

作业 5

1. 若 $\mathbf{x}_{m \times 1}, \mathbf{y}_{n \times 1}$ 为任意两个随机向量, $E(\mathbf{y}|\mathbf{x})$ 称为回归函数, 记 $\boldsymbol{\epsilon} = \mathbf{y} - E(\mathbf{y}|\mathbf{x})$.

- (a) 证明 $\boldsymbol{\epsilon}$ 与 \mathbf{x} 不相关 (因此, \mathbf{y} 可分解为两个不相关的部分: $\mathbf{y} = E(\mathbf{y}|\mathbf{x}) + \boldsymbol{\epsilon}$).
- (b) 利用 (a) 的结果证明 $\min_{f: R^m \rightarrow R^n} E\|\mathbf{y} - f(\mathbf{x})\|^2 = E\|\mathbf{y} - E(\mathbf{y}|\mathbf{x})\|^2$ (提示: 首先证明 $\hat{f}(\mathbf{x}) = E(\mathbf{y}|\mathbf{x})$ 极小化给定 \mathbf{x} 条件下的条件期望 $E(\|\mathbf{y} - f(\mathbf{x})\|^2|\mathbf{x})$).
- (c) 利用 (a) 的结果证明方差矩阵分解公式: $\text{var}(\mathbf{y}) = \text{var}[E(\mathbf{y}|\mathbf{x})] + E[\text{var}(\mathbf{y}|\mathbf{x})]$ (提示: 只需证明 $\text{var}(\boldsymbol{\epsilon}) = E[\text{var}(\mathbf{y}|\mathbf{x})]$).
- (d) 假设 $\mathbf{x}, \mathbf{y}, \mathbf{z}$ 是三个随机向量, 证明

$$\text{cov}(\mathbf{x}, \mathbf{y}) = \text{cov}[E(\mathbf{x}|\mathbf{z}), E(\mathbf{y}|\mathbf{z})] + E[\text{cov}(\mathbf{x}, \mathbf{y}|\mathbf{z})].$$

2. 假设 y 是一元响应变量, \mathbf{x} 是 q 元随机向量, \mathbf{z} 是 $(p-q) \times 1$ 随机向量, 都是可观测变量。我们感兴趣的问题是研究 y 与 \mathbf{x} 的关系, 而 \mathbf{z} 是干扰因素 (既与 y 有关也与 \mathbf{x} 有关), 需要加以控制。假设如下线性模型

$$y = a + \mathbf{b}^T \mathbf{x} + \mathbf{c}^T \mathbf{z} + \epsilon, \quad \epsilon \sim (0, \sigma^2), \epsilon \perp\!\!\!\perp \mathbf{x}, \mathbf{z} \quad (1)$$

问题是, 该模型是否正确地实现了目标 “在控制 \mathbf{z} 的条件下, 研究 y 与 \mathbf{x} 的关系”?

为了考察模型 (1) 中加项 $\mathbf{c}^T \mathbf{z}$ 的作用, 以及考察系数 \mathbf{b} 的含义, 我们令

$$\mathbf{y}^\perp = y - \Sigma_{yz} \Sigma_{zz}^{-1} \mathbf{z}, \quad \mathbf{x}^\perp = \mathbf{x} - \Sigma_{xz} \Sigma_{zz}^{-1} \mathbf{z},$$

则可以证明模型 (1) 蕴含了

$$\mathbf{y}^\perp = a + \mathbf{b}^T \mathbf{x}^\perp + \epsilon, \quad \epsilon \sim (0, \sigma^2), \epsilon \perp\!\!\!\perp \mathbf{x}^\perp. \quad (2)$$

这说明模型 (1) 中线性项 $\mathbf{c}^T \mathbf{z}$ 确实起到了控制 (或消除) \mathbf{z} 影响的作用。进一步, 可以证明

$$\mathbf{b} = \Sigma_{xx \bullet z}^{-1} \Sigma_{xy \bullet z}, \quad (3)$$

特别地, 当 $q=1$ 时, $b \propto \rho_{xy \bullet z}$ 。结果 (4) 说明了模型 (2) 中 \mathbf{x} 的系数 \mathbf{b} 确实代表了偏相关系数, 干扰因素的影响通过在模型 (1) 添加 $\mathbf{c}^T \mathbf{z}$ 得到了消除。

另一方面, 假设模型确实是正确模型, 但假如我们没有意识到 \mathbf{z} 是一个潜在的干扰因素, 并假设模型

$$y = \alpha + \boldsymbol{\beta}^T \mathbf{x} + \delta, \quad \delta \sim (0, \tau^2), \delta \perp\!\!\!\perp \mathbf{x} \quad (4)$$

也就是说, 我们将模型 (1) 中的 $\mathbf{c}^T \mathbf{z}$ 一项归入了误差项:

$$\delta = \epsilon + \mathbf{c}^T \mathbf{z} - E(\mathbf{c}^T \mathbf{z}),$$

其中最后一项 $-E(\mathbf{c}^T \mathbf{z})$ 是为了保证 $E(\delta) = 0$, 而 $\alpha = a + E(\mathbf{c}^T \mathbf{z})$, $\boldsymbol{\beta} = \mathbf{b}$ 。显然 δ 与 \mathbf{x} 不独立, 那么基于错误模型 (4), 由课件命题 2

$$\mathbf{b} = \boldsymbol{\beta} = \Sigma_{xx}^{-1} \Sigma_{xy}, \quad (5)$$

与 (3) 相比, 这个表达没有控制 \mathbf{z} , 因而是错误的表达。

本题的任务是, 假设模型 (1) 是正确模型, 证明 (2) 和 (3)。