_{yy} - S_{y\mathbf{x}} S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}$
 $= S_{yy} (1 - R^2)$, $R^2 = S_{y\mathbf{x}} S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}} / S_{yy}$.

对比第5讲命题2(总体版本)

$$\mathbf{b} = \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}}$$

$$\beta_0 = \mu_y - \mathbf{b}^\top \boldsymbol{\mu}_x$$

$$\sigma^2 = \Sigma_{yy \cdot \mathbf{x}} = (1 - \Phi) \Sigma_{yy}$$

$$\Phi = \Sigma_{y\mathbf{x}} \Sigma_{\mathbf{xx}}^{-1} \Sigma_{\mathbf{xy}} / \Sigma_{yy}$$

注：将**b**、 β_0 、 σ^2 中的总体方差 $\Sigma_{\mathbf{xx}}$ 、 $\Sigma_{\mathbf{xy}}$ 换成样本方差 $S_{\mathbf{xx}}$ 、 $S_{\mathbf{xy}}$ ，总体均值换成样本均值即得矩估计。**b**、 β_0 的矩估计与LS估计相同， σ^2 的估计略有差异(相差倍数 $(n-1)/(n-p) \approx 1$)。

证1: (1) 先将Z中心化 (即Z与1正交化),

令 $Z_c = Z - P_1 Z = Z - \mathbf{1}\bar{\mathbf{x}}^\top$, 改写模型

$$\mathbf{y} = \mathbf{1}\beta_0 + Z\mathbf{b} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0^* + Z_c\mathbf{b} + \boldsymbol{\varepsilon}, \quad \beta_0^* = \beta_0 + \bar{\mathbf{x}}^\top\mathbf{b}$$

则 \mathbf{y} 在 $C(X) = C(\mathbf{1}, Z) = C(\mathbf{1}, Z_c)$ 上的投影:

$$\hat{\mathbf{y}} = P_X \mathbf{y} = P_1 \mathbf{y} + P_{Z_c} \mathbf{y} = \underbrace{\mathbf{1}\mathbf{1}^\top \mathbf{y} / n}_{\hat{\beta}_0^*} + \underbrace{Z_c (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y}}_{Z_c \hat{\mathbf{b}}}$$

1的系数为 $\hat{\beta}_0^*$,
Z的系数为 $\hat{\mathbf{b}}$

所以 $\hat{\mathbf{b}} = (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y}$, $\hat{\beta}_0^* = \mathbf{1}^\top \mathbf{y} / n = \bar{y} \Rightarrow \hat{\beta}_0 = \hat{\beta}_0^* - \bar{\mathbf{x}}^\top \hat{\mathbf{b}} = \bar{y} - \bar{\mathbf{x}}^\top \hat{\mathbf{b}}$.

或对中心化模型

$$\mathbf{y} = \mathbf{1}\beta_0^* + Z_c\mathbf{b} + \boldsymbol{\varepsilon} \stackrel{\Delta}{=} X^* \boldsymbol{\beta}^* + \boldsymbol{\varepsilon}, \quad X^* = (\mathbf{1}, Z_c), \beta_0^* = \beta_0 + \bar{\mathbf{x}}^\top\mathbf{b}$$

应用LS估计公式:

$$\hat{\boldsymbol{\beta}}^* = \begin{pmatrix} \hat{\beta}_0^* \\ \hat{\mathbf{b}} \end{pmatrix} = (X^{*\top} X^*)^{-1} X^{*\top} \mathbf{y} = \begin{pmatrix} n & 0 \\ 0 & Z_c^\top Z_c \end{pmatrix}^{-1} \begin{pmatrix} \mathbf{1}^\top \mathbf{y} \\ Z_c^\top \mathbf{y} \end{pmatrix} = \begin{pmatrix} \bar{y} \\ (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y} \end{pmatrix}$$

$$\Rightarrow \hat{\mathbf{b}} = (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y}, \quad \hat{\beta}_0^* = \bar{y}.$$

注意 $Z_c^\top Z_c = \sum (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top = (n-1)S_{\mathbf{xx}}$, $Z_c^\top \mathbf{y} = (n-1) S_{\mathbf{xy}} \Rightarrow$

$$\hat{\mathbf{b}} = (Z_c Z_c^\top)^{-1} Z_c^\top \mathbf{y} = S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}$$

(2) 显然 $\text{var}(\hat{\mathbf{b}} | X) = \sigma^2 (Z_c^\top Z_c)^{-1}$, 所以

$$\text{var}(\hat{\mathbf{b}} | X) = \sigma^2 (Z_c^\top Z_c)^{-1} = \sigma^2 S_{\mathbf{xx}}^{-1} / (n-1).$$

(3) 由 $\hat{\mathbf{y}} = P_1 \mathbf{y} + P_{Z_c} \mathbf{y} = \mathbf{1}\bar{y} + P_{Z_c} \mathbf{y}$, 知 $\hat{\mathbf{y}} - \mathbf{1}\bar{y} = P_{Z_c} \mathbf{y}$,

$$Z_c^\top \mathbf{y} = Z_c^\top \mathbf{y}_c$$

所以

$$SS_{\text{回}} = \|\hat{\mathbf{y}} - \mathbf{1}\bar{y}\|^2 = \|P_{Z_c} \mathbf{y}\|^2 = \mathbf{y}^\top Z_c (Z_c^\top Z_c)^{-1} Z_c^\top \mathbf{y} = (n-1) S_{\mathbf{yx}} S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}$$

而 $SS_{\text{总}} = \|\mathbf{y} - \mathbf{1}\bar{y}\|^2 = (n-1)S_{yy}$, 所以

$$RSS = SS_{\text{总}} - SS_{\text{回}} = (n-1) [S_{yy} - S_{\mathbf{yx}} S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}] = (n-1) S_{yy \bullet \mathbf{x}},$$

所以

$$\hat{\sigma}^2 = RSS / (n-p) = \frac{n-1}{n-p} S_{yy \bullet \mathbf{x}}, \quad R^2 = \frac{S_{\mathbf{yx}} S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}}{S_{yy}}.$$

其它更直接但更复杂的证明（可略过）：

证2.(应用分块矩阵的逆, 求 $\hat{\boldsymbol{\beta}}$ 的分量) $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = (\mathbf{1}, Z) \begin{pmatrix} \beta_0 \\ \mathbf{b} \end{pmatrix} + \boldsymbol{\varepsilon}$

由定理1, 已知LS估计 $\hat{\boldsymbol{\beta}} = (X^T X)^{-1} X^T \mathbf{y}$, 下面求分量 $\hat{\mathbf{b}}$ 。

$$\text{分块: } X^T X = \begin{pmatrix} \mathbf{1}^T \\ Z^T \end{pmatrix} (\mathbf{1}, Z) = \begin{pmatrix} \mathbf{1}^T \mathbf{1} & \mathbf{1}^T Z \\ Z^T \mathbf{1} & Z^T Z \end{pmatrix} = \begin{pmatrix} n & n\bar{\mathbf{x}}^T \\ n\bar{\mathbf{x}} & \sum \mathbf{x}_i \mathbf{x}_i^T \end{pmatrix}, X^T \mathbf{y} = \begin{pmatrix} \mathbf{1}^T \\ Z^T \end{pmatrix} \mathbf{y} = \begin{pmatrix} n\bar{y} \\ \sum \mathbf{x}_i y_i \end{pmatrix},$$

由分块矩阵求逆公式（第4讲命题1）

$$(X^T X)^{-1} = \begin{pmatrix} a & -\bar{\mathbf{x}}^T A^{-1} \\ -A^{-1} \bar{\mathbf{x}} & A^{-1} \end{pmatrix}, \text{其中 } A = (n-1)S_{\mathbf{xx}}, \quad a = 1/n + \bar{\mathbf{x}}^T A^{-1} \bar{\mathbf{x}}$$

$$\Rightarrow \hat{\boldsymbol{\beta}} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\mathbf{b}} \end{pmatrix} = \begin{pmatrix} n & n\bar{\mathbf{x}}^T \\ n\bar{\mathbf{x}} & \sum \mathbf{x}_i \mathbf{x}_i^T \end{pmatrix}^{-1} \begin{pmatrix} n\bar{y} \\ \sum \mathbf{x}_i y_i \end{pmatrix} = \begin{pmatrix} a & -\bar{\mathbf{x}}^T A^{-1} \\ -A^{-1} \bar{\mathbf{x}} & A^{-1} \end{pmatrix} \begin{pmatrix} n\bar{y} \\ \sum \mathbf{x}_i y_i \end{pmatrix}$$

$$= \begin{pmatrix} na\bar{y} - \bar{\mathbf{x}}^T A^{-1} \sum \mathbf{x}_i y_i \\ A^{-1} \sum \mathbf{x}_i y_i - nA^{-1} \bar{\mathbf{x}} \bar{y} \end{pmatrix} = \begin{pmatrix} \bar{y} - \bar{\mathbf{x}}^T S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}} \\ S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}} \end{pmatrix}$$

所以 $\hat{\mathbf{b}} = S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}$, $\hat{\beta}_0 = \bar{y} - \bar{\mathbf{x}}^T \hat{\mathbf{b}}$ 。

第4讲命题1: $\Sigma > 0$,

$$\begin{pmatrix} \Sigma_{11} & \Sigma_{12} \\ \Sigma_{21} & \Sigma_{22} \end{pmatrix}^{-1} = \begin{pmatrix} \Sigma_{11\bullet 2}^{-1} & -\Sigma_{11\bullet 2}^{-1} \Sigma_{12} \Sigma_{22}^{-1} \\ -\Sigma_{22}^{-1} \Sigma_{21} \Sigma_{11\bullet 2}^{-1} & \Sigma_{22\bullet 1}^{-1} \end{pmatrix}$$

证3 (误差平方和分别对 β_0 和 \mathbf{b} 求导) $\boldsymbol{\beta} = (\beta_0, \mathbf{b}^\top)^\top$

$$Q(\boldsymbol{\beta}) = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2 = \sum_{i=1}^n (y_i - \tilde{\mathbf{x}}_i^\top \boldsymbol{\beta})^2 = \sum_{i=1}^n (y_i - \beta_0 - \mathbf{x}_i^\top \mathbf{b})^2$$

$$\frac{\partial Q}{\partial \boldsymbol{\beta}} = 0 \Leftrightarrow \begin{cases} \frac{\partial Q}{\partial \beta_0} = \sum_{i=1}^n (y_i - \beta_0 - \mathbf{x}_i^\top \mathbf{b}) = 0 \\ \frac{\partial Q}{\partial \mathbf{b}} = \sum_{i=1}^n \mathbf{x}_i (y_i - \beta_0 - \mathbf{x}_i^\top \mathbf{b}) = 0 \end{cases} \Leftrightarrow \begin{cases} \sum y_i - n\beta_0 - (\sum \mathbf{x}_i)^\top \mathbf{b} = 0 \\ \sum \mathbf{x}_i y_i - (\sum \mathbf{x}_i) \beta_0 - (\sum \mathbf{x}_i \mathbf{x}_i^\top) \mathbf{b} = 0 \end{cases}$$

$$\Leftrightarrow \begin{cases} \bar{y} - \beta_0 - \bar{\mathbf{x}}^\top \mathbf{b} = 0 \\ \sum \mathbf{x}_i y_i - n\bar{\mathbf{x}} \beta_0 - (\sum \mathbf{x}_i \mathbf{x}_i^\top) \mathbf{b} = 0 \end{cases}$$

第一式左乘 $n\bar{\mathbf{x}}$ 减去第二式, 消去 β_0 , 得:

消去 β_0 的过程 \Leftrightarrow 中心化

$$(\sum \mathbf{x}_i \mathbf{x}_i^\top - n\bar{\mathbf{x}}\bar{\mathbf{x}}^\top) \mathbf{b} = \sum \mathbf{x}_i y_i - n\bar{\mathbf{x}}\bar{y}$$

$$\Rightarrow \hat{\mathbf{b}} = \left(\sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top \right)^{-1} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}}) y_i = S_{\mathbf{xx}}^{-1} S_{\mathbf{xy}}, \hat{\beta}_0 = \bar{y} - \bar{\mathbf{x}}^\top \hat{\mathbf{b}},$$

为了简化论证过程，常常“不妨假设数据已经中心化或中心标准化”

我们已知：

- 如果 $\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + Z\mathbf{b} + \boldsymbol{\varepsilon}$ 中 Z 已经中心化，那么

$$\hat{\mathbf{b}} = (Z^T Z)^{-1} Z^T \mathbf{y} = S_{xx}^{-1} S_{xy}, \quad \hat{\beta}_0 = \bar{y}$$

- 如果 \mathbf{y} , X 都已经中心化，那么

$$\hat{\mathbf{b}} = (Z^T Z)^{-1} Z^T \mathbf{y} = S_{xx}^{-1} S_{xy}, \quad \hat{\beta}_0 \equiv 0, \quad \text{此时 } \beta_0 \text{ 无需估计。}$$

假设 \mathbf{y} , Z 都已经中心化，则截距项LS估计恒为0，故假设无截距项：

- $\mathbf{y} = Z\mathbf{b} + \boldsymbol{\varepsilon}$ （不含截距项），假设 \mathbf{y} , Z 都已经中心化，

$$\hat{\mathbf{b}} = (Z^T Z)^{-1} Z^T \mathbf{y} = S_{xx}^{-1} S_{xy}, \quad S: \text{样本方差矩阵}$$

- $\mathbf{y} = Z\mathbf{b} + \boldsymbol{\varepsilon}$ （不含截距项），假设 \mathbf{y} , Z 都已经中心标准化，


$$\hat{\mathbf{b}} = (Z^T Z)^{-1} Z^T \mathbf{y} = R_{xx}^{-1} R_{xy}, \quad R: \text{样本相关系数矩阵。}$$

部分回归系数的LS估计

假设设计阵 X 按列划分为 $X = (\mathbf{1}, X_1, X_2)$, 模型为

$$\mathbf{y} = X\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + X_1\boldsymbol{\beta}_1 + X_2\boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}$$

其中 X_1 的列是干扰因素, X_2 的列是感兴趣的变量。LS估计 $\hat{\boldsymbol{\beta}}_2$ 是否有效地消除了 X_1 的影响?



$$X_2^\perp = X_2 - P_{\mathbf{1}, X_1} X_2$$

$$\hat{\boldsymbol{\beta}}_2 = (X_2^{\perp\top} X_2^\perp)^{-1} X_2^{\perp\top} \mathbf{y}$$

记号：记所有数据 (\mathbf{y}, X_1, X_2) 的样本方差-协方差矩阵为

$$S = \begin{matrix} & \mathbf{x}_1 & \mathbf{x}_2 & y \\ \mathbf{x}_1 & \begin{pmatrix} S_{11} & S_{12} & S_{1y} \end{pmatrix} \\ \mathbf{x}_2 & \begin{pmatrix} S_{21} & S_{22} & S_{2y} \end{pmatrix} \\ y & \begin{pmatrix} S_{y1} & S_{y2} & S_{yy} \end{pmatrix} \end{matrix}, \begin{pmatrix} S_{22 \cdot 1} & S_{2y \cdot 1} \\ S_{y2 \cdot 1} & S_{yy \cdot 1} \end{pmatrix} = \begin{pmatrix} S_{22} & S_{2y} \\ S_{y2} & S_{yy} \end{pmatrix} - \begin{pmatrix} S_{21} \\ S_{y1} \end{pmatrix} S_{11}^{-1} (S_{12}, S_{1y})$$

LS估计的分量

命题4: 假设线性模型:

$$\mathbf{y}_{n \times 1} = X_{n \times p} \boldsymbol{\beta}_{p \times 1} + \boldsymbol{\varepsilon}_{n \times 1} = \mathbf{1} \beta_0 + X_1 \boldsymbol{\beta}_1 + X_2 \boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim (\mathbf{0}, \sigma^2 I_n), \quad \boldsymbol{\varepsilon} \perp X$$

其中 $X = (\mathbf{1}, X_1, X_2)$ 列满秩, $\boldsymbol{\beta} = (\beta_0, \boldsymbol{\beta}_1^\top, \boldsymbol{\beta}_2^\top)^\top$, 令 $X_2^\perp = X_2 - P_{\mathbf{1}, X_1} X_2$, 则

$$\hat{\boldsymbol{\beta}}_2 = (X_2^{\perp \top} X_2^\perp)^{-1} X_2^{\perp \top} \mathbf{y} = S_{22 \cdot 1}^{-1} S_{2y \cdot 1},$$

$$\text{var}(\hat{\boldsymbol{\beta}}_2 | X) = \sigma^2 (X_2^{\perp \top} X_2^\perp)^{-1} = \sigma^2 S_{22 \cdot 1}^{-1} / (n-1),$$

对比第5讲命题3(总体)

$$\boldsymbol{\beta}_2 = \Sigma_{22 \cdot 1}^{-1} \Sigma_{2y \cdot 1}$$

这里给出 $\hat{\boldsymbol{\beta}}$ 的分量的数学表达是为了理解参数估计的含义。实际数据计算时，无需应用命题4，只需要套用一般公式 $\hat{\boldsymbol{\beta}} = (X^\top X)^{-1} X^\top \mathbf{y}$ 即可。

$\hat{\beta}_2$ 的评注

注1. β 的整体LS估计 $\hat{\beta} = (X^T X)^{-1} X^T y$ 和它的一部分 $\hat{\beta}_2 = (X_2^{\perp T} X_2^{\perp})^{-1} X_2^{\perp T} y$ 形式完全相同。

$$\hat{\beta}_2 = (X_2^{\perp T} X_2^{\perp})^{-1} X_2^{\perp T} y = (X_2^{\perp T} X_2^{\perp})^{-1} X_2^{\perp T} y^{\perp}, y^{\perp} = y - P_{X_1} y$$

表明 $\hat{\beta}_2$ 是 X_2 和/或 y 消除了 X_1 影响之后的估计, 即 $y \sim X_2^{\perp}$ 或 $y^{\perp} \sim X_2^{\perp} \Rightarrow \hat{\beta}_2$ 。

注2. 特别地, 当 X_2 是向量时, $\hat{\beta}_2 = S_{22 \cdot 1}^{-1} S_{2y \cdot 1} \propto r_{2y \cdot 1}$ (样本偏相关系数)。即线性回归与偏相关系数本质上相同, 都是消除了 X_1 的影响之后得到的 y 和 X_2 之间的关系。

注3: 由注1的观察, $\hat{\beta}_2$ 可由两步回归得到:

(1) $X_2 \sim X_1$ (多元回归, X_2 的每一列对 X_1 回归) 所有残差按列排列得:

$$X_2^{\perp} = X_2 - P_{1, X_1} X_2;$$

(2) $y \sim X_2^{\perp}$: $y = X_2^{\perp} \beta_2 + \delta$ 得 $\hat{\beta}_2 = (X_2^{\perp T} X_2^{\perp})^{-1} X_2^{\perp T} y$ 。

注4. 由命题4所给的表达式, 我们可以如下方式简单求解 $\hat{\beta}_2$:
 模型 $\mathbf{y} = X_1\beta_1 + X_2\beta_2 + \boldsymbol{\varepsilon}$ 两端同时左乘 $X_2^\perp{}^\top$, 并令 $X_2^\perp{}^\top \boldsymbol{\varepsilon} = \mathbf{0}$, 得

$$X_2^\perp{}^\top \mathbf{y} = X_2^\perp{}^\top X_2 \beta_2 \Rightarrow \hat{\beta}_2 = (X_2^\perp{}^\top X_2^\perp)^{-1} X_2^\perp{}^\top \mathbf{y}.$$


为什么方程两端同时左乘 $X_2^\perp{}^\top$?

- (1) X_2^\perp 与 X_1 列正交 (消除 β_1),
- (2) X_2^\perp 与 X_2 最接近(投影的LS性质)。

一般地, 假设 W 是任一 $n \times q$ 矩阵, $W^\top X_1 = 0, W^\top X_2$ 可逆,
 模型方程两端同时左乘 W^\top 并令 $W^\top \boldsymbol{\varepsilon} = 0$, 得

$$W^\top \mathbf{y} = W^\top X_2 \beta_2 \Rightarrow \tilde{\beta}_2 = (W^\top X_2)^{-1} W^\top \mathbf{y},$$

$\tilde{\beta}_2$ 是无偏估计, 由GM定理, 当 $W = X_2^\perp = X_2 - P_{X_1} X_2$ 时方差最小。



命题4的证明1:

(1) 不妨设 X_1, X_2 已经中心化, 所以 $\mathbf{1}, X_1, X_2^\perp$ 三部分相互列正交. 下面我们将投影 $\hat{\mathbf{y}} = P_X \mathbf{y} = P_{(\mathbf{1}, X_1, X_2)} \mathbf{y}$ 表示成 $\mathbf{1}, X_1, X_2$ 的组合形式 $\mathbf{1}\{\bar{y}\} + X_1\{\mathbf{u}\} + X_2\{\mathbf{v}\}$, 则三个组合系数分别是 $\hat{\beta}_0, \hat{\beta}_1, \hat{\beta}_2$.

$$\begin{aligned} \hat{\mathbf{y}} &= P_{(\mathbf{1}, X_1, X_2)} \mathbf{y} = P_{(\mathbf{1}, X_1, X_2^\perp)} \mathbf{y} = P_{\mathbf{1}} \mathbf{y} + P_{X_1} \mathbf{y} + P_{X_2^\perp} \mathbf{y} \\ &= \mathbf{1}\bar{y} + X_1 \left[(X_1^\top X_1)^{-1} X_1^\top \mathbf{y} \right] + X_2^\perp \left[(X_2^{\perp\top} X_2^\perp)^{-1} X_2^{\perp\top} \mathbf{y} \right] \\ &\stackrel{\Delta}{=} \mathbf{1}\bar{y} + X_1[\mathbf{u}] + X_2^\perp[\mathbf{v}] \\ &= \mathbf{1}\bar{y} + X_1 \mathbf{u} + \left(X_2 - X_1 (X_1^\top X_1)^{-1} X_1^\top X_2 \right) \mathbf{v} \\ &= \mathbf{1}\{\bar{y}\} + X_1 \left\{ \mathbf{u} - (X_1^\top X_1)^{-1} X_1^\top X_2 \mathbf{v} \right\} + X_2 \{\mathbf{v}\} \end{aligned}$$

$$\Rightarrow \hat{\beta}_0 = \bar{y}, \quad \hat{\beta}_1 = \mathbf{u} - (X_1^\top X_1)^{-1} X_1^\top X_2 \mathbf{v}, \quad \hat{\beta}_2 = \mathbf{v} = (X_2^{\perp\top} X_2^\perp)^{-1} X_2^{\perp\top} \mathbf{y}$$

由对称性 $\hat{\beta}_1$ 必定等于 $(X_1^{\perp\top} X_1^\perp)^{-1} X_1^{\perp\top} \mathbf{y}$, $X_1^\perp = X_1 - P_{X_2} X_1$

另外, $X_2^\perp = X_2 - P_{X_1} X_2 \Rightarrow X_2^{\perp T} X_2^\perp = X_2^T X_2 - X_2^T X_1 (X_1^T X_1)^{-1} X_1^T X_2$
 $= (n-1)S_{22} - (n-1)S_{21}S_{11}^{-1}S_{12} = (n-1)S_{22\cdot 1}$, 同样 $X_2^{\perp T} \mathbf{y} = (n-1)S_{2y\cdot 1}$,
 $\Rightarrow \hat{\boldsymbol{\beta}}_2 = (X_2^{\perp T} X_2^\perp)^{-1} X_2^{\perp T} \mathbf{y} = S_{22\cdot 1}^{-1} S_{2y\cdot 1}$,
 $\text{var}(\hat{\boldsymbol{\beta}}_2 | X) = \sigma^2 (X_2^{\perp T} X_2^\perp)^{-1} = \sigma^2 S_{22\cdot 1}^{-1} / (n-1)$. 证毕。

证明2: (X_1, X_2 先正交化, 再应用LS估计一般公式) 不妨假设 X_1, X_2 已经中心化, 这不影响 $\boldsymbol{\beta}_1, \boldsymbol{\beta}_2$ 的LS估计。 $X_2^\perp = X_2 - P_{X_1} X_2$, 改写模型:

$$\begin{aligned} \mathbf{y} &= \mathbf{1}\beta_0 + X_1\boldsymbol{\beta}_1 + X_2\boldsymbol{\beta}_2 + \boldsymbol{\varepsilon} = \mathbf{1}\beta_0 + X_1\boldsymbol{\beta}_1 + (X_2^\perp + P_{X_1} X_2)\boldsymbol{\beta}_2 + \boldsymbol{\varepsilon} \\ &= \mathbf{1}\beta_0 + X_1 \left[\boldsymbol{\beta}_1 + (X_1^T X_1)^{-1} X_1^T X_2 \boldsymbol{\beta}_2 \right] + X_2^\perp \boldsymbol{\beta}_2 + \boldsymbol{\varepsilon} \\ &\hat{=} \mathbf{1}\beta_0 + X_1 \boldsymbol{\beta}_1^* + X_2^\perp \boldsymbol{\beta}_2 + \boldsymbol{\varepsilon}, \text{其中 } \boldsymbol{\beta}_1^* = \boldsymbol{\beta}_1 + (X_1^T X_1)^{-1} X_1^T X_2 \boldsymbol{\beta}_2 \end{aligned}$$

该模型的设计阵的三部分 $\mathbf{1}, X_1, X_2^\perp$ 相互正交, $X^T X$ 分块对角, 所以由LS估计公式

$$\text{易得 } \hat{\boldsymbol{\beta}} = \begin{pmatrix} \hat{\beta}_0 \\ \hat{\boldsymbol{\beta}}_1^* \\ \hat{\boldsymbol{\beta}}_2 \end{pmatrix} = \begin{pmatrix} \mathbf{1}^T \mathbf{1} & 0 & 0 \\ 0 & X_1^T X_1 & 0 \\ 0 & 0 & X_2^{\perp T} X_2^\perp \end{pmatrix}^{-1} \begin{pmatrix} \mathbf{1}^T \mathbf{y} \\ X_1^T \mathbf{y} \\ X_2^{\perp T} \mathbf{y} \end{pmatrix} = \begin{pmatrix} \bar{y} \\ (X_1^T X_1)^{-1} X_1^T \mathbf{y} \\ (X_2^{\perp T} X_2^\perp)^{-1} X_2^{\perp T} \mathbf{y} \end{pmatrix} \Rightarrow \hat{\boldsymbol{\beta}}_2 = (X_2^{\perp T} X_2^\perp)^{-1} X_2^{\perp T} \mathbf{y}.$$

证明3: (求导, 不假设 X_1, X_2 已经中心化)

$Q = \|\mathbf{y} - \mathbf{1}\beta_0 - X_1\boldsymbol{\beta}_1 - X_2\boldsymbol{\beta}_2\|^2$ 求导得正则方程 $X^\top(\mathbf{y} - X\boldsymbol{\beta}) = \mathbf{0}$:

$$\begin{cases} \partial Q / \partial \beta_0 = -\mathbf{1}^\top(\mathbf{y} - \mathbf{1}\beta_0 - X_1\boldsymbol{\beta}_1 - X_2\boldsymbol{\beta}_2) = 0 \\ \partial Q / \partial \boldsymbol{\beta}_1 = -X_1^\top(\mathbf{y} - \mathbf{1}\beta_0 - X_1\boldsymbol{\beta}_1 - X_2\boldsymbol{\beta}_2) = \mathbf{0} \\ \partial Q / \partial \boldsymbol{\beta}_2 = -X_2^\top(\mathbf{y} - \mathbf{1}\beta_0 - X_1\boldsymbol{\beta}_1 - X_2\boldsymbol{\beta}_2) = \mathbf{0} \end{cases}$$

下面应用初等消去法解正则方程(即求 $X^\top X$ 的逆)

第一式整理得: $\beta_0 = \bar{y} - \bar{\mathbf{x}}_1^\top \boldsymbol{\beta}_1 - \bar{\mathbf{x}}_2^\top \boldsymbol{\beta}_2$, 代入二、三式

$$\begin{cases} X_1^\top [\mathbf{y} - \mathbf{1}(\bar{y} - \bar{\mathbf{x}}_1^\top \boldsymbol{\beta}_1 - \bar{\mathbf{x}}_2^\top \boldsymbol{\beta}_2) - X_1\boldsymbol{\beta}_1 - X_2\boldsymbol{\beta}_2] = 0 \\ X_2^\top [\mathbf{y} - \mathbf{1}(\bar{y} - \bar{\mathbf{x}}_1^\top \boldsymbol{\beta}_1 - \bar{\mathbf{x}}_2^\top \boldsymbol{\beta}_2) - X_1\boldsymbol{\beta}_1 - X_2\boldsymbol{\beta}_2] = 0 \end{cases}$$

整理得:

$$\begin{cases} X_1^\top (X_1 - \mathbf{1}\bar{\mathbf{x}}_1^\top) \boldsymbol{\beta}_1 + X_1^\top (X_2 - \mathbf{1}\bar{\mathbf{x}}_2^\top) \boldsymbol{\beta}_2 = X_1^\top (\mathbf{y} - \mathbf{1}\bar{y}) = (X_1 - \mathbf{1}\bar{\mathbf{x}}_1^\top)^\top \mathbf{y} \\ X_2^\top (X_1 - \mathbf{1}\bar{\mathbf{x}}_1^\top) \boldsymbol{\beta}_1 + X_2^\top (X_2 - \mathbf{1}\bar{\mathbf{x}}_2^\top) \boldsymbol{\beta}_2 = X_2^\top (\mathbf{y} - \mathbf{1}\bar{y}) \end{cases}$$

记（中心化） $X_{1c} = X_1 - \mathbf{1}\bar{x}_1^\top$, $X_{2c} = X_2 - \mathbf{1}\bar{x}_2^\top$, $\mathbf{y}_c = \mathbf{y} - \mathbf{1}\bar{y}$,

前述方程组简写为

$$\begin{cases} X_{1c}^\top X_{1c} \boldsymbol{\beta}_1 + X_{1c}^\top X_{2c} \boldsymbol{\beta}_2 = X_{1c}^\top \mathbf{y} \\ X_{2c}^\top X_{1c} \boldsymbol{\beta}_1 + X_{2c}^\top X_{2c} \boldsymbol{\beta}_2 = X_{2c}^\top \mathbf{y} \end{cases}$$

第一式左乘 $X_{2c}^\top X_{1c} (X_{1c}^\top X_{1c})^{-1}$ 得:

$$X_{2c}^\top X_{1c} \boldsymbol{\beta}_1 + X_{2c}^\top X_{1c} (X_{1c}^\top X_{1c})^{-1} X_{1c}^\top X_{2c} \boldsymbol{\beta}_2 = X_{2c}^\top X_{1c} (X_{1c}^\top X_{1c})^{-1} X_{1c}^\top \mathbf{y}$$

即 $X_{2c}^\top X_{1c} \boldsymbol{\beta}_1 + X_{2c}^\top P_{X_{1c}} X_{2c} \boldsymbol{\beta}_2 = X_{2c}^\top P_{X_{1c}} \mathbf{y}$, 与第二式相减(消去 $\boldsymbol{\beta}_1$)得:

$$X_{2c}^\top (I - P_{X_{1c}}) X_{2c} \boldsymbol{\beta}_2 = X_{2c}^\top (I - P_{X_{1c}}) \mathbf{y},$$

$$\Leftrightarrow X_2^\perp{}^\top X_2^\perp \boldsymbol{\beta}_2 = X_2^\perp{}^\top \mathbf{y} \Rightarrow \hat{\boldsymbol{\beta}}_2 = (X_2^\perp{}^\top X_2^\perp)^{-1} X_2^\perp{}^\top \mathbf{y}$$

证明4: 不用中心化、正交化, 应用分块矩阵的逆 (略)

例2. (命题4的 $p = 3$ 情形) 假设数据 $(y_i, x_i, z_i), i = 1, 2, \dots, n$, 满足模型:

$$y_i = a + bx_i + cz_i + \varepsilon_i, \quad \varepsilon_i \text{ iid } \sim (0, \sigma^2), \quad \varepsilon_i \text{ 与 } x_i, z_i \text{ 独立。}$$

由命题4,

$$\hat{b} = \frac{S_{xy \cdot z}}{S_{xx \cdot z}} = \frac{S_{xy} - S_{xz} S_{yz} / S_{zz}}{S_{xx} - S_{xz}^2 / S_{zz}} = \sqrt{\frac{S_{yy}}{S_{xx}}} \left(\frac{r_{yx} - r_{yz} r_{xz}}{1 - r_{xz}^2} \right) \propto r_{yx \cdot z},$$

$$\text{var}(\hat{b} | x, z) = \frac{\sigma^2}{(n-1)(S_{xx} - S_{xz}^2 / S_{zz})} = \frac{\sigma^2}{(n-1)S_{xx}} \times \frac{1}{1 - r_{xz}^2},$$

注意 $r_{xz} = 0$ 时, 方差 $\text{var}(\hat{b} | x, z) = \frac{\sigma^2}{(n-1)S_{xx}}$,


故 $VIF = \frac{1}{1 - r_{xz}^2}$ 称为方差膨胀因子(VIF: variance inflation factor)。

路径模型 (path model)

路径模型

路径模型(Path model, Sewall Wright, 1921) 是若干个有联系的线性回归模型, 表示变量之间的因果链。通常路径模型用有向树图表示, 箭头旁边的数字是回归系数/效应。

为了避免截距项的干扰, 假设所有变量都已中心化或标准化。



$$y = ax + bz + \varepsilon, \varepsilon \sim (0, \sigma^2)$$

$$x = cz + dw + \eta, \eta \sim (0, \tau^2)$$

x 是第一个模型的自变量,
是第二个模型的响应变量

基于所有变量的协方差矩阵, 可以求出路径模型中所有的参数。

路径模型的指定通常是非常困难的问题。对于有时间次序的问题, 路径模型相对容易指定。

例3. 美国社会学家布劳和邓肯(Blau & Duncan,1967; Freedman,P81-86) 研究了美国职业结构和社会阶层分化过程(social stratification)。调查对象是20000名年龄在20-64的男性的职业(分值0-96)和教育程度(分值0-8)。变量包括（按时间次序）：

当前职业Y，第一份工作W，学历U，父亲的职业X，父亲的学历 V

5个变量的样本相关系数如下。

		Y	W	U	X	V
		Son's occ	Son's 1 st job	Son's ed	Dad's occ	Dad's ed
Y	Son's occ	1.000	.541	.596	.405	.322
W	Son's 1 st job	.541	1.000	.538	.417	.332
U	Son's ed	.596	.538	1.000	.438	.453
X	Dad's occ	.405	.417	.438	1.000	.516
V	Dad's ed	.322	.332	.453	.516	1.000

按照时间次序，假设中心标准化的5个变量满足Blau-Duncan status attainment路径模型：

学历U 受到父亲的职业X和学历V的影响： $U \sim X + V$

第一份工作W受其学历和父亲的职业影响： $W \sim U + X$

职业Y受W,U,X的影响： $Y \sim W + U + X$

(1) 假设Blau–Duncan模型正确。考虑第二个方程

$$W = dU + eX + \delta, \delta \sim (0, \tau^2)$$

该模型仅涉及响应W, 自变量 $\mathbf{z} = (U, X)$, 我们仅需要考虑原始相关系数矩阵的W, U, X对应的行和列


$$S = \begin{matrix} & \begin{matrix} W & U & X \end{matrix} \\ \begin{matrix} W \\ U \\ X \end{matrix} & \begin{pmatrix} 1 & 0.538 & 0.417 \\ 0.538 & 1 & 0.438 \\ 0.417 & 0.438 & 1 \end{pmatrix} \end{matrix} = \begin{pmatrix} S_{ww} & S_{wz} \\ S_{zw} & S_{zz} \end{pmatrix}$$

$\mathbf{z} = (UX)$

$$\begin{pmatrix} \hat{d} \\ \hat{e} \end{pmatrix} = S_{zz}^{-1} S_{zw} = \begin{pmatrix} 1 & 0.438 \\ 0.438 & 1 \end{pmatrix}^{-1} \begin{pmatrix} 0.538 \\ 0.417 \end{pmatrix} = \begin{pmatrix} 0.440 \\ 0.224 \end{pmatrix}$$

$$\hat{\tau}^2 \approx S_{ww \bullet z} = S_{ww} - S_{wz} S_{zz}^{-1} S_{zw} = 1 - (0.538, 0.417) \begin{pmatrix} 0.440 \\ 0.224 \end{pmatrix} = 0.670, \quad \hat{\tau} = 0.819$$

$$R^2 = SS_{wz} S_{zz}^{-1} S_{zw} / S_{ww} = 1 - \hat{\sigma}^2 = 0.330$$



(2) $Y = aW + bU + cX + \varepsilon, \varepsilon \sim (0, \sigma^2)$, 该模型仅涉及响应 Y , 自变量 $\mathbf{x} = (W, U, X)$, 我们仅需要相关系数矩阵的前4行、列.

$$S = \begin{pmatrix} Y & W & U & X \\ 1 & 0.541 & 0.596 & 0.405 \\ 0.541 & 1 & 0.538 & 0.417 \\ 0.596 & 0.538 & 1 & 0.438 \\ 0.405 & 0.417 & 0.438 & 1 \end{pmatrix} = \begin{pmatrix} Y & \mathbf{x} = (WUX) \\ S_{yy} & S_{yx} \\ S_{xy} & S_{xx} \end{pmatrix}$$

$$\begin{pmatrix} \hat{a} \\ \hat{b} \\ \hat{c} \end{pmatrix} = S_{xx}^{-1} S_{xy} = \begin{pmatrix} 1 & 0.538 & 0.417 \\ 0.538 & 1 & 0.438 \\ 0.417 & 0.438 & 1 \end{pmatrix}^{-1} \begin{pmatrix} 0.541 \\ 0.596 \\ 0.405 \end{pmatrix} = \begin{pmatrix} 0.281 \\ 0.394 \\ 0.115 \end{pmatrix}$$

$$\hat{\sigma}^2 \approx S_{yy \bullet \mathbf{x}} = S_{yy} - S_{yx} S_{xx}^{-1} S_{xy} = 0.566, \hat{\sigma} = 0.753$$

$$R^2 = S_{yx} S_{xx}^{-1} S_{xy} / S_{yy} = 1 - \hat{\sigma}^2 = 0.434$$

