

4.5 HW 5

作业 5 链接

练习 4.1 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

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

证明

(a)

$$\begin{aligned} & \text{Cov}(\boldsymbol{\epsilon}, \mathbf{x}) \\ &= \text{Cov}(\mathbf{y} - E(\mathbf{y} | \mathbf{x}), \mathbf{x}) \\ &= E((\mathbf{y} - E(\mathbf{y} | \mathbf{x}))\mathbf{x}^\top) - E(\mathbf{y} - E(\mathbf{y} | \mathbf{x}))E\mathbf{x}^\top \\ &= E((\mathbf{y} - E(\mathbf{y} | \mathbf{x}))\mathbf{x}^\top) \\ &= 0 \quad (\text{根据条件期望定义}) \end{aligned}$$

(b)

$$\begin{aligned} & E(\|\mathbf{y} - f(\mathbf{x})\|^2 | \mathbf{x}) \\ &= E(\|\mathbf{y} - E(\mathbf{y} | \mathbf{x}) + E(\mathbf{y} | \mathbf{x}) - f(\mathbf{x})\|^2 | \mathbf{x}) \end{aligned}$$

$$\text{记 } \boldsymbol{\epsilon} = \mathbf{y} - E(\mathbf{y} | \mathbf{x})$$

由于 $\boldsymbol{\epsilon}$ 与 \mathbf{x} 不相关

$$\begin{aligned} & \Rightarrow \text{Cov}(\boldsymbol{\epsilon}, E(\mathbf{y} | \mathbf{x}) - f(\mathbf{x})) = 0 \\ & \Rightarrow E(\boldsymbol{\epsilon}(E(\mathbf{y} | \mathbf{x}) - f(\mathbf{x}))^\top) = 0 \end{aligned}$$

$$\begin{aligned} & E(\|\mathbf{y} - f(\mathbf{x})\|^2 | \mathbf{x}) \\ &= E(\|\boldsymbol{\epsilon}\|^2 | \mathbf{x}) + E(\|E(\mathbf{y} | \mathbf{x}) - f(\mathbf{x})\|^2 | \mathbf{x}) \\ &= E(\|\boldsymbol{\epsilon}\|^2 | \mathbf{x}) + \|E(\mathbf{y} | \mathbf{x}) - f(\mathbf{x})\|^2 \\ &\geq E(\|\boldsymbol{\epsilon}\|^2 | \mathbf{x}) \end{aligned}$$

$$\begin{aligned} & E\|\mathbf{y} - f(\mathbf{x})\|^2 \\ &= E(E(\|\mathbf{y} - f(\mathbf{x})\|^2 | \mathbf{x})) \\ &\geq E(E(\|\boldsymbol{\epsilon}\|^2 | \mathbf{x})) \\ &= E\|\boldsymbol{\epsilon}\|^2 \end{aligned}$$

当且仅当 $f(\mathbf{x}) = E(\mathbf{y} | \mathbf{x})$

(c)

$$\begin{aligned}
& \text{Var}(\varepsilon) \\
&= E(\varepsilon\varepsilon^\top) - (E\varepsilon)(E\varepsilon)^\top \\
&= E(E(\varepsilon\varepsilon^\top | x)) \\
&= E((y - E(y|x))(y - E(y|x))^\top | x) \\
&= E(E(yy^\top + E(y|x)E(y|x)^\top - 2yE(y|x)^\top | x)) \\
&= E(E(yy^\top | x) + E(y|x)E(y|x)^\top - 2E(y|x)E(y|x)^\top) \\
&= E(E(yy^\top | x) - E(y|x)E(y|x)^\top) \\
&= E(\text{Var}(y | x))
\end{aligned}$$

(d)

$$\begin{aligned}
& \text{Cov}(E(x | z), E(y | z)) \\
&= E(E(x | z)E(y | z)^\top) - ExEy^\top \\
& \\
& E(\text{Cov}(x, y | z)) \\
&= E(E(xy^\top | z) - E(x | z)E(y | z)^\top) \\
&= Exy^\top - E(E(x | z)E(y | z)^\top) \\
& \\
& \text{Cov}(E(x | z), E(y | z)) + E(\text{Cov}(x, y | z)) \\
&= Exy^\top - ExEy^\top \\
&= \text{Cov}(x, y)
\end{aligned}$$

练习 4.2 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

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

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 $\mathbf{c}^\top \mathbf{z}$ 的作用, 以及考察系数 \mathbf{b} 的含义, 我们令

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

则可以证明模型 (1) 蕴含了

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

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

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

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 $\mathbf{c}^\top \mathbf{z}$ 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

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

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

$$\delta = \varepsilon + \mathbf{c}^\top \mathbf{z} - E(\mathbf{c}^\top \mathbf{z})$$

其中最后一项 $-E(\mathbf{c}^\top \mathbf{z})$ 是为了保证 $E(\delta) = 0$, 而 $\alpha = a + E(\mathbf{c}^\top \mathbf{z})$, $\beta = \mathbf{b}$ 。显然 δ 与 \mathbf{x} 不独立, 那么基于

错误模型 (4), 由课件命题 2

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

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)。

证明

(2)

$$\begin{aligned} y^\perp &= y - \Sigma_{yz} \Sigma_{zz}^{-1} z \\ &= a + b^\top x + c^\top z + \varepsilon - \Sigma_{yz} \Sigma_{zz}^{-1} z \\ &= a + b^\top (x^\perp + \Sigma_{xz} \Sigma_{zz}^{-1} z) + c^\top z + \varepsilon - \Sigma_{yz} \Sigma_{zz}^{-1} z \\ &= a + b^\top x^\perp + \varepsilon + c'^\top z \end{aligned}$$

由于 $y^\perp x^\perp, \varepsilon$ 与 z 不相关

$$\Rightarrow c' = 0, \quad \varepsilon \perp x^\perp$$

$$\Rightarrow y^\perp = a + b^\top x^\perp + \varepsilon$$

(3)

$\varepsilon = y^\perp - a - b^\top x^\perp$ 与 x^\perp 不相关

$$\text{Cov}(\varepsilon, x^\perp) = 0$$

$$\Sigma_{yx \cdot z} - b^\top \Sigma_{xx \cdot z} = 0$$

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