

作业 14

1. 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 $\tilde{\theta} = \lambda \bar{\mathbf{y}}$, 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 $\|\bar{\mathbf{y}}\|^2$ 不是 $\|\theta\|^2$ 的无偏估计), 得到的 $\tilde{\theta} = \hat{\lambda}_{opt} \bar{\mathbf{y}}$ 是否等于或接近 James-Stein 估计?
2. 假设二维数据 $(x_i, y_i), i = 1, 2, \dots, n$ 满足简单线性回归模型

$$y_i = a + bx_i + \epsilon_i, \quad \epsilon \sim (0, \sigma^2),$$

最小二乘法拟合得到 LS 估计 \hat{a}, \hat{b} . 假设 (x_0, y_0) 也来自于同一模型, 即

$$y_0 = a + bx_0 + \epsilon_0, \quad \epsilon \sim (0, \sigma^2),$$

且 y_0 与 $y_i, i = 1, 2, \dots, n$ 独立。我们需要预测 x_0 所对应的 y_0 。取预测统计量为

$$\tilde{y}_0 = \tilde{a} + \tilde{b}x_0,$$

其中 $\tilde{b} = \lambda \hat{b}, \tilde{a} = \bar{y} - \tilde{b}\bar{x}, 0 \leq \lambda \leq 1$ 为常数。

- (a) 证明 \tilde{y}_0 的预测误差 $e(\lambda) = E(\tilde{y}_0 - y_0)^2 = \frac{n+1}{n} \sigma^2 + (x_0 - \bar{x})^2 \left\{ \frac{\lambda^2 \sigma^2}{s_{xx}} + (1 - \lambda)^2 b^2 \right\}$.
- (b) 说明何时 \tilde{y}_0 的预测效果好于 $\hat{y}_0 = \hat{a} + \hat{b}x_0$.
3. 假设模型

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

其中 X 的第一列为向量 1. 回归系数的最小二乘估计记为 $\hat{\boldsymbol{\beta}} = (X^\top X)^{-1} X^\top \mathbf{y}$ 。假设有“新”数据 \mathbf{x}_0, y_0 满足模型 $y_0 = \mathbf{x}_0^\top \boldsymbol{\beta} + \epsilon_0, \epsilon_0 \sim (0, \sigma^2)$, 其中 \mathbf{x}_0 已知, 需要预测 y_0 。预测统计量取为 $\hat{y}_0 = \mathbf{x}_0^\top \hat{\boldsymbol{\beta}}$ 。证明 \hat{y}_0 的预测误差为 $pe(\hat{y}_0) = E(\hat{y}_0 - y_0)^2 = \sigma^2 [1 + \mathbf{x}_0^\top (X^\top X)^{-1} \mathbf{x}_0]$ 。由此说明

- (a) 当 $\mathbf{x}_0 = \mathbf{x}_i$ (即 X 的第 i 行) 时, $pe(\hat{y}_0) = (1 + h_{ii})\sigma^2$ 记作 $e(\mathbf{x}_i)$, 其中 h_{ii} 为 $H = X(X^\top X)^{-1} X^\top$ 的 (i, i) 元;
- (b) 当 $\mathbf{x}_0 = \bar{\mathbf{x}} = \mathbf{1}^\top / n$ 时, $\hat{y}_0 = \bar{y} = \mathbf{1}^\top \mathbf{y} / n$, 且 $pe(\hat{y}_0) = (1 + 1/n)\sigma^2$, 说明 $pe(\bar{\mathbf{x}}) \leq e(\mathbf{x}_i), i = 1, \dots, n$.
- (c) 当 $\mathbf{x}_0 = X^\top \mathbf{a}$ 时 (这里 $\mathbf{a} \in R^n$), $pe(\hat{y}_0) \leq \sigma^2(1 + \|\mathbf{a}\|^2)$.
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 $\tilde{y}_0 = \mathbf{x}_0^\top \tilde{\boldsymbol{\beta}}$, 其中 $\tilde{\boldsymbol{\beta}} = \hat{\boldsymbol{\beta}}\lambda, 0 \leq \lambda \leq 1$ 。

- (a) 证明 \tilde{y}_0 的预测误差为

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

- (b) 如果 $\|X\boldsymbol{\beta}\|^2 \leq \frac{1+\lambda}{1-\lambda} \sigma^2$, 则 $pe(\tilde{y}_0) \leq pe(\hat{y}_0)$, 其中 $\hat{y}_0 = \mathbf{x}_0^\top \hat{\boldsymbol{\beta}}$ 为基于 LS 估计的预测 (参见上一题)。

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（搜索所有可能的子集 $A_q, q = 0, 1, \dots, p$ ）的快速算法。