

4.12 HW 12

作业 12 链接

练习 4.1 假设 $(y_i, \mathbf{x}_i), i = 1, \dots, n$ 满足线性模型

$$y_i = \beta_0 + \mathbf{x}_i^\top \mathbf{b} + \epsilon_i, \quad \epsilon_i \sim (0, \sigma^2), \quad i = 1, \dots, n.$$

若对某个 $1 \leq k \leq n$, $y_k = \bar{y} = \sum_{i=1}^n y_i/n$, $\mathbf{x}_k = \bar{\mathbf{x}} = \sum_{i=1}^n \mathbf{x}_i/n$, 证明删除 (y_k, \mathbf{x}_k) 不影响最小二乘法。

证明 线性模型可写为 $y = X\beta + \varepsilon$, $\hat{\beta}$ 为 β 的 LS 估计

设 $\tilde{\beta}$ 为删除 (\mathbf{x}_k, y_k) 后 β 的 LS 估计, 根据 ppt week13 P29 命题 2

$$\begin{aligned}\tilde{\beta} &= \hat{\beta} - \frac{(X^\top X)^{-1} \mathbf{x}_k e_k}{1 - h_{ii}} \\ \text{其中 } e_k &= y_k - \mathbf{x}_k^\top \beta \\ &= \bar{y} - \bar{\mathbf{x}}^\top \beta \\ &= \frac{1}{n} \left(\mathbf{1}^\top \mathbf{y} - \mathbf{1}^\top \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y} \right) \\ &= \frac{1}{n} \mathbf{1}^\top (\mathbf{I} - \mathbf{P}_{\mathbf{X}}) \mathbf{y}\end{aligned}$$

由于 $\mathbf{1} \in \mathbf{C}(\mathbf{X})$, 则 $\mathbf{1}^\top (\mathbf{I} - \mathbf{P}_{\mathbf{X}}) = \mathbf{0}$, 所以 $\tilde{\beta} = \hat{\beta}$

练习 4.2 假设 $\mathbf{y}_1, \dots, \mathbf{y}_n$ iid $\sim N(\theta, \sigma^2 I_p)$, 其中 θ 为 $p \times 1$ 未知参数向量, 假设 σ^2 已知。令 $\tilde{\theta} = \lambda \bar{y}$, 其中 $0 \leq \lambda \leq 1$ 是常数。

(a) 求 $\tilde{\theta}$ 的均方误差 $m(\lambda) = E\|\tilde{\theta} - \theta\|^2$.

(b) 求 $\lambda_{opt} = \arg \min_{\lambda} m(\lambda)$ (即求使得 $m(\lambda)$ 达到最小的 λ).

(c) λ_{opt} 中含有未知 $\|\theta\|^2$, 以其无偏估计代入 (注意 $\|\bar{y}\|^2$ 不是 $\|\theta\|^2$ 的无偏估计), 得到的 $\tilde{\theta} = \hat{\lambda}_{opt} \bar{y}$ 是否等于或接近 James-Stein 估计?

解

(a) 因为

$$(i) \text{Var}(\tilde{\theta}) = \lambda^2 \text{Var}(\bar{y}) = \lambda^2 \sigma^2 I_p / n,$$

$$(ii) \text{bias} = E\tilde{\theta} - \theta = \lambda\theta - \theta$$

所以

$$m(\lambda) = E\|\tilde{\theta} - \theta\|^2 = \text{tr}(\text{Var}(\tilde{\theta})) + \|\text{bias}\|^2 = \lambda^2 \sigma^2 p / n + (\lambda - 1)^2 \|\theta\|^2$$

(b)

$$\lambda_{opt} = \underset{\lambda}{\operatorname{argmin}} m(\lambda) = \frac{\theta^\top \theta}{\frac{p\sigma^2}{n} + \theta^\top \theta}$$

(c)

$$\begin{aligned}E\|\bar{y}\|^2 &= E\bar{y}^\top \bar{y} \\ &= \frac{np\sigma^2 + n^2\theta^\top \theta}{n^2} \\ &= \frac{p\sigma^2}{n} + \theta^\top \theta\end{aligned}$$

$$\|\bar{y}\|^2 - \frac{p\sigma^2}{n} \text{ 为 } \theta^\top \theta \text{ 的无偏估计}$$

$$\begin{aligned}\tilde{\theta} &= \hat{\lambda}_{opt} \bar{y} = \frac{\|\bar{y}\|^2 - \frac{p\sigma^2}{n}}{\|\bar{y}\|^2} \bar{y} \\ &= \left(1 - \frac{p\sigma^2}{n\|\bar{y}\|^2} \right) \bar{y}\end{aligned}$$

$$\text{James - Stein 估计} \hat{\theta}_{J-S} = \left(1 - \frac{(p-2)\sigma^2}{n\|\bar{y}\|^2}\right) \bar{y}$$

练习 4.3 假设模型

$$\mathbf{y}_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \epsilon_{n \times 1}, \epsilon \sim (0, \sigma^2 I_n),$$

其中 X 的第一列为向量 $\mathbf{1}$ 。回归系数的最小二乘估计记为 $\hat{\beta} = (X^\top X)^{-1} X^\top \mathbf{y}$ 。假设有“新”数据 \mathbf{x}_0, y_0 满足模型 $y_0 = \mathbf{x}_0^\top \beta + \epsilon_0, \epsilon_0 \sim (0, \sigma^2)$, 其中 \mathbf{x}_0 已知, 需要预测 y_0 。预测统计量取为 $\hat{y}_0 = \mathbf{x}_0^\top \hat{\beta}$ 证明如下结论

(a) \hat{y}_0 的预测误差为 $pe(\hat{y}_0) = E(\hat{y}_0 - y_0)^2 = \sigma^2 [1 + \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0]$.

(b) 当 $\mathbf{x}_0 = \mathbf{x}_i$ (X 的第 i 行), $pe(\hat{y}_0) = (1 + h_{ii})\sigma^2$ 记作 $e(\mathbf{x}_i)$, 其中 h_{ii} 为 $H = X(X^\top X)^{-1} X^\top$ 的 (i, i) 元;

(c) 当 $\mathbf{x}_0 = \bar{\mathbf{x}}$, $\hat{y}_0 = \bar{y} = \mathbf{1}^\top \mathbf{y}/n$, 且 $pe(\hat{y}_0) = (1 + 1/n)\sigma^2$ 记作 $e(\bar{\mathbf{x}})$, 说明 $e(\bar{\mathbf{x}}) \leq e(\mathbf{x}_i), i = 1, \dots, n$.

(d) 当 $\mathbf{x}_0 = X^\top \mathbf{a}$ (这里 $\mathbf{a} \in R^n$), $pe(\hat{y}_0) \leq \sigma^2 (1 + \|\mathbf{a}\|^2)$.

证明

(a)

$$\begin{aligned} pe(\hat{y}_0) &= E(\hat{y}_0 - y_0)^2 \\ &= E(\mathbf{x}_0^\top \hat{\beta} - \mathbf{x}_0^\top \beta - \epsilon_0)^2 \\ &= E(\mathbf{x}_0^\top \hat{\beta} - \mathbf{x}_0^\top \beta)^2 + E\epsilon_0^2 \\ &= \text{Var}(\mathbf{x}_0^\top \hat{\beta}) + \sigma^2 \\ &= \mathbf{x}_0^\top \text{Var}(\hat{\beta}) \mathbf{x}_0 + \sigma^2 \\ &= \mathbf{x}_0^\top \text{Var}((X^\top X)^{-1} X^\top \mathbf{y}) \mathbf{x}_0 + \sigma^2 \\ &= (1 + \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0) \sigma^2 \end{aligned}$$

(b) 当 $\mathbf{x}_0 = \mathbf{x}_i$ 时,

$$\begin{aligned} \mathbf{x}_i^\top (X^\top X)^{-1} \mathbf{x}_i &= h_{ii} \\ \Rightarrow pe(\hat{y}_0) &= (1 + h_{ii})\sigma^2 \end{aligned}$$

(c) 当 $\mathbf{x}_0 = \bar{\mathbf{x}}$ 时

$$\begin{aligned} \bar{\mathbf{x}}^\top (X^\top X)^{-1} \bar{\mathbf{x}} &= \frac{1}{n^2} \mathbf{1}^\top \mathbf{X} (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{1} \\ &= \frac{1}{n^2} \mathbf{1}^\top \mathbf{P}_X \mathbf{1} \\ &= \frac{1}{n^2} \mathbf{1}^\top \mathbf{1} \\ &= \frac{1}{n} \\ pe(\hat{y}_0) &= \left(1 + \frac{1}{n}\right) \sigma^2 \end{aligned}$$

根据 ppt week 13 命题 1 可知 $h_{ii} \geq \frac{1}{n}$

所以 $e(\bar{\mathbf{x}}) \leq e(\mathbf{x}_i)$

(d) 当 $\mathbf{x}_0 = X^\top \mathbf{a}$ 时

$$\begin{aligned} pe(\hat{y}_0) &= (\mathbf{a}^\top P_X \mathbf{a} + 1) \sigma^2 \\ &= (\|P_X \mathbf{a}\|^2 + 1) \sigma^2 \\ &\leq (\|\mathbf{a}\|^2 + 1) \sigma^2 \end{aligned}$$

练习 4.4 条件同上一题, 对任何给定的 $\mathbf{x}_0 \in R^p$, 我们需要预测对应的 y_0 , 但 y_0 的预测取为 $\tilde{y}_0 = \mathbf{x}_0^\top \tilde{\beta}$, 其中 $\tilde{\beta} = \hat{\beta}\lambda, 0 \leq \lambda \leq 1$ 。

(a) 证明 \tilde{y}_0 的预测误差为

$$pe(\tilde{y}_0) = E(\tilde{y}_0 - y_0)^2 = (1 - \lambda)^2 (\mathbf{x}_0^\top \beta)^2 + \lambda^2 \sigma^2 \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0 + \sigma^2.$$

(b) 证明如果 $\|X\beta\|^2 \leq \frac{1+\lambda}{1-\lambda}\sigma^2$, 则 $pe(\tilde{y}_0) \leq pe(\hat{y}_0)$, 其中 $\hat{y}_0 = \mathbf{x}_0^\top \hat{\beta}$ 为基于 LS 估计的预测。

证明

(a)

$$\begin{aligned} \tilde{y}_0 &= \mathbf{x}_0^\top \tilde{\beta} = \lambda \mathbf{x}_0^\top \hat{\beta} \\ p(\tilde{y}_0) &= E(\tilde{y}_0 - y_0)^2 \\ &= E\left(\lambda \mathbf{x}_0^\top \hat{\beta} - \mathbf{x}_0^\top \beta - \varepsilon_0\right)^2 \\ &= E\left(\lambda \mathbf{x}_0^\top \hat{\beta} - \lambda \mathbf{x}_0^\top \beta + (\lambda - 1) \mathbf{x}_0^\top \beta - \varepsilon_0\right)^2 \\ &= \text{Var}(\lambda \mathbf{x}_0^\top \hat{\beta}) + (1 - \lambda)^2 (\mathbf{x}_0^\top \beta)^2 + E\varepsilon_0^2 \\ &= \lambda^2 \mathbf{x}_0^\top \text{Var}(\hat{\beta}) \mathbf{x}_0 + (1 - \lambda)^2 (\mathbf{x}_0^\top \beta)^2 + \sigma^2 \\ &= \lambda^2 \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0 \sigma^2 + (1 - \lambda)^2 (\mathbf{x}_0^\top \beta)^2 + \sigma^2 \end{aligned}$$

(b)

$$\begin{aligned} pe(\tilde{y}_0) &= (1 - \lambda)^2 (\mathbf{x}_0^\top \beta)^2 + \lambda^2 \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0 \sigma^2 + \sigma^2 \\ pe(\hat{y}_0) &= \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0 \sigma^2 + \sigma^2 \\ pe(\hat{y}_0) - pe(\tilde{y}_0) &= (1 - \lambda^2) \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0 \sigma^2 - (1 - \lambda)^2 (\mathbf{x}_0^\top \beta)^2. \end{aligned}$$

由于 $\beta^\top X^\top X \beta \leq \frac{1+\lambda}{1-\lambda}\sigma^2$ 和 ppt week15 p5 引理 1

$$\begin{aligned} \beta \beta^\top &\leq \frac{1+\lambda}{1-\lambda}\sigma^2 (X^\top X)^{-1} \\ \mathbf{x}_0^\top \beta \beta^\top \mathbf{x}_0 &\leq \frac{1+\lambda}{1-\lambda} \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0 \sigma^2 \\ \text{所以 } pe(\hat{y}_0) &\geq pe(\tilde{y}_0) \end{aligned}$$

练习 4.5 假设模型 $\mathbf{y}_{n \times 1} = X_{n \times p} \beta_{p \times 1} + \epsilon_{n \times 1}, \epsilon \sim (0, \sigma^2 I_n)$ 中 X, \mathbf{y} 都已经中心化 (因此模型中没有截距项), 对设计阵 X 进行奇异值分解:

$$X_{n \times p} = U_{n \times p} D_{p \times p} V_{p \times p}^\top,$$

其中 $U^\top U = I_p, V^\top V = I_p, D = \text{diag}(\sqrt{\lambda_1}, \dots, \sqrt{\lambda_p})$, 这里 $\lambda_1 \geq \dots \geq \lambda_p > 0$ 是 $X^\top X$ 的特征根。所以 $X\beta = UDV^\top \beta = U\gamma$, 其中 $\gamma = DV^\top \beta$ 。由此, 我们改写原模型为

$$\mathbf{y} = U\gamma + \epsilon, \epsilon \sim (0, \sigma^2 I_n),$$

此模型称为主成分回归模型。记 U 的各列为 $U = (\mathbf{u}_1, \mathbf{u}_2, \dots, \mathbf{u}_p)$ 。

(a) 证明主成分回归模型中回归系数 γ 的最小二乘估计为 $\hat{\gamma} = U^\top \mathbf{y}$, 由此求出原模型中的 β 的 LS 估计。

(b) 主成分回归模型中, 响应变量的基于最小二乘估计 $\hat{\gamma}$ 的拟合值向量为 $\hat{\mathbf{y}} = U\hat{\gamma} = \sum_{j=1}^p \mathbf{u}_j (\mathbf{u}_j^\top \mathbf{y})$, 求其均方误差 $m(\hat{\mathbf{y}}) = E\|\hat{\mathbf{y}} - U\gamma\|^2$.

(c) 设下标集合 $A_q = \{i_1, \dots, i_q\} \subset \{1, 2, \dots, p\}, 1 \leq q \leq p - 1$, 令

$$\tilde{\mathbf{y}}^{(A_q)} = \sum_{j \in A_q} \mathbf{u}_j (\mathbf{u}_j^\top \mathbf{y}).$$

求其均方误差 $m(\tilde{\mathbf{y}}^{(A_q)}) = E\|\tilde{\mathbf{y}}^{(A_q)} - U\gamma\|^2$ 。假设 $\|\gamma\|^2 \leq \sigma^2$, 证明

$$m(\tilde{\mathbf{y}}^{(A_q)}) \leq m(\hat{\mathbf{y}}).$$

(d) 写出 C_q 准则的具体表达, 给出最优子集搜索算法。

解

(a)

$$\begin{aligned}
\hat{\gamma} &= (U^\top U)^{-1} U^\top y \\
&= U^\top y \\
&= DV^\top \beta \\
X\beta &= U\hat{\gamma} \\
&= UU^\top y \\
X(X^\top X)^{-1}X^\top &= UDV^\top (VDU^\top UDV^\top)^{-1} VDU^\top \\
&= UU^\top \\
\Rightarrow X\beta &= X(X^\top X)^{-1}X^\top y \\
\hat{\beta} &= (X^\top X)^{-1}X^\top y
\end{aligned}$$

(b)

$$\begin{aligned}
m(\hat{y}) &= E\|\hat{y} - U\gamma\|^2 \\
&= E\|UU^\top y - U\gamma\|^2 \\
&= E\|UU^\top(y - U\gamma)\|^2 \\
&= E\|UU^\top\varepsilon\|^2 \\
&= E(\varepsilon^\top UU^\top\varepsilon) \\
&= \text{tr}(UU^\top)\sigma^2 \\
&= \text{tr}(U^\top U)\sigma^2 \\
&= p\sigma^2
\end{aligned}$$

(c)

$$\begin{aligned}
\tilde{y}^{(A_q)} &= \sum_{j \in A_q} u_j (u_j^\top y) \\
m(\tilde{y}^{(A_q)}) &= E \left\| \sum_{j \in A_q} u_j (u_j^\top y) - \sum_{i=1}^p u_i \gamma_i \right\|^2 \\
&= E \left\| \sum_{j \in A_q} u_j \hat{\gamma}_j - \sum_{i=1}^p u_i \gamma_i \right\|^2 \\
&= E \left\| \sum_{j \in A_q} u_j (\hat{\gamma}_j - \gamma_j) - \sum_{i \notin A_q} u_i \gamma_i \right\|^2 \\
&= E \left\| \sum_{j \in A_q} u_j (\hat{\gamma}_j - \gamma_j) \right\|^2 + E \left\| \sum_{i \notin A_q} u_i \gamma_i \right\|^2 \\
&= E \left(\sum_{j \in A_q} u_j (\hat{\gamma}_j - \gamma_j) \right)^\top \left(\sum_{j \in A_q} u_j (\hat{\gamma}_j - \gamma_j) \right) + \sum_{i \notin A_q} \gamma_i^2 \\
&= \sum_{j \in A_q} E \|\hat{\gamma}_j - \gamma_j\|^2 + \sum_{i \notin A_q} \gamma_i^2 \\
&= \sum_{j \in A_q} E \varepsilon^\top u_j u_j^\top \varepsilon + \sum_{i \notin A_q} \gamma_i^2 \\
&\leq q\sigma^2 + \|\gamma\|^2 \\
&\leq (q+1)\sigma^2 \leq p\sigma^2 = m(\hat{y})
\end{aligned}$$

(d)

$$\begin{aligned}
C_q &= \frac{RSS_q}{\hat{\sigma}^2} - n + 2q \\
\text{其中 } \hat{\sigma}^2 &= \frac{RSS_p}{x-p} \\
RSS_q &= \left\| y - \tilde{y}^{(A_q)} \right\|^2 \\
&= \|y\|^2 - \sum_{j \in A_q} (u_j^\top y)^2 \\
RSS_p &= \|y - \hat{y}\|^2 \\
&= \|y\|^2 - \sum_{j=1}^p (u_j^\top y)^2 \\
C_q &= \frac{\|y\|^2 - \sum_{j \in A_q} (u_j^\top y)^2}{\|y\|^2 - \sum_{j=1}^p (u_j^\top y)^2} (n-p) - n + 2q
\end{aligned}$$

1. 计算 $u_j^\top y, j = 1, \dots, p$, 并排序 $u_{i_1}^\top y \leq \dots \leq u_{i_p}^\top y$ 2. $q^* = \arg \min_q = \frac{\|y\|^2 - \sum_{j \in A_q} (u_j^\top y)^2}{\hat{\sigma}^2} (n-p) - n + 2q$ 3. $A_{q^*} = \{i_1, \dots, i_{q^*}\}$