

- $y = f(x) + e$, $f(x) = a + bx$.
- 最小二乘拟合系数、最大似然估计、最优线性无偏估计:

$$\hat{a} = \bar{y} - \hat{b}\bar{x}, \quad \hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\ell_{xy}}{\ell_{xx}}.$$
- 残差平方和: $Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=3}^n Z_i^2$,
 回归平方和: $U = \sum_i (\hat{y}_i - \bar{y})^2 = (\sqrt{\ell_{xx}}b + Z_2)^2$,
- $\frac{1}{\sigma^2}Q \sim \chi^2(n-2)$, $\frac{1}{\sigma^2}U_0 \sim \chi^2(1)$, 在某种意义上, $U_0 \leq U_b$.

- $y = f(x) + e$, $f(x) = a + bx$.
- 最小二乘拟合系数、最大似然估计、最优线性无偏估计:

$$\hat{a} = \bar{y} - \hat{b}\bar{x}, \quad \hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{\ell_{xy}}{\ell_{xx}}.$$
- 残差平方和: $Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=3}^n Z_i^2$,
 回归平方和: $U = \sum_i (\hat{y}_i - \bar{y})^2 = (\sqrt{\ell_{xx}}b + Z_2)^2$,
- $\frac{1}{\sigma^2}Q \sim \chi^2(n-2)$, $\frac{1}{\sigma^2}U_0 \sim \chi^2(1)$, 在某种意义上, $U_0 \leq U_b$.
- Q 与 U 相互独立.

- $y = f(x) + e, f(x) = a + bx.$
- 最小二乘拟合系数、最大似然估计、最优线性无偏估计:

$$\hat{a} = \bar{y} - \hat{b}\bar{x}, \quad \hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{l_{xy}}{l_{xx}}.$$
- 残差平方和: $Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=3}^n Z_i^2,$
 回归平方和: $U = \sum_i (\hat{y}_i - \bar{y})^2 = (\sqrt{l_{xx}}b + Z_2)^2,$
- $\frac{1}{\sigma^2}Q \sim \chi^2(n-2), \quad \frac{1}{\sigma^2}U_0 \sim \chi^2(1),$ 在某种意义上, $U_0 \leq U_b.$
- Q 与 U 相互独立.
- 直观: $Q, U, l_{yy} = \sum_i (y_i - \bar{y})^2$ 都是 $N(0, *)$ 的平方和.
 l_{yy} : 自由度为 $n-1$ (1个约束条件 $\sum_i (y_i - \bar{y}) = 0$).
 U : 自由度(维数)为1, $\hat{y}_i - \bar{y} = \hat{b}(x_i - \bar{x}).$
 $Q = l_{yy} - U$: 自由度为 $(n-1) - 1 = n-2.$

假设检验问题 $H_0 : b = 0 \leftrightarrow H_1 : b \neq 0$.

假设检验问题 $H_0 : b = 0 \leftrightarrow H_1 : b \neq 0$.

- 否定 H_0 , 则表明 y 与 x 之间有线性依赖关系.

假设检验问题 $H_0 : b = 0 \leftrightarrow H_1 : b \neq 0$.

- 否定 H_0 , 则表明 y 与 x 之间有线性依赖关系.
- 若 H_0 成立, 则 $\frac{1}{\sigma^2}Q \sim \chi^2(n-2)$, $\frac{1}{\sigma^2}U \sim \chi^2(1)$,
 $\frac{U}{Q/(n-2)} \sim F(1, n-2)$.
- 否定域: $W = \{(\vec{x}, \vec{y}) : \frac{U}{Q/(n-2)} > \lambda\}$.
在某种意义上, $U_0 \leq U_b$.

假设检验问题 $H_0 : b = 0 \leftrightarrow H_1 : b \neq 0$.

- 否定 H_0 , 则表明 y 与 x 之间有线性依赖关系.
- 若 H_0 成立, 则 $\frac{1}{\sigma^2}Q \sim \chi^2(n-2)$, $\frac{1}{\sigma^2}U \sim \chi^2(1)$,
 $\frac{U}{Q/(n-2)} \sim F(1, n-2)$.
- 否定域: $W = \{(\vec{x}, \vec{y}) : \frac{U}{Q/(n-2)} > \lambda\}$.
在某种意义上, $U_0 \leq U_b$.
- 根据水平 α 选择 λ . $P(F_{1, n-2} > \lambda) = \alpha$.

例2.1. 根据散点图建立函数关系 $y = e^a e^{bx}$,

即回归关系式 $z = \log y = a + bx + e$.

$x =$ 注射后天数, $y =$ 金残留量.

例2.1. 根据散点图建立函数关系 $y = e^a e^{bx}$,

即回归关系式 $z = \log y = a + bx + e$.

$x =$ 注射后天数, $y =$ 金残留量.

- $n = 7$, 数据 $(x_i, y_i \rightarrow z_i = \log y_i), i = 1, \dots, 7$.

例2.1. 根据散点图建立函数关系 $y = e^a e^{bx}$,

即回归关系式 $z = \log y = a + bx + e$.

$x =$ 注射后天数, $y =$ 金残留量.

- $n = 7$, 数据 $(x_i, y_i \rightarrow z_i = \log y_i), i = 1, \dots, 7$.
- 求 $\bar{x}, \bar{z}; \hat{b} = \frac{\ell_{xz}}{\ell_{xx}}, \hat{a} = \bar{z} - \hat{b}\bar{x}$.
以及 $\hat{z}_i = \hat{a} + \hat{b}x_i$.

例2.1. 根据散点图建立函数关系 $y = e^a e^{bx}$,

即回归关系式 $z = \log y = a + bx + e$.

$x =$ 注射后天数, $y =$ 金残留量.

• $n = 7$, 数据 $(x_i, y_i \rightarrow z_i = \log y_i), i = 1, \dots, 7$.

• 求 $\bar{x}, \bar{z}; \hat{b} = \frac{\ell_{xz}}{\ell_{xx}}, \hat{a} = \bar{z} - \hat{b}\bar{x}$.

以及 $\hat{z}_i = \hat{a} + \hat{b}x_i$.

• 求残差平方和: $Q = \sum_i (z_i - \hat{z}_i)^2$

与回归平方和: $U = \sum_i (\hat{z}_i - \bar{z})^2$.

例2.1. 根据散点图建立函数关系 $y = e^a e^{bx}$,

即回归关系式 $z = \log y = a + bx + e$.

$x =$ 注射后天数, $y =$ 金残留量.

- $n = 7$, 数据 $(x_i, y_i \rightarrow z_i = \log y_i), i = 1, \dots, 7$.
- 求 $\bar{x}, \bar{z}; \hat{b} = \frac{\ell_{xz}}{\ell_{xx}}, \hat{a} = \bar{z} - \hat{b}\bar{x}$.
以及 $\hat{z}_i = \hat{a} + \hat{b}x_i$.
- 求残差平方和: $Q = \sum_i (z_i - \hat{z}_i)^2$
与回归平方和: $U = \sum_i (\hat{z}_i - \bar{z})^2$.
- 根据 $P(F_{1, n-2} = F_{1,5} > \lambda) = \alpha = 0.05$, 查表得 $\lambda = 6.61$.
 $\frac{U}{Q/(n-2)} = 344.82 > \lambda$ 否定 H_0 , 强烈认可 z 线性依赖于 x .

例2.1. 根据散点图建立函数关系 $y = e^a e^{bx}$,

即回归关系式 $z = \log y = a + bx + e$.

$x =$ 注射后天数, $y =$ 金残留量.

- $n = 7$, 数据 $(x_i, y_i \rightarrow z_i = \log y_i), i = 1, \dots, 7$.
- 求 $\bar{x}, \bar{z}; \hat{b} = \frac{\ell_{xz}}{\ell_{xx}}, \hat{a} = \bar{z} - \hat{b}\bar{x}$.
以及 $\hat{z}_i = \hat{a} + \hat{b}x_i$.
- 求残差平方和: $Q = \sum_i (z_i - \hat{z}_i)^2$
与回归平方和: $U = \sum_i (\hat{z}_i - \bar{z})^2$.
- 根据 $P(F_{1,n-2} = F_{1,5} > \lambda) = \alpha = 0.05$, 查表得 $\lambda = 6.61$.
 $\frac{U}{Q/(n-2)} = 344.82 > \lambda$ 否定 H_0 , 强烈认可 z 线性依赖于 x .
- 自习图9.9.2 ~ 9.2.5.

§9.3 多元线性回归

§9.3 多元线性回归

- 函数关系: $y = a + b_1x_1 + \cdots + b_px_p + e = a + \mathbf{x}\mathbf{b} + e$.
 $\mathbf{x} = (x_1, \cdots, x_p)$ 行向量, $\mathbf{b} = (b_1, \cdots, b_p)^T$ 列向量.

§9.3 多元线性回归

- 函数关系: $y = a + b_1x_1 + \cdots + b_px_p + e = a + \mathbf{x}\mathbf{b} + e$.
 $\mathbf{x} = (x_1, \cdots, x_p)$ 行向量, $\mathbf{b} = (b_1, \cdots, b_p)^T$ 列向量.
- 数据: y_i ; $\mathbf{x}_i = (x_{i1}, \cdots, x_{ip})$, $i = 1, \cdots, n$.
均值: \bar{y} ; $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$.

§9.3 多元线性回归

- 函数关系: $y = a + b_1x_1 + \cdots + b_px_p + e = a + \mathbf{x}\mathbf{b} + e$.
 $\mathbf{x} = (x_1, \cdots, x_p)$ 行向量, $\mathbf{b} = (b_1, \cdots, b_p)^T$ 列向量.
- 数据: y_i ; $\mathbf{x}_i = (x_{i1}, \cdots, x_{ip})$, $i = 1, \cdots, n$.
均值: \bar{y} ; $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$.
- 回归模型: $y_i = a + \mathbf{x}_i\mathbf{b} + e_i$, $e_1, \cdots, e_n \sim \text{i.i.d. } N(0, \sigma^2)$.
 $\mathbf{y} = a\mathbf{1} + \mathbf{X}\mathbf{b} + \mathbf{e}$, 其中 $\mathbf{y} = (y_i)_{n \times 1}$, $\mathbf{X} = (x_{ij})_{n \times p}$.

§9.3 多元线性回归

- 函数关系: $y = a + b_1x_1 + \cdots + b_px_p + e = a + \mathbf{x}\mathbf{b} + e$.
 $\mathbf{x} = (x_1, \cdots, x_p)$ 行向量, $\mathbf{b} = (b_1, \cdots, b_p)^T$ 列向量.
- 数据: y_i ; $\mathbf{x}_i = (x_{i1}, \cdots, x_{ip})$, $i = 1, \cdots, n$.
均值: \bar{y} ; $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$.
- 回归模型: $y_i = a + \mathbf{x}_i\mathbf{b} + e_i$, $e_1, \cdots, e_n \sim \text{i.i.d. } N(0, \sigma^2)$.
 $\mathbf{y} = a\mathbf{1} + \mathbf{X}\mathbf{b} + \mathbf{e}$, 其中 $\mathbf{y} = (y_i)_{n \times 1}$, $\mathbf{X} = (x_{ij})_{n \times p}$.
- 最小二乘、最优(定理3.1,3.3):
 $\hat{a} = \bar{y} - \hat{b}\bar{x} \longrightarrow \bar{y} - \mathbf{X}\hat{\mathbf{b}}$,
 $\hat{\mathbf{b}} = \frac{1}{\ell_{xx}} \ell_{xy} \longrightarrow (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{y}} = (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{y}$,
 $\tilde{\mathbf{x}}_i = \mathbf{x}_i - \bar{\mathbf{x}}$, $\tilde{\mathbf{y}} = \mathbf{y} - \bar{y}\mathbf{1}$. $\tilde{\mathbf{X}}^T \mathbf{1} = \mathbf{0}$.

§9.3 多元线性回归

- 函数关系: $y = a + b_1x_1 + \cdots + b_px_p + e = a + \mathbf{x}\mathbf{b} + e$.
 $\mathbf{x} = (x_1, \cdots, x_p)$ 行向量, $\mathbf{b} = (b_1, \cdots, b_p)^T$ 列向量.
- 数据: y_i ; $\mathbf{x}_i = (x_{i1}, \cdots, x_{ip})$, $i = 1, \cdots, n$.
均值: \bar{y} ; $\bar{\mathbf{x}} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i$.
- 回归模型: $y_i = a + \mathbf{x}_i\mathbf{b} + e_i$, $e_1, \cdots, e_n \sim \text{i.i.d. } N(0, \sigma^2)$.
 $\mathbf{y} = a\mathbf{1} + \mathbf{X}\mathbf{b} + \mathbf{e}$, 其中 $\mathbf{y} = (y_i)_{n \times 1}$, $\mathbf{X} = (x_{ij})_{n \times p}$.
- 最小二乘、最优(定理3.1,3.3):
 $\hat{a} = \bar{y} - \hat{b}\bar{x} \longrightarrow \bar{y} - \mathbf{X}\hat{\mathbf{b}}$,
 $\hat{\mathbf{b}} = \frac{1}{\ell_{xx}} \ell_{xy} \longrightarrow (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{y}} = (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{y}$,
 $\tilde{\mathbf{x}}_i = \mathbf{x}_i - \bar{\mathbf{x}}$, $\tilde{\mathbf{y}} = \mathbf{y} - \bar{y}\mathbf{1}$. $\tilde{\mathbf{X}}^T \mathbf{1} = 0$.
- $\hat{\mathbf{b}} = (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{X}\mathbf{b} + (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{e}$

假设检验 $H_0 : \mathbf{b} = 0 \leftrightarrow H_1 : \mathbf{b} \neq 0$.

假设检验 $H_0 : \mathbf{b} = 0 \leftrightarrow H_1 : \mathbf{b} \neq 0$.

- $\hat{y}_i - \bar{y} = \hat{b}(x_i - \bar{x}) \longrightarrow (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}$

$$U = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \sum_{i=1}^n ((\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}})^2 = \|\tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

自由度(维数)为 p : $\hat{y}_i - \bar{y} = \sum_{j=1}^p \hat{b}_j (x_{ij} - (\bar{\mathbf{x}})_j)$.

假设检验 $H_0 : \mathbf{b} = 0 \leftrightarrow H_1 : \mathbf{b} \neq 0$.

- $\hat{y}_i - \bar{y} = \hat{b}(x_i - \bar{x}) \longrightarrow (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}$

$$U = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \sum_{i=1}^n ((\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}})^2 = \|\tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

自由度(维数)为 p : $\hat{y}_i - \bar{y} = \sum_{j=1}^p \hat{b}_j (x_{ij} - (\bar{\mathbf{x}})_j)$.

- $\frac{1}{\sigma^2} U \stackrel{H_0}{\sim} \chi^2(p)$.

$$\tilde{\mathbf{X}}\hat{\mathbf{b}} \stackrel{H_0}{=} \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{e}.$$

$$\frac{1}{\sigma^2} EU = \text{Tr}(\tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T) =$$

$$\text{Tr}(\underline{(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}} (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}}_{p \times p}) = \text{Tr}(\mathbf{I})_{p \times p} = p.$$

假设检验 $H_0 : \mathbf{b} = 0 \leftrightarrow H_1 : \mathbf{b} \neq 0$.

- $\hat{y}_i - \bar{y} = \hat{b}(x_i - \bar{x}) \longrightarrow (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}$

$$U = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \sum_{i=1}^n ((\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}})^2 = \|\tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

自由度(维数)为 p : $\hat{y}_i - \bar{y} = \sum_{j=1}^p \hat{b}_j (x_{ij} - (\bar{\mathbf{x}})_j)$.

- $\frac{1}{\sigma^2} U \stackrel{H_0}{\sim} \chi^2(p)$.

$$\tilde{\mathbf{X}}\hat{\mathbf{b}} \stackrel{H_0}{=} \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{e}.$$

$$\frac{1}{\sigma^2} EU = \text{Tr}(\tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T) =$$

$$\text{Tr}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}_{p \times p} = \text{Tr}(\mathbf{I})_{p \times p} = p.$$

- $\frac{1}{\sigma^2} Q \sim \chi^2(n - 1 - p)$.

$$y_i - \hat{y}_i = (y_i - \bar{y}) - (\hat{y}_i - \bar{y}) = \tilde{y}_i - (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}.$$

$$Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \|\tilde{\mathbf{y}} - \tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

假设检验 $H_0 : \mathbf{b} = 0 \leftrightarrow H_1 : \mathbf{b} \neq 0$.

- $\hat{y}_i - \bar{y} = \hat{b}(x_i - \bar{x}) \longrightarrow (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}$

$$U = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \sum_{i=1}^n ((\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}})^2 = \|\tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

自由度(维数)为 p : $\hat{y}_i - \bar{y} = \sum_{j=1}^p \hat{b}_j (x_{ij} - (\bar{\mathbf{x}})_j)$.

- $\frac{1}{\sigma^2} U \stackrel{H_0}{\sim} \chi^2(p)$.

$$\tilde{\mathbf{X}}\hat{\mathbf{b}} \stackrel{H_0}{=} \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{e}.$$

$$\frac{1}{\sigma^2} EU = \text{Tr}(\tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T) =$$

$$\text{Tr}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}_{p \times p} = \text{Tr}(\mathbf{I})_{p \times p} = p.$$

- $\frac{1}{\sigma^2} Q \sim \chi^2(n - 1 - p)$.

$$y_i - \hat{y}_i = (y_i - \bar{y}) - (\hat{y}_i - \bar{y}) = \tilde{y}_i - (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}.$$

$$Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \|\tilde{\mathbf{y}} - \tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

假设检验 $H_0: \mathbf{b} = 0 \leftrightarrow H_1: \mathbf{b} \neq 0$.

- $\hat{y}_i - \bar{y} = \hat{b}(x_i - \bar{x}) \longrightarrow (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}$

$$U = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \sum_{i=1}^n ((\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}})^2 = \|\tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

自由度(维数)为 p : $\hat{y}_i - \bar{y} = \sum_{j=1}^p \hat{b}_j (x_{ij} - (\bar{\mathbf{x}})_j)$.

- $\frac{1}{\sigma^2} U \stackrel{H_0}{\sim} \chi^2(p)$.

$$\tilde{\mathbf{X}}\hat{\mathbf{b}} \stackrel{H_0}{=} \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \mathbf{e}.$$

$$\frac{1}{\sigma^2} EU = \text{Tr}(\tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T) =$$

$$\text{Tr}(\underbrace{(\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T \tilde{\mathbf{X}}}_{\mathbf{I}_{p \times p}} (\tilde{\mathbf{X}}^T \tilde{\mathbf{X}})^{-1} \tilde{\mathbf{X}}^T) = \text{Tr}(\mathbf{I})_{p \times p} = p.$$

- $\frac{1}{\sigma^2} Q \sim \chi^2(n - 1 - p)$.

$$y_i - \hat{y}_i = (y_i - \bar{y}) - (\hat{y}_i - \bar{y}) = \tilde{y}_i - (\mathbf{x}_i - \bar{\mathbf{x}})\hat{\mathbf{b}}.$$

$$Q = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \|\tilde{\mathbf{y}} - \tilde{\mathbf{X}}\hat{\mathbf{b}}\|^2.$$

- $\frac{U/p}{Q/(n-p-1)} \stackrel{H_0}{\sim} F(p, n - p - 1)$.

否定域: $W = \left\{ \frac{U/p}{Q/(n-p-1)} > \lambda \right\}$, 其中 $P(F_{p, n-p-1} > \lambda) = \alpha$.

§10.1 统计决策问题概述

例1.1. θ_1 好, θ_2 坏; a_1 保留, a_2 更换, a_3 修理.

表 10.1.1 损失函数 $L(\theta, a)$ 的值

$L(\theta, a)$ $\theta \backslash a$	a_1	a_2	a_3
θ_1	0	10	5
θ_2	12	1	6

§10.1 统计决策问题概述

例1.1. θ_1 好, θ_2 坏; a_1 保留, a_2 更换, a_3 修理.

表 10.1.1 损失函数 $L(\theta, a)$ 的值

$L(\theta, a)$ $\theta \backslash a$	a_1	a_2	a_3
θ_1	0	10	5
θ_2	12	1	6

- 状态: $\theta = \theta_1$ 或 θ_2 .

§10.1 统计决策问题概述

例1.1. θ_1 好, θ_2 坏; a_1 保留, a_2 更换, a_3 修理.

表 10.1.1 损失函数 $L(\theta, a)$ 的值

$L(\theta, a)$ $\theta \backslash a$	a_1	a_2	a_3
θ_1	0	10	5
θ_2	12	1	6

- 状态: $\theta = \theta_1$ 或 θ_2 .
- 行动: a_1, a_2, a_3 . 行动空间 $A = \{a_1, a_2, a_3\}$.

§10.1 统计决策问题概述

例1.1. θ_1 好, θ_2 坏; a_1 保留, a_2 更换, a_3 修理.

表 10.1.1 损失函数 $L(\theta, a)$ 的值

$L(\theta, a)$ $\theta \backslash a$	a_1	a_2	a_3
θ_1	0	10	5
θ_2	12	1	6

- 状态: $\theta = \theta_1$ 或 θ_2 .
- 行动: a_1, a_2, a_3 . 行动空间 $A = \{a_1, a_2, a_3\}$.
- 损失: 比如 $L(\theta_1, a_2) = 10$: 如果是好零件, 更换它, 损失为10.

§10.1 统计决策问题概述

例1.1. θ_1 好, θ_2 坏; a_1 保留, a_2 更换, a_3 修理.

表 10.1.1 损失函数 $L(\theta, a)$ 的值

$L(\theta, a)$	a	a_1	a_2	a_3
θ				
θ_1		0	10	5
θ_2		12	1	6

- 状态: $\theta = \theta_1$ 或 θ_2 .
- 行动: a_1, a_2, a_3 . 行动空间 $A = \{a_1, a_2, a_3\}$.
- 损失: 比如 $L(\theta_1, a_2) = 10$: 如果是好零件, 更换它, 损失为10.
- 本应根据 θ 采取行动使得 L 最小, 但是 θ 不可观测!

§10.1 统计决策问题概述

例1.1. θ_1 好, θ_2 坏; a_1 保留, a_2 更换, a_3 修理.

表 10.1.1 损失函数 $L(\theta, a)$ 的值

$L(\theta, a)$	a	a_1	a_2	a_3
θ				
θ_1		0	10	5
θ_2		12	1	6

- 状态: $\theta = \theta_1$ 或 θ_2 .
- 行动: a_1, a_2, a_3 . 行动空间 $A = \{a_1, a_2, a_3\}$.
- 损失: 比如 $L(\theta_1, a_2) = 10$: 如果是好零件, 更换它, 损失为10.
- 本应根据 θ 采取行动使得 L 最小, 但是 θ 不可观测!
- 样本: $X = 1$ (正常); $X = 0$ (发烫). 可观测. 根据 x 采取行动.

§10.1 统计决策问题概述

例1.1. θ_1 好, θ_2 坏; a_1 保留, a_2 更换, a_3 修理.

表 10.1.1 损失函数 $L(\theta, a)$ 的值

$L(\theta, a)$	a	a_1	a_2	a_3
θ				
θ_1		0	10	5
θ_2		12	1	6

- 状态: $\theta = \theta_1$ 或 θ_2 .
- 行动: a_1, a_2, a_3 . 行动空间 $A = \{a_1, a_2, a_3\}$.
- 损失: 比如 $L(\theta_1, a_2) = 10$: 如果是好零件, 更换它, 损失为10.
- 本应根据 θ 采取行动使得 L 最小, 但是 θ 不可观测!
- 样本: $X = 1$ (正常); $X = 0$ (发烫). 可观测. 根据 x 采取行动.
- X 与 θ 有关: $X \sim P_\theta$.

决策与风险.

决策与风险.

- 决策函数: 根据观测值采取行动.

如: $\delta_7 =$ 若发烫则 $a_3 =$ 修理, 若正常则 $a_1 =$ 保留.

表 10.1.3 9 个决策函数的列表

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
$\delta(0)$	a_1	a_1	a_1	a_2	a_2	a_2	a_3	a_3	a_3
$\delta(1)$	a_1	a_2	a_3	a_1	a_2	a_3	a_1	a_2	a_3

每个 X 的观测值 x , 有 3 种可选行动. 因此, 共 3×3 个决策.

决策与风险.

- 决策函数: 根据观测值采取行动.

如: $\delta_7 =$ 若发烫则 $a_3 =$ 修理, 若正常则 $a_1 =$ 保留.

表 10.1.3 9个决策函数的列表

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
$\delta(0)$	a_1	a_1	a_1	a_2	a_2	a_2	a_3	a_3	a_3
$\delta(1)$	a_1	a_2	a_3	a_1	a_2	a_3	a_1	a_2	a_3

每个 X 的观测值 x , 有3种可选行动. 因此, 共 3×3 个决策.

- 风险函数: 决策带来的平均损失.

P_θ : $P_{\theta_1=好}(X=0=发烫) = 0.3$, $P_{\theta_2}(X=0) = 0.6$.

如: $R(\theta_1, \delta_2) = P_{\theta_1}(X=0)L(\theta_1, a_1) + P_{\theta_1}(X=1)L(\theta_1, a_2)$
 $= 0.3 \times 0 + 0.7 \times 10 = 7$.

决策的优劣:

表 10.1.4 各决策函数的风险函数值

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
$R(\theta_1, \delta)$	0	7	3.5	3	10	6.5	1.5	8.5	5
$R(\theta_2, \delta)$	12	7.6	9.6	5.4	1	3	8.4	4	6

决策的优劣:

表 10.1.4 各决策函数的风险函数值

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
$R(\theta_1, \delta)$	0	7	3.5	3	10	6.5	1.5	8.5	5
$R(\theta_2, \delta)$	12	7.6	9.6	5.4	1	3	8.4	4	6

- 不可容许的: 如 δ_2 .

$R(\theta, \delta_2) \geq R(\theta, \delta_4), \forall \theta$, 且存在严格不等号.

决策的优劣:

表 10.1.4 各决策函数的风险函数值

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
$R(\theta_1, \delta)$	0	7	3.5	3	10	6.5	1.5	8.5	5
$R(\theta_2, \delta)$	12	7.6	9.6	5.4	1	3	8.4	4	6

- 不可容许的: 如 δ_2 .

$R(\theta, \delta_2) \geq R(\theta, \delta_4), \forall \theta$, 且存在严格不等号.

- 该例题不存在一致最优的 δ : 对任意 $\tilde{\delta}$ 都有

$R(\theta, \tilde{\delta}) \geq R(\theta, \delta), \forall \theta$.

决策的优劣:

表 10.1.4 各决策函数的风险函数值

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
$R(\theta_1, \delta)$	0	7	3.5	3	10	6.5	1.5	8.5	5
$R(\theta_2, \delta)$	12	7.6	9.6	5.4	1	3	8.4	4	6

- 不可容许的: 如 δ_2 .
 $R(\theta, \delta_2) \geq R(\theta, \delta_4), \forall \theta$, 且存在严格不等号.
- 该例题不存在一致最优的 δ : 对任意 $\tilde{\delta}$ 都有
 $R(\theta, \tilde{\delta}) \geq R(\theta, \delta), \forall \theta$.
- 极小极大准则: 选 δ_4 使得其最大风险5.4 是最小的.

贝叶斯决策.

贝叶斯决策.

- 将 θ 视为随机的: 如, 假设某零件“好”的概率为0.7, 先验分布: $\pi(\theta_1) = 0.7, \pi(\theta_2) = 0.3$.

贝叶斯决策.

- 将 θ 视为随机的: 如, 假设某零件“好”的概率为0.7, 先验分布: $\pi(\theta_1) = 0.7, \pi(\theta_2) = 0.3$.
- 平均风险: $\pi(\theta_1)R(\theta_1, \delta) + \pi(\theta_2)R(\theta_2, \delta)$.

表 10.1.5 各决策函数的平均风险值

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
平均风险	3.6	5.13	12.48	3.72	7.20	5.45	3.57	7.15	5.3

贝叶斯决策.

- 将 θ 视为随机的: 如, 假设某零件“好”的概率为0.7, 先验分布: $\pi(\theta_1) = 0.7, \pi(\theta_2) = 0.3$.
- 平均风险: $\pi(\theta_1)R(\theta_1, \delta) + \pi(\theta_2)R(\theta_2, \delta)$.

表 10.1.5 各决策函数的平均风险值

δ	δ_1	δ_2	δ_3	δ_4	δ_5	δ_6	δ_7	δ_8	δ_9
平均风险	3.6	5.13	12.48	3.72	7.20	5.45	3.57	7.15	5.3

- 选择 δ_7 , 使得平均风险达到最小.

一般情形.

一般情形.

- 状态(空间): $\theta \in \Theta$.
行动(空间): $a \in A$.
损失函数: $L(\theta, a)$.

一般情形.

- 状态(空间): $\theta \in \Theta$.

行动(空间): $a \in A$.

损失函数: $L(\theta, a)$.

- 样本(空间): $X \sim P_\theta$, 取值 $x \in \mathcal{X}$.

策略函数: $\delta : \mathcal{X} \rightarrow A$, $\delta(x) = a$.

风险函数: $R(\theta, \delta) = E_\theta L(\theta, \delta(X))$, $a = \delta(X)$.

一般情形.

- 状态(空间): $\theta \in \Theta$.

行动(空间): $a \in A$.

损失函数: $L(\theta, a)$.

- 样本(空间): $X \sim P_\theta$, 取值 $x \in \mathcal{X}$.

策略函数: $\delta : \mathcal{X} \rightarrow A$, $\delta(x) = a$.

风险函数: $R(\theta, \delta) = E_\theta L(\theta, \delta(X))$, $a = \delta(X)$.

- 极小极大准则:

选择 δ^* 使得 $\max_{\theta \in \Theta} R(\theta, \delta)$ 在 $\delta = \delta^*$ 达到最小.

一般情形.

- 状态(空间): $\theta \in \Theta$.
行动(空间): $a \in A$.
损失函数: $L(\theta, a)$.
- 样本(空间): $X \sim P_\theta$, 取值 $x \in \mathcal{X}$.
策略函数: $\delta : \mathcal{X} \rightarrow A, \delta(x) = a$.
风险函数: $R(\theta, \delta) = E_\theta L(\theta, \delta(X)), a = \delta(X)$.
- 极小极大准则:
选择 δ^* 使得 $\max_{\theta \in \Theta} R(\theta, \delta)$ 在 $\delta = \delta^*$ 达到最小.
- 贝叶斯决策:
将 θ 视为取值于 Θ 的随机变量, 分布为 π .
选择 δ^* 使得 $E_\pi R(\theta, \delta)$ 在 $\delta = \delta^*$ 达到最小.