

应用数理统计

Review.

概率论. 随机变量的定义

数字特征: 期望, 方差

离散型

连续型

$Y = g(X)$ 的概率分布.

多维随机变量.

定义: $X_1(\omega), \dots, X_n(\omega)$ 定义在同 Ω .

$$X(\omega) = (X_1(\omega), \dots, X_n(\omega)).$$

边缘分布 联合分布函数. $\forall x_1, \dots, x_n, F(x_1, \dots, x_n) = P(X_1 \leq x_1, \dots, X_n \leq x_n)$

边缘分布 联合分布列 $(X, Y) \quad P_{ij} = P(X = x_i, Y = y_j) \quad i, j = 1, 2, \dots$

边缘密度 联合密度函数

\exists 二元非负函数 $p(x, y)$

$$F(x, y) = \int_{-\infty}^x \int_{-\infty}^y p(u, v) dv du.$$

独立性.

$$A, B \quad P(AB) = P(A)P(B)$$

$X_1, \dots, X_n \quad F(x_1, \dots, x_n) = \prod_{i=1}^n F_{X_i}(x_i) \quad$ 称 X_1, \dots, X_n 相互独立.

离散 $P(X_1 = x_1, \dots, X_n = x_n) = \prod_{i=1}^n P(X_i = x_i)$

连续 $f(x_1, \dots, x_n) = \prod_{i=1}^n f_{X_i}(x_i)$

(X_1, \dots, X_n) 多维 r.v.

数字特征.

1. 期望 $(X, Y) \quad Z = g(X, Y) \quad EZ = \begin{cases} \sum_i \sum_j g(x_i, y_j) P(X = x_i, Y = y_j) & \text{离} \\ \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} g(x, y) p(x, y) dx dy & \text{连} \end{cases}$

$$\textcircled{1} E(X+Y) = EX + EY.$$

$$E\left(\sum_{i=1}^n X_i\right) = \sum_{i=1}^n EX_i.$$

2. 若 X 与 Y 独立.

$$\text{则 } EXY = EX \cdot EY.$$

若 X_1, \dots, X_n 相互独立, 则 $E \prod_{i=1}^n X_i = \prod_{i=1}^n EX_i.$

$$\textcircled{2} \text{Var}(X) = E(X - EX)^2 = \underline{EX^2 - (EX)^2}$$

$$\text{Var}(aX + b) = a^2 \text{Var}(X)$$

$$\text{Var}(DX \pm Y) = D^2X + D^2Y \pm 2\text{cov}(X, Y)$$

若 X 与 Y 相互独立, $\text{Var}(X \pm Y) = \text{Var}(X) + \text{Var}(Y)$

③ 协方差

$$\text{cov}(X, Y) = E(X - EX)(Y - EY) = \underline{EXY - EXEY}$$

$$1. \text{cov}(X, Y) = \text{cov}(Y, X)$$

$$2. \text{Var}(X \pm Y) = \text{Var}(X) + \text{Var}(Y) \pm 2\text{cov}(X, Y)$$

$$3. \text{Cov}(X, a) = 0$$

$$\text{cov}(aX + bY) = ab \text{cov}(X, Y)$$

$$\text{cov}^2(X, Y) \quad \rho_{XY} = \frac{\text{cov}(X, Y)}{\sqrt{\text{Var}(X)} \sqrt{\text{Var}(Y)}}$$

问题是 $g(X_1, \dots, X_n)$ 分布?

X, Y 为例. X 与 Y 独立. $X+Y$ 的概率密度. $X-Y$ $\frac{X}{Y}$

常用离散分布.

1° 0-1 分布 $X \sim b(1, p)$

$$P_k^{[X=k]} = p^k (1-p)^{1-k}, \quad k=0, 1.$$

$$EX = p, \quad \text{Var} X = p(1-p)$$

2° 二项分布. $X \sim b(n, p)$

$$P_k^{[X=k]} = C_n^k p^k (1-p)^{n-k}, \quad k=0, 1, \dots, n.$$

$$EX = np, \quad \text{Var}(X) = np(1-p)$$

3° 泊松分布 $X \sim P(\lambda)$ $P_k = \frac{\lambda^k}{k!} e^{-\lambda}, k=0, 1, \dots$
 $E X = \lambda, \text{Var } X = \lambda$

连续分布

1° 正态分布 $X \sim N(\mu, \sigma^2)$ $f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$
 $E X = \mu, \text{Var } X = \sigma^2$

2° 均匀分布

$X \sim U(a, b)$ $f(x) = \frac{1}{b-a}, a \leq x \leq b$
 $E X = \frac{a+b}{2}, \text{Var } X = \frac{(b-a)^2}{12}$

3° 指数分布

$X \sim \text{Exp}(\lambda)$ $f(x) = \lambda e^{-\lambda x}, x \geq 0$
 $E X = \frac{1}{\lambda}, \text{Var } X = \frac{1}{\lambda^2}$

多维: 多项分布

① $F(y) = P(Y \leq y)$

② $F'(y) = f(y)$

第1章. 数理统计的基本概念.

1.1 总体, 样本, 统计量

① 样本具有随机性

i.i.d. 独立同分布

② 样本具有独立性.

总体 $\begin{cases} \text{有限总体 } N \\ \text{无限总体.} \end{cases}$

统计量 $t = g(X_1, \dots, X_n)$

~~统计量~~ $t = (g_1, g_2, \dots)$

样本矩: $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ 修正样本矩 $S^{*2} = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$

样本 k 阶原点矩 $A_k = \frac{1}{n} \sum_{i=1}^n X_i^k$

样本 k 阶中心矩 $B_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k$


(次)

顺序统计量 $(X_{(1)}, \dots, X_{(n)})^T$

总体 $X \sim f(x)$

(1) $X_{(k)}$ 的概率密度 $f_{(k)}(x) \quad (1 \leq k \leq n)$


概率微元法




$$f_{(k)}(x) = \frac{n!}{(k-1)!(n-k)!} [F(x)]^{k-1} [1-F(x)]^{n-k} f(x)$$

dx 足够小.

(2) $X_{(k)}$ 与 $X_{(j)}$ 的联合概率密度 $f_{(k,j)}(x,y) \quad (1 \leq k < j \leq n)$



$$f_{(k,j)}(x,y) = \frac{n!}{(k-1)!(j-k-1)!(n-j)!} [F(x)]^{k-1} [F(y)-F(x)]^{j-k-1} [1-F(y)]^{n-j} f(x) f(y)$$



前 r 个

$$f_{(1) \dots (r)}(x_1, \dots, x_r) = \begin{cases} \frac{n!}{(n-r)!} [1 - F(x_r)]^{n-r} f(x_1) \dots f(x_r) & x_1 < \dots < x_r \\ 0 & \text{其他} \end{cases}$$

样本中位数 $Me = \begin{cases} X_{(n+1)/2} & n \text{ 为奇} \\ \frac{1}{2} (X_{n/2} + X_{n/2+1}) & n \text{ 为偶} \end{cases}$

样本极差 $r = X_{(n)} - X_{(1)}$

经验分布函数

设 $X \sim F(x)$

$$F_n^*(x) = \begin{cases} 0 & x < X_{(1)} \\ \frac{k}{n} & X_{(k)} \leq x < X_{(k+1)} \quad k = 1, 2, \dots, n-1 \\ 1 & X_{(n)} \leq x \end{cases}$$

① 固定 $(x_1, \dots, x_n)^T$, $F_n^*(x)$ 作为 x 的函数 就是分布函数.

② 固定 x , $F_n^*(x)$ 是随机变量

$$= \frac{m(x)}{n}$$

$$m(x) = \sum_{i=1}^n u(x - X_i)$$

$$u(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases}$$

$$E[F_n^*(x)] = F(x)$$

$$D[F_n^*(x)] = \frac{F(x)[1-F(x)]}{n}$$

1.2 抽样分布 (统计量的分布)

1. Γ 分布 $X \sim \Gamma(\alpha, \lambda)$ $\alpha > 0, \lambda > 0$

形状
尺度

$$f(x; \alpha, \lambda) = \frac{\lambda^\alpha}{\Gamma(\alpha)} x^{\alpha-1} e^{-\lambda x}, \quad x > 0$$

Γ 函数 $\Gamma(\alpha) = \int_0^{+\infty} x^{\alpha-1} e^{-x} dx$

$$\Gamma(\alpha+1) = \alpha \Gamma(\alpha) \quad \Gamma(n+1) = n!$$

$$\Gamma(1) = 1 \quad \Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

$$\frac{\Gamma(p) \Gamma(q)}{\Gamma(p+q)} = B(p, q) \quad B(p, q) = \int_0^1 x^{p-1} (1-x)^{q-1} dx$$

$$(\Gamma(p) \Gamma(q) \neq \Gamma(p+q) \quad B(p, q))$$

证: $\Gamma(p) \Gamma(q) = \int_0^{+\infty} \int_0^{+\infty} x^{p-1} y^{q-1} e^{-(x+y)} dx dy$

$0 < u = x+y < \infty$
 $0 < v = \frac{x}{x+y} < 1$

$$\begin{cases} x = uv \\ y = u(1-v) \end{cases} \quad \text{和} \quad J = \begin{vmatrix} \frac{\partial x}{\partial u} & \frac{\partial x}{\partial v} \\ \frac{\partial y}{\partial u} & \frac{\partial y}{\partial v} \end{vmatrix} = \begin{vmatrix} v & u \\ 1-v & -u \end{vmatrix} = -u$$

$$= \int_0^{+\infty} \int_0^1 (uv)^{p-1} (u(1-v))^{q-1} e^{-u} du dv$$

$$= \int_0^{+\infty} \underbrace{u^{p+q-1} e^{-u} du}_{\Gamma(p+q)} \int_0^1 \underbrace{v^{p-1} (1-v)^{q-1} dv}_{B(p, q)}$$

性质: ① $EX = \frac{\alpha}{\lambda} \quad DX = \frac{\alpha}{\lambda^2}$

② 若 $X_i \sim \Gamma(\alpha_i, \lambda)$ $i.i.d.$

$$X_1 + \dots + X_n \sim \Gamma(\alpha_1 + \dots + \alpha_n, \lambda)$$

$\alpha=1$ 时 $X \sim \text{Exp}(\lambda) = \Gamma(1, \lambda)$

$$X_i \sim \text{Exp}(\lambda) \quad \sum_{i=1}^n X_i \sim \Gamma(n, \lambda)$$

变换

② 倒 Γ / 逆 Γ

$$P(Y \leq y) = P\left(\frac{1}{X} \leq x\right)$$

$$X \sim \Gamma(\alpha, \lambda) \quad Y = g(X) = \frac{1}{X}$$

$$X = h(Y) = \frac{1}{Y} \quad h'(y) = -\frac{1}{y^2}$$

① $g(x)$ 单调

$$f_Y(y) = P_X(h(y)) |h'(y)|$$

$$a < y < b$$

② 定义

2. β 分布. $X \sim \beta(a, b)$ $a > 0, b > 0$
 $f(x; a, b) = \frac{x^{a-1} (1-x)^{b-1}}{B(a, b)}, 0 < x < 1$

性质 ① $EX = \frac{a}{a+b}$ $DX = \frac{ab}{(a+b)^2(a+b+1)}$

② $X \sim \Gamma(a, 1)$ $Y \sim \Gamma(b, 1)$ X, Y 独立.
 $Z = \frac{X}{X+Y} \sim \beta(a, b)$

求法:

X, Y (X, Y) 联合密度.

$$\begin{cases} Z = \frac{X}{X+Y} \\ U = X \end{cases}$$

增补变量 (Z, U) 的联合密度.

$P(Z, u)$ 关于 u 积分, 可得 $P_Z(Z)$

$$X \sim \beta(1, 1) = U(0, 1)$$

3. χ^2 分布.

$X_i \sim N(0, 1)$ $\sum_{i=1}^n X_i^2 \sim \chi^2(n)$

性质 ① $EX = n$ $DX = 2n$


$X \sim \chi^2(n) = \Gamma\left(\frac{n}{2}, \frac{1}{2}\right)$ — 证. $Y \sim \chi^2(1)$ $Y = X^2$ $X \sim N(0, 1)$

$F_Y(y) = P\{Y \leq y\} = P\{X^2 \leq y\} = \dots$
 $f'_Y(y) = \dots$

② $X_i \sim \chi^2(n_i)$

$X_1 + X_2 + \dots + X_k \sim \chi^2(n_1 + \dots + n_k)$

③ $n \rightarrow \infty$ 时 $\chi^2 \sim N(n, 2n)$



4. t分布

$$X \sim N(0, 1), \quad Y \sim \chi^2(n)$$


$$T = \frac{X}{\sqrt{Y/n}} \sim t(n)$$

5. F分布


$$X \sim \chi^2(n_1), \quad Y \sim \chi^2(n_2) \quad X, Y \text{ 独立}$$

$$F = \frac{X/n_1}{Y/n_2} \sim F(n_1, n_2)$$


$$\frac{1}{F} \sim (n_2, n_1)$$




分位数



$$F(x_p) = P$$



$$F(y_d) = 1 - \alpha$$



$$F_\alpha(n_1, n_2) = \frac{1}{F_{1-\alpha}(n_2, n_1)}$$

$$\chi^2_\alpha(1) = \sqrt{\frac{1}{\alpha}}$$

$$F_\alpha(1, n) = t_{\frac{\alpha}{2}}^2(n)$$

$$u_{1-\alpha} = -u_\alpha$$

$$t_{1-\alpha}(n) = -t_\alpha(n)$$

正态总体的抽样分布

定理 1

$$(1) \bar{X} \sim N(\mu, \frac{\sigma^2}{n})$$

$$(2) \frac{(n-1)S^{*2}}{\sigma^2} \sim \chi^2(n-1)$$

(3) \bar{X} 与 S^{*2} 相互独立。

消去了一个 σ^2

不可及即为消去的 σ^2

$$\frac{nS^2}{\sigma^2}$$

$$2. \quad \bar{T} = \frac{\sqrt{n}(\bar{X} - \mu)}{S^*} \sim t(n-1)$$

$$3. \quad \bar{T} = \frac{(\bar{X} - \bar{Y}) - (\mu_1 - \mu_2)}{S_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t(n_1 + n_2 - 2)$$

$$S_w = \sqrt{\frac{(n_1 - 1) S_{1n_1}^{*2} + (n_2 - 1) S_{2n_2}^{*2}}{n_1 + n_2 - 2}}$$

$$4. \quad F = \frac{\sigma_2^2 S_{1n_1}^{*2}}{\sigma_1^2 S_{2n_2}^{*2}} \sim F(n_1 - 1, n_2 - 1)$$

第2章 参数估计

2-1 点估计和估计量的求法

估计量: $\hat{\theta}_i(X_1, X_2, \dots, X_n)$ 估计值 $\hat{\theta}_i(x_1, x_2, \dots, x_n)$

矩估计法:

样本矩 $\overset{\text{估计}}{\underset{B_k}{A_k}}$ 估计 总体矩

总体 k 阶原点矩 $\alpha_k = E(X^k)$

样本 k 阶原点矩 $A_k = \frac{1}{n} \sum_{i=1}^n X_i^k$

$$\hat{\mu} = \bar{X} \quad \hat{\sigma}^2 = S^2$$

极大似然估计法 (优: 用了总体的分布)

样~~本~~到观测值的概率 $L(\theta)$

顺序估计量法

$$\hat{\mu} = M_e \quad \text{— 样本中位数}$$

$$\hat{\sigma} = R/d_n$$

样本极差

此估计量的均方误差 $\frac{V_n^2}{d_n^2} \sigma^2$ 标准差 $\frac{V_n}{d_n} \sigma$

$n > 10$ 时, 分若干组

2.2 估计量的评判标准.

2.2.1. 无偏性. — 平均误差 $E(\hat{\theta} - \theta) = 0 \Rightarrow E\hat{\theta} = \theta.$

无偏估计量 $E\hat{\theta} = \theta$

有偏估计量 $E\hat{\theta} \neq \theta$ $E(\hat{\theta} - \theta) \rightarrow$ 偏差.

渐近无偏估计量 $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta.$

$\exists, g(\theta)$, $T = T(X_1, \dots, X_n)$ 使 $ET = g(\theta).$

则 $g(\theta)$ 为可估函数, T 为 $g(\theta)$ 的无偏估计量.

结论 (1) $\exists EX = \mu$, 则 $E\bar{X} = \mu$ \bar{X} 为 μ 的无偏估计量.

(2) $\exists EX^k = \mu_k$ 则 $E A_k = \mu_k$

(3) $\exists DX = \sigma^2$ 则 S^2 为 σ^2 的渐近

一致 $E S^2 = \sigma^2$ 无偏.

注意: 无偏估计量 可以不存在 有 明显弊端

不具有 不变性 $E\hat{\theta} = \theta \rightarrow E g(\hat{\theta}) \neq g(\theta).$

2.2.2 有效性. — 误差偏离程度

1. 均方误差 $MSE(\hat{\theta}, \theta) \triangleq E(\hat{\theta} - \theta)^2$

一致最小均方误差估计量 $\hat{\theta}^*$

$$MSE(\hat{\theta}^*, \theta) \leq MSE(\hat{\theta}, \theta), \quad \forall \theta \in \Theta$$

$$MSE(\hat{\theta}, \theta) = D(\hat{\theta}) + (E\hat{\theta} - \theta)^2$$

$$\text{推导: } E(\hat{\theta} - \theta)^2 = E(\hat{\theta}^2 + \theta^2 - 2\hat{\theta}\theta) = E\hat{\theta}^2 - 2\theta E\hat{\theta} + \theta^2 = \underbrace{E\hat{\theta}^2 - (E\hat{\theta})^2}_{D(\hat{\theta})} + (E\hat{\theta} - \theta)^2$$

$$- 2\theta E\hat{\theta} + \theta^2 = D(\hat{\theta}) + (E\hat{\theta} - \theta)^2$$

$\hat{\theta}$ 为 θ 的无偏估计量时.

$$MSE(\hat{\theta}, \theta) = D(\hat{\theta})$$

方差最小准则.

2. 一致最小方差无偏估计量 $\hat{\theta}^*$ UMVUE

$$D_0(\hat{\theta}^*) \leq D_0(\hat{\theta}), \forall \hat{\theta} \in \mathcal{H}$$

$$U = \{ \hat{\theta} : E_0(\hat{\theta}) = \theta, D_0(\hat{\theta}) < \infty, \forall \theta \in \mathcal{H} \}$$

$$U_0 = \{ \hat{\theta}_0 : E_0(\hat{\theta}_0) = 0, D_0(\hat{\theta}_0) < \infty, \forall \theta \in \mathcal{H} \}$$

定理 2.2.1

$\hat{\theta}^* \in U, \hat{\theta}_0 \in U_0$, 则 $\hat{\theta}^*$ 为 ~~唯一~~ UMVUE.

$$\iff E_\theta(\hat{\theta}^* \hat{\theta}_0) = 0, \forall \theta \in \mathcal{H} \quad (\hat{\theta}^* \text{ 与 } \hat{\theta}_0 \text{ 不相关时})$$

定理 2.2.1 θ 至多存在一个 UMVUE.

证明 $\hat{\theta}^*$ 为 UMVUE 思路:

- ① $\int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \hat{\theta}_0(x_1, \dots, x_n) \frac{\partial}{\partial \theta} f(x; \theta) dx_1 \dots dx_n$
- ② 求导 凑出 $\hat{\theta}^*$ 即可得出证明

3. Rao-Cramer 不等式.

定理 2.2.3 条件: $T = (X_1, \dots, X_n)$ 是 $g(\theta)$ 的 ^{可估函数} 无偏估计量

- (1) $\{X: f(x; \theta) > 0\}$ 与 θ 无关.
- (2) $\frac{\partial}{\partial \theta} \int_{-\infty}^{+\infty} f(x; \theta) dx = \int_{-\infty}^{+\infty} \frac{\partial f(x; \theta)}{\partial \theta} dx$
- (3) $I(\theta) = E \left(\frac{\partial \ln f(X; \theta)}{\partial \theta} \right)^2 > 0$

Fisher 信息量.

$$D(T) \geq \frac{[g'(\theta)]^2}{nI(\theta)} \quad \text{--- } g(\theta) \text{ 的 R-C 下界.}$$

$g(\theta) = \theta$ 时.

$$D(T) \geq \frac{1}{nI(\theta)} \quad \text{--- } \theta \text{ 的 R-C 下界}$$

$$I(\theta) = E \left(\frac{\partial \ln f(x; \theta)}{\partial \theta} \right)^2 = -E \left(\frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} \right)$$

$$\int_{-\infty}^{+\infty} f(x; \theta) dx = 1$$

对 θ 求导: $\int_{-\infty}^{+\infty} \frac{\partial}{\partial \theta} f(x; \theta) dx = 0$

对数形式: $\int_{-\infty}^{+\infty} \frac{\partial \ln f(x; \theta)}{\partial \theta} f(x; \theta) dx = 0$

再求导: $\int_{-\infty}^{+\infty} \frac{\partial^2 \ln f(x; \theta)}{\partial \theta^2} f(x; \theta) dx = -E \left[\frac{\partial \ln f(x; \theta)}{\partial \theta} \right]^2$

\Downarrow

$$E \left[\frac{\partial \ln f(x; \theta)}{\partial \theta} \right]^2 = -E \left[\frac{\partial^2 \ln f}{\partial \theta^2} \right]$$

σ^2 的 R-C 下界 $\frac{2\sigma^4}{n}$

σ^2 的 WMVUE s^{*2} : $D(s^{*2}) = \frac{2\sigma^4}{n-1} > \frac{2\sigma^4}{n}$

表明: 一致最小方差无偏估计 WMVUE 的方差未必能达到 R-C 下界.

4. 有效估计量: 若 $g(\theta)$ 的无偏估计 $T = T(X_1, \dots, X_n)$ 的方差达到 R-C 下界

即 $D_0(T) = \frac{[g'(\theta)]^2}{nI(\theta)}$ $\forall \theta \in \Theta$ 称 T 为 $g(\theta)$ 的有效估计量.

有效率 $e(T) = \frac{[g'(\theta)]^2}{nI(\theta)} / D(T)$

渐近有效估计 $\lim_{n \rightarrow \infty} e_n(T) = 1$

定理 2.2.4 (2.2.3 的推广)

(1) T 是 $g(\theta)$ 的有效估计量 $\Leftrightarrow \frac{\partial \ln L(\theta)}{\partial \theta} = C(\theta) [T - g(\theta)]$
似然函数 是 $g(\theta)$ 的无偏估计
 $\neq 0$ 实际中, 推出 $T = g(\theta)$
即得 $C(\theta)$

(2) $D_0(T) = \frac{[g'(\theta)]^2}{nI(\theta)} = \frac{g'(\theta)}{C(\theta)}$ $I(\theta) = \frac{C(\theta)g'(\theta)}{n}$ $I = \frac{Cg'}{n}$

当 $g(\theta) = \theta$ 时 有 $D_0(T) = \frac{1}{C(\theta)}$, $I(\theta) = \frac{C(\theta)}{n}$ 常用结论.

(3) 有效估计量唯一.

(4) $g(\theta)$ 的有效估计量是 $g(\theta)$ 的唯一极大似然估计量

1. 样本 k 阶矩 A_k 是总体 k 阶矩 α_k 的一致估计. 矩估计法得到的估计量为一致估计量.
 2. $E\hat{\theta} = \theta$ 且 $\lim_{n \rightarrow \infty} D(\hat{\theta}) = 0$ 则 $\hat{\theta}$ 是 θ 的一致估计量.

2.2.3 相合性 n 很大时, 可估计到任意精度.

相合估计量 (一致估计量) $\lim_{n \rightarrow \infty} P\{|T_n - g(\theta)| \geq \epsilon\} = 0$ (CP) $\lim_{n \rightarrow \infty} T_n = g(\theta)$ 用契比

均为相合估计量. $\lim_{n \rightarrow \infty} E\{T_n - g(\theta)\}^2 = 0$ (OKS) $\lim_{n \rightarrow \infty} T_n = g(\theta)$

结论: $\hat{\theta}$ 为 θ 的相合估计 \nexists 一致性? $g(\theta)$ 为连续函数, $g(\hat{\theta})$ 是 $g(\theta)$ 的相合估计.

(2) 常数列 C_n $\lim_{n \rightarrow \infty} C_n = 1$. $C_n \hat{\theta}$ 也是 θ 的相合估计.

契比 $P(|X - EX| \geq \epsilon) \leq \frac{DX}{\epsilon^2}$

2.4 区间估计

2.4.1 区间估计概念

$$P\{\underline{\theta}(X_1, \dots, X_n) < \theta < \bar{\theta}(X_1, \dots, X_n)\} \geq 1 - \alpha$$

统计量

置信度

每取一次样本, $\theta, \bar{\theta}$ 会变.

精度 $E(\theta - \bar{\theta})$ — 平均长度

置信区间

枢轴量法: 从 θ 的点估计量入手, 构造枢轴量 G (仅包含样本和被估参数 θ) 找出置信区间.

2.4.2 一个正态总体的情形.

1. $\mu - \bar{X}$

(1) σ^2 已知 $U = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1)$

无偏量
 $P\{c < U < d\} = 1 - \alpha$
 对称取 c, d .
 $P\{U < c\} = \frac{\alpha}{2}$
 $P\{U > d\} = \frac{\alpha}{2}$

$$P\{-u_{\frac{\alpha}{2}} < U < u_{\frac{\alpha}{2}}\} = 1 - \alpha$$

(2) σ^2 未知 $T = \frac{\bar{X} - \mu}{\frac{s^*}{\sqrt{n}}} \sim t(n-1)$

$$P\{|T| < t_{\frac{\alpha}{2}}(n-1)\} = 1 - \alpha$$

2. $\sigma^2 - S^{*2}$

(1) μ 已知 (自由)

$$\chi^2 = \frac{n(\bar{X} - \mu)^2}{\sigma^2} \sim \chi^2(1)$$

$$\chi^2 = \frac{\sum_{i=1}^n (X_i - \mu)^2}{\sigma^2} \sim \chi^2(n)$$

(2) μ 未知

$$P\{\chi_{1-\alpha/2}^2 < \chi^2 < \chi_{\alpha/2}^2\} = 1 - \alpha$$

$$\chi^2 = \frac{(n-1)S^{*2}}{\sigma^2} \sim \chi^2(n-1)$$

2.4.3 两个正态总体的情形

1. $\mu_1 - \mu_2$ — $\bar{X} - \bar{Y}$

(1) σ_1^2 和 σ_2^2 已知

$$U = \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}}$$

(2) $\sigma_1^2 = \sigma_2^2 = \sigma^2$ 未知

$$T = \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{S_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t(n_1 + n_2 - 2)$$

$$S_w = \sqrt{\frac{(n_1 - 1)S_{n_1}^{*2} + (n_2 - 1)S_{n_2}^{*2}}{n_1 + n_2 - 2}}$$

(3) σ_1^2, σ_2^2 未知 $n_1 = n_2 = n$

$$Z_i = X_i - Y_i \sim N(\mu_1 - \mu_2, \sigma_1^2 + \sigma_2^2)$$

~~$$\bar{Z} \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2 + \sigma_2^2}{n})$$~~

$$\bar{Z} \sim N(\mu_1 - \mu_2, \frac{\sigma_1^2 + \sigma_2^2}{n})$$

$$T = \frac{\bar{Z} - (\mu_1 - \mu_2)}{\frac{S_Z^*}{\sqrt{n}}} \sim t(n-1) \quad S_Z^* = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (Z_i - \bar{Z})^2}$$

2. $\frac{\sigma_1^2}{\sigma_2^2}$ — $S_{n_1}^{*2}, S_{n_2}^{*2}$

未知

(1) μ_1, μ_2 已知 (自证)

$$F = \frac{\sigma_2^2 \sum_{i=1}^{n_1} (X_i - \mu_1)^2}{\sigma_1^2 \sum_{i=1}^{n_2} (Y_i - \mu_2)^2} \sim F(n_1, n_2)$$

(2) μ_1, μ_2 未知
未知

$$F = \frac{\sigma_2^2 S_{n_1}^{*2}}{\sigma_1^2 S_{n_2}^{*2}} \sim F(n_1 - 1, n_2 - 1)$$

2.4.4 非正态总体的区间估计

1. 指数分布参数的估计 $\lambda \sim \bar{X}$ $E\bar{X} = \frac{1}{\lambda}$

结论 设 r.v. $X \sim \Gamma(d, \lambda)$ 则当

$$k > 0 \text{ 时 } Y = kX \sim \Gamma(d, \frac{\lambda}{k})$$

证: 当 $y < 0$ 时 $f_Y(y) = 0$

$$\begin{aligned} \text{当 } y \geq 0 \text{ 时 } f_Y(y) &= f_X\left(\frac{y}{k}\right) \frac{1}{k} = \frac{\lambda^d}{\Gamma(d)} \left(\frac{y}{k}\right)^{d-1} e^{-\lambda \frac{y}{k}} \cdot \frac{1}{k} \\ &= \frac{(\frac{\lambda}{k})^d}{\Gamma(d)} y^{d-1} e^{-\frac{\lambda}{k} y} \end{aligned}$$

表明 $Y \sim \Gamma(d, \frac{\lambda}{k})$

$$X_i \sim \text{Exp}(\lambda) = \Gamma(1, \lambda)$$

$$2n\lambda\bar{X} = 2n\lambda \cdot \frac{\sum_{i=1}^n X_i}{n} = \frac{\sum_{i=1}^n (2\lambda X_i)}{n} \sim \Gamma(n, \frac{1}{2})$$

$$\sim \Gamma(n, \frac{1}{2}) = \Gamma\left(\frac{2n}{2}, \frac{1}{2}\right) \sim \chi^2(2n)$$

$$\chi^2 = 2n\lambda\bar{X} \sim \chi^2(2n)$$

2. 0-1分布参数的区间估计 $X_i \sim B(1, p)$

$$U = \frac{\sum_{i=1}^n X_i - np}{\sqrt{np(1-p)}} = \frac{\sqrt{n}(\bar{X} - p)}{\sqrt{p(1-p)}} \quad \text{该分布与 } p \text{ 有关}$$

由中心极限定理得

$$n \text{ 充分大时, } U \sim N(0, 1)$$

3. 大样本条件下总体均值的区间估计

$$n \text{ 充分大时 } U = \frac{\bar{X} - \mu}{S/\sqrt{n}} \sim N(0, 1)$$

2.4.5 单侧区间估计

$$P\{\theta(X_1, \dots, X_n) < \theta\} \geq 1 - \alpha$$

单侧置信下限 $(-\infty, +\infty)$ 单侧置信区间.

$$P\{\theta < \hat{\theta}(X_1, \dots, X_n)\} \geq 1 - \alpha.$$

$(-\infty, \hat{\theta})$

例如 $X \sim N(\mu, \sigma^2)$ σ^2 未知

$$T = \frac{\sqrt{n}(\bar{X} - \mu)}{S} \sim t(n-1)$$

$$P\{T < t_{\alpha}(n-1)\} = 1 - \alpha$$

\downarrow

$$P\{\bar{X} - \frac{S}{\sqrt{n}} t_{\alpha}(n-1) < \mu < +\infty\} = 1 - \alpha.$$

单侧置信下限.

第3章 假设检验

3.1 假设检验的基本概念

假设检验：对总体或总体性质提出假设，利用样本进行检验。

参数假设检验

非参数假设检验

假设：原假设 $H_0: \theta \in \Theta_0$

备择假设 $H_1: \theta \in \Theta_1$ 对立假设

简单假设 (对合)

复合假设

检验规则：

W - 拒绝域

W^c - 接受域

检验函数 $S(x)$

$$S(x) = \begin{cases} 0, & x \in W \\ 1, & x \notin W \end{cases}$$

两类错误

第I类错误 (弃真错误)

$P_0(W), \theta \in \Theta_0$

H_0 为真，而样本值落在拒绝域

第II类错误 (存伪错误)

$P_0(W^c), \theta \in \Theta_1$

(减小)

控制第I类错误的概率

(自然提高了II类的概率，危险的)

功效函数：(样本落入拒绝域的概率)

$$\beta_0(\theta) \triangleq P_0(W) = E_0[S(x)], \theta \in \Theta$$

显著水平 α

$$\sup_{\theta \in \Theta_0} \beta_0(\theta) \leq \alpha$$

拒绝域 \longleftrightarrow 检验统计量

置信度 $1-\alpha$ \longleftrightarrow 显著性水平 α

区间估计 \longleftrightarrow 拒绝域

α : 弃真的概率!!!

区间估计

假设检验

假设检验思想

1° 先假设 H_0 正确，在此假设上

2° 构造某事件 A (它在 H_0 正确条件下，概率很小)



eg $P(A|H_0) = \alpha$

3° 进行试验，若 A 发生，就说一个低概率事件居然发生了，否定 H_0

小概率事件原理

小概率事件在一次试验 (或观察)

是几乎不可能发生的



P_{02}

步骤:

成立时 统计量有什么性质 来确定 W 的边界? 一般是为了指出 E

- (1) 提出 H_0, H_1
- (2) 构造 检验统计量 Z 不含参数. H_0 成立前提下 Z 落在 W 的概率
- (3) 确定拒绝域 W $P_{H_0}\{W\} \leq \alpha$
- (4) 抽样

我认为, 统计量建立起假设 (或 $A \in \Theta$) 与样本的关系 (在样本的条件下)

认为 样本代替了参数 落在拒绝域. P_{01}, P_{10}
估计量

3.2 正态总体参数的假设检验

3.2.1 一个正态总体的情形

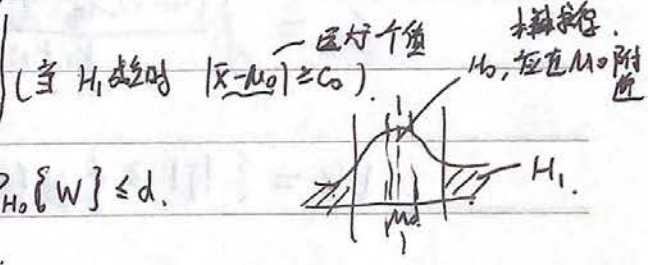
1. μ 的检验. $H_0: \mu = \mu_0 \leftrightarrow H_1: \mu \neq \mu_0$

(1) σ^2 已知. $-\mu$ 检验.

H_0 成立时 $\rightarrow U = \frac{\sqrt{n}(\bar{X} - \mu_0)}{\sigma_0} \sim N(0, 1)$

$W = \{ |U| \geq U_{\alpha/2} \}$

$P_{H_0}\{W\} \leq \alpha$



(2) σ^2 未知. $-t$ 检验.

$$T = \frac{\sqrt{n}(\bar{X} - \mu_0)}{S^*} \sim t(n-1)$$

$$W = \{ |T| \geq t_{\alpha/2}(n-1) \}$$

2. σ^2 的检验. $H_0: \sigma^2 = \sigma_0^2 \leftrightarrow H_1: \sigma^2 \neq \sigma_0^2$

(1) μ 已知 (自证)

$$\frac{\sum_{i=1}^n (X_i - \mu)^2}{\sigma^2} \sim \chi^2(n)$$

(2) μ 未知 - χ^2 检验.

$$\chi^2 = \frac{(n-1)S^{*2}}{\sigma_0^2} \sim \chi^2(n-1)$$

$$W = \{ \chi^2 \leq \chi_{1-\frac{\alpha}{2}}^2(n-1) \cup \chi^2 \geq \chi_{\frac{\alpha}{2}}^2(n-1) \}$$

3-2-2 两个正态总体的情形

1. $\mu_1 - \mu_2 = C$ 的检验.

$\sigma_1^2 = \sigma_2^2 = \sigma^2$. - t 检验.

$$T = \frac{(\bar{X} - \bar{Y}) - C}{S_w \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}} \sim t(n_1 + n_2 - 2)$$

$$S_w = \sqrt{\frac{(n_1-1)S_{n_1}^{*2} + (n_2-1)S_{n_2}^{*2}}{n_1 + n_2 - 2}}$$

$$W = \{ |T| \geq t_{\alpha/2}(n_1 + n_2 - 2) \}$$

2. $\frac{\sigma_1^2}{\sigma_2^2} = C$ 的检验.

(1) μ_1, μ_2 已知 (有证)

$$F = \frac{\frac{\sigma_2^2}{\sigma_1^2} \frac{\sum_{i=1}^{n_1} (X_i - \mu_1)^2}{n_1}}{\frac{\sum_{i=1}^{n_2} (Y_i - \mu_2)^2}{n_2}} = \frac{\frac{\sum_{i=1}^{n_1} (X_i - \mu_1)^2}{n_1}}{C \frac{\sum_{i=1}^{n_2} (Y_i - \mu_2)^2}{n_2}} \sim F(n_1, n_2)$$

(2) μ_1, μ_2 未知 - F 检验.

$$F = \frac{S_{n_1}^{*2}}{C S_{n_2}^{*2}} \sim F(n_1 - 1, n_2 - 1) \quad \text{一般, } E(F) = \frac{n_2 - 1}{n_2 - 3}$$

$\therefore H_0$ 成立时, F 在 $E(F)$ 附近.

$$W = \{ F \leq F_{1-\alpha/2}(n_1-1, n_2-1) \cup F \geq F_{\alpha/2}(n_1-1, n_2-1) \}$$

3.3 非正态总体参数的假设检验.

3.3.1 指数分布的假设检验.

$$H_0: \lambda = \lambda_0 \leftrightarrow H_1: \lambda \neq \lambda_0$$

$$\chi^2 = 2n\lambda_0\bar{X} \sim \chi^2(2n)$$

$$W = \{ 2n\lambda_0\bar{X} \leq \chi^2_{1-\alpha/2}(2n) \cup 2n\lambda_0\bar{X} \geq \chi^2_{\alpha/2}(2n) \}.$$

3.3.2 大样本条件下的参数假设检验. ($n \rightarrow \infty$)

例 $U = \frac{\bar{X} - \mu_0}{S/\sqrt{n}} \xrightarrow{n \rightarrow \infty} N(0, 1)$

$$U = \frac{(\bar{X} - \bar{Y}) - C}{\sqrt{\frac{S_{1n_1}^2}{n_1} + \frac{S_{2n_2}^2}{n_2}}} \xrightarrow{n \rightarrow \infty} N(0, 1).$$

3.4 单侧假设检验.

单侧假设/单边假设.

例 $H_0: \theta \leq \theta_0 \leftrightarrow H_1: \theta > \theta_0.$

复合原假设 $H_0: \mu \geq \mu_0$

$H_1: \mu < \mu_0$

简单

$\mu = \mu_0$
所有检验规则相同

$P\{U \leq \cdot\} < \alpha.$

大数定律符号相反!

符号成立时设为 H_0 .

例 $H_0: \lambda \leq \lambda_0 \leftrightarrow H_1: \lambda > \lambda_0$

$$W = \{ n\lambda_0\bar{X} \leq \chi^2_{\alpha}(2n) \}$$

3.5 非参数假设检验

3.5.1 分布假设检验

1. χ^2 拟合检验

$H_0: X$ 的分布函数 $F = F_0$

n 指若有 n 个样本

$$\sum_{i=1}^r \frac{n}{P_i} \left(\frac{m_i}{n} - P_i \right)^2$$

$$K_n = \sum_{i=1}^r \frac{(m_i - nP_i)^2}{nP_i} = \sum_{i=1}^r \frac{m_i^2}{nP_i} - n \sim \chi^2(r-1)$$

$$W = \{K_n \geq \chi^2_{\alpha}(r-1)\}$$


r 为分成 r 个子集 (区间)

我认为思路: 将 X 分为 r 个区间, 使样本落在每个区间的频率与理论相等

K_n 为实际频率与理论频率加权平方和

要求理论频率 $nP_i \geq 5$
若小于 5 则将区间合并

证明对 $r=2$



$$m_1 \sim b(n, P_1)$$

$$m_1 - nP_1 = (n - m_2) - n(1 - P_2) = nP_2 - m_2$$

$$\text{且 } P_1 + P_2 = 1, m_1 + m_2 = n$$

$$K_n = \frac{(m_1 - nP_1)^2}{nP_1} + \frac{(m_2 - nP_2)^2}{nP_2} = \frac{(m_1 - nP_1)^2 P_2 + (m_2 - nP_2)^2 P_1}{nP_1 P_2} = \frac{(m_1 - nP_1)^2}{nP_1 P_2} \sim \chi^2(1) = \chi^2(r-1)$$

$$\frac{m_1 - nP_1}{\sqrt{nP_1 P_2}} \xrightarrow{L} N(0, 1) \quad n \rightarrow \infty$$

分类数据的拟合优度检验

$H_0: S_i$ 所占比例为 $P_i (i=1, \dots, r)$

设总体 X 为取有限或可列个值 a_1, a_2, \dots, a_k

把相邻的某些 a_i 合并为一类, 使得 a_1, a_2, \dots 被分为有限个类 S_1, \dots, S_r

并使样本观测值 X_1, \dots, X_n 落入每一个 S_i 内个数 m_i 不小于 5, 也 $P(X \in S_i) = P_i (i=1, 2, \dots, r)$

做法: X 为连续 r.v.

选 $r-1$ 个数 $a_1 < a_2 < \dots < a_{r-1}$

$S_1 \dots S_r$

$a_0 = -\infty$

把实数轴分为 r 个区间



$a_r = +\infty$

S_1 S_2 S_r
 $(-\infty, a_1]$ $(a_1, a_2]$ \dots (a_{r-1}, ∞)

当观测值落入第 i 个区间, 看作它属于第 i 类.

在 H_0 成立 $P_i = P(a_{i-1} < X \leq a_i) = F_0(a_i) - F_0(a_{i-1}) \quad i=1, 2, \dots, r.$

$H_0: F = F_0$

若 F_0 有 k 个未知参数 先用参数的极大似然估计 $\hat{\theta}$ 代替.

$K_n \sim \chi^2(r-k-1)$

正态总体的极大似然估计 $\hat{\mu} = \bar{X}$
 $\hat{\sigma}^2 = S^2$

2. 柯尔莫哥洛夫检验 (为分布函数 $F(x)$ 要连续, 且不含未知参数)

思想: n 很大时 $F_n(x)$ 一样本经验分布函数 为 $F(x)$ 的很好近似.

$$D_n = \sup_{-\infty < x < +\infty} |F_n(x) - F(x)| \xrightarrow{a.s.} 0 \quad n \rightarrow \infty$$

→ 将大数定律变得更强 (变为一致)

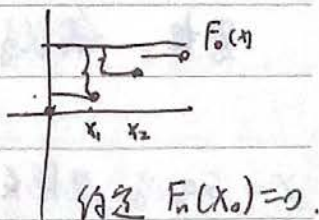
$H_0: F(x) = F_0(x)$

$$D_{nd} \approx \frac{\lambda_{1-d}}{\sqrt{n}} \quad W = \{D_n \geq D_{nd}\}$$

步骤 (1) 将值 x_1, \dots, x_n 排序

(2) 计算经验分布 $F_n(x)$, 和 $F_n(x_i) \quad i=1, \dots, n$

$$d_i = \max[|F_n(x_{i-1}) - F_0(x_i)|, |F_n(x_i) - F_0(x_i)|]$$



(3) $D_n = \sup_{-\infty < x < +\infty} |F_n(x) - F_0(x)| = \max\{d_1, d_2, \dots, d_n\}$

(4) 检验

3.5.2 两个总体之间关系的假设检验

1. 斯米尔诺夫检验

$$H_0: F = G \iff H_1: F \neq G$$

连续 随机变量 X_1, X_2 Y_1, Y_2

$$D_{n_1, n_2} \hat{=} \sup_{-\infty < x < \infty} |F_{n_1}(x) - G_{n_2}(x)|$$

$$W = \{ D_{n_1, n_2} \geq D_{n_1, n_2, d} \}$$

取 $n = \lfloor \frac{n_1 n_2}{n_1 + n_2} \rfloor$ 取整

$$n \leq 100 \quad D_{n_1, n_2, d} \approx D_{nd}$$

$$n > 100 \quad D_{n_1, n_2, d} \approx \frac{\lambda_{nd}}{\sqrt{n}}$$

2. 独立性检验 (利用 χ^2 拟合检验)

$$H_0: F(x, y) \equiv F_x(x) F_y(y) \iff H_1: F(x, y) \neq F_x(x) F_y(y)$$

分成 r 行 分成 s 列

$$H_0: p_{ij} = p_i \cdot p_j \quad i=1, \dots, r; j=1, \dots, s$$

p_i, p_j 共 $r+s-2$ 个未知参数. 用极大似然估计 $\hat{p}_i = \frac{n_i}{n} \quad \hat{p}_j = \frac{n_j}{n}$

$$K_n = \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - n \hat{p}_i \hat{p}_j)^2}{n \hat{p}_i \hat{p}_j} = \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - n \hat{p}_i \hat{p}_j)^2}{n \hat{p}_i \hat{p}_j} = \sum_{i=1}^r \sum_{j=1}^s \frac{(n_{ij} - \frac{n_i n_j}{n})^2}{\frac{n_i n_j}{n}}$$

$$\sim \chi^2((r-1)(s-1))$$

$$= n \left(\sum_{i=1}^r \sum_{j=1}^s \frac{n_{ij}^2}{n_i \cdot n_j} - 1 \right)$$

$$W = \{ K_n \geq \chi_{\alpha}^2((r-1)(s-1)) \} \quad rs - (r+s-2) - 1$$

思想: 我认为 $F = F_0$ —— χ^2 拟合检验
 $F(x, y) \quad \downarrow \quad F_x(x) F_y(y)$

$r=s=2$ 时. 表格

n_{11}	n_{12}	$n_{1\cdot}$
n_{21}	n_{22}	$n_{2\cdot}$
$n_{\cdot 1}$	$n_{\cdot 2}$	

$$K_n = \frac{n(n_{11}n_{22} - n_{12}n_{21})^2}{n_{1\cdot}n_{2\cdot}n_{\cdot 1}n_{\cdot 2}}$$

$$W = \{ K_n \geq \chi_{\alpha}^2(1) \}$$

第4章 方差分析与正交试验设计

4.1 单因素方差分析 → 多个总体均值是否相同

前提：正态总体，同方差，独立样本。

总离差平方和：

$$Q_T = \sum_{i=1}^r \sum_{j=1}^{n_i} (X_{ij} - \bar{X})^2 = \sum_{i=1}^r n_i (\bar{X}_i - \bar{X})^2 + \sum_{i=1}^r \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i)^2$$

组间平方和

$$Q_A = \sum_{i=1}^r n_i (\bar{X}_i - \bar{X})^2 = \sum_{i=1}^r n_i (\delta_i + \bar{\varepsilon}_i - \bar{\varepsilon})^2$$

组内平方和

$$Q_E = \sum_{i=1}^r \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i)^2 = \sum_{i=1}^r \sum_{j=1}^{n_i} (\varepsilon_{ij} - \bar{\varepsilon}_i)^2$$

$$E Q_A = \sum_{i=1}^r n_i \delta_i^2 + (r-1)\sigma^2$$

$$E Q_E = \sum_{i=1}^r (n_i - 1)\sigma^2 = (n-r)\sigma^2$$

对 $E Q_A$ ：

$$E: E\left(\sum_{i=1}^r n_i (\bar{\varepsilon}_i - \bar{\varepsilon})^2\right)$$

$$\bar{\varepsilon}_i \sim (0, \frac{\sigma^2}{n_i}) \quad \bar{\varepsilon} \sim (0, \frac{\sigma^2}{n})$$

$$E(\bar{\varepsilon}^2) = D(\bar{\varepsilon})$$

$$= E\left(\sum_{i=1}^r n_i \bar{\varepsilon}_i^2 + \sum_{i=1}^r n_i \bar{\varepsilon}^2 - \sum_{i=1}^r 2n_i \bar{\varepsilon}_i \bar{\varepsilon}\right)$$

$$= \sum_{i=1}^r n_i \frac{\sigma^2}{n_i} + \sum_{i=1}^r n_i \frac{\sigma^2}{n} - 2E\left(\bar{\varepsilon} \sum_{i=1}^r \frac{n_i \bar{\varepsilon}_i}{n}\right)$$

$$= r\sigma^2 + \sigma^2 - 2\sigma^2 = (r-1)\sigma^2$$

对 $E Q_E$ ：

$$\varepsilon_{ij} \sim N(0, \sigma^2) \quad \bar{\varepsilon}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \varepsilon_{ij}$$

$$E\left(\sum_{i=1}^r \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i)^2\right) = (n-r)\sigma^2$$

↓

构造统计量

$$F = \frac{Q_A / (r-1)}{Q_E / (n-r)} \sim F(r-1, n-r)$$

证明：

柯赫伦定理。

求自由度方法:

设实二次型 $f(x_1, \dots, x_n) = \sum_{i=1}^n (a_{i1}x_1 + \dots + a_{in}x_n)^2$

证 $f(x_1, \dots, x_n)$ 的秩等于矩阵 $A = \begin{bmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{n1} & \dots & a_{nn} \end{bmatrix}$ 的秩

自由度 计算某一统计量时, 取值不受限制的变量个数

$f(x_1, \dots, x_n) = a_{11}x_1^2 + 2a_{12}x_1x_2 + 2a_{13}x_1x_3 + \dots + 2a_{1n}x_1x_n$

$$(x_1 \dots x_n) \begin{pmatrix} a_{11} & \dots & a_{1n} \\ \vdots & & \vdots \\ a_{n1} & \dots & a_{nn} \end{pmatrix} \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix} = \sum_{i=1}^n a_{ii}x_i^2 + \dots$$

方差分析表

方差来源	平方和	自由度	均方和	F值
因素 A (组间)	Q_A	$r-1$	$\bar{Q}_A = \frac{Q_A}{r-1}$	$F = \frac{\bar{Q}_A}{\bar{Q}_E}$
误差 E (组内)	Q_E	$n-r$	$\bar{Q}_E = \frac{Q_E}{n-r}$	
总和	Q_T	$n-1$		

未知参数估计

$$\hat{\mu} = \bar{X}$$

$$\hat{\mu}_i = \bar{X}_i$$

$$\hat{\delta}_i = \bar{X}_i - \bar{X}$$

$$\hat{\sigma}^2 = \frac{Q_E}{n-r} = \bar{Q}_E$$

对 $\mu_i - \mu_k$ 区间估计

不同水平对应总均值 $T = \frac{\bar{X}_i - \bar{X}_k - (\mu_i - \mu_k)}{\sqrt{(\frac{1}{n_i} + \frac{1}{n_k}) \bar{Q}_E}} \sim t(n-r)$

$$P\{|T| < t_{\alpha/2}(n-r)\} = 1 - \alpha$$

$1-\alpha$ 的置信区间为 $(\bar{X}_i - \bar{X}_k \mp t_{\alpha/2}(n-r) \sqrt{(\frac{1}{n_i} + \frac{1}{n_k}) \bar{Q}_E})$

4.2 双因素方差分析

1. 等重复 $r > 1$

交互效应

2. 无重复 $r = 1$

4.3 正交试验设计

正交表

{ 不考虑交互作用
考虑交互作用

首先看水平数。

自由度与正交表

(1) 正交表的总自由度 $f_{总} = \text{试验次数} - 1$

正交表每列的自由度 $f_{列} = \text{水平数} - 1$

(2) 因素 A 的自由度 $f_A = \text{因素 A 的水平数} - 1$

A、B 间交互作用的自由度 $f_{A \times B} = f_A \times f_B$

~~因素~~ 因素 + 交互 自由度 \leq 正交表自由度

1. 直观分析 (极差分析)

T 因素某水平对应指标之和

R

水平数不等时 $\bar{T}_{ij} = T_{ij} / (n_j)$

2. 方差分析

解 $Q_T = Q_A + Q_B + \dots + Q_{\text{交互}} + Q_e$

$$Q_T = \sum_{i=1}^n (y_i - \bar{y})^2$$

$$Q_j (j=A, B, \dots) = \frac{1}{n} \sum_{i=1}^n T_{ij}^2 - \frac{1}{n} \left(\sum_{i=1}^n T_{ij} \right)^2$$

AB 交互时 也按上表计算

第五章 回归分析

5.1 一元线性回归

5.1.1 模型

$$y = a + bx + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2)$$

y 的期望 — $\mu(x) = E(y|x) = a + bx$

y 关于 x 的回归函数

5.1.2 参数估计

1. a, b 最小二乘估计

$$\hat{b} = \frac{\sum_{i=1}^n x_i y_i - n \bar{x} \bar{y}}{\sum_{i=1}^n x_i^2 - n \bar{x}^2}$$

$$\hat{a} = \bar{y} - \hat{b} \bar{x}$$

经验回归: $\hat{y} = \hat{a} + \hat{b}x = \bar{y} + \hat{b}(x - \bar{x})$

2. σ^2 估计

$$\begin{aligned} \hat{\sigma}^2 &= \frac{1}{n} \sum_{i=1}^n (y_i - \hat{a} - \hat{b}x_i)^2 \\ &= \frac{1}{n} \sum_{i=1}^n (y_i - \bar{y})^2 - \frac{\hat{b}^2}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \end{aligned}$$

5.1.3 概率分布

$$l_{xx} \triangleq \sum_{i=1}^n (x_i - \bar{x})^2 = \sum_{i=1}^n x_i^2 - n \bar{x}^2$$

$$l_{yy} \triangleq \sum_{i=1}^n (y_i - \bar{y})^2$$

$$l_{xy} \triangleq \sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y}) = \sum_{i=1}^n (x_i - \bar{x})y_i$$

1. \hat{b} 的分布

$$\hat{b} \sim N\left(b, \frac{\sigma^2}{l_{xx}}\right)$$

2. \hat{a} 的分布 $\hat{a} \sim N\left(a, \left[\frac{1}{n} + \frac{\bar{x}^2}{l_{xx}}\right] \sigma^2\right)$

3. $\hat{\sigma}^2$ 的分布. $\hat{\sigma}^2 = \frac{1}{n} Q_e$

残差平方和 $Q_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \sum_{i=1}^n (y_i - \hat{a} - \hat{b}x_i)^2$

(1) $\frac{Q_e}{\sigma^2} \sim \chi^2(n-2)$

(2) \bar{y}, \hat{b}, Q_e 相互独立.

$\hat{\sigma}^{*2} = \frac{Q_e}{n-2}$ $\hat{\sigma}^{*2}$ 为 σ^2 的无偏估计

$\hat{\sigma}^2 = \frac{n}{n-2} \hat{\sigma}^{*2}$ $\hat{\sigma}^2$ 为 σ^2 的渐近无偏估计

5.1.4 一元线性回归的假设检验 (判断线性回归是否显著)

$H_0: b=0$

$t = \frac{\hat{b}}{\hat{\sigma}^*} \sqrt{l_{xx}} \sim t(n-2)$

$W = \{|t| \geq t_{\alpha/2}(n-2)\}$

另一种

$Q_e = \sum_{i=1}^n (y_i - \hat{y}_i)^2$

\downarrow
 $= \sum_{i=1}^n (y_i - \bar{y})^2 - \hat{b}^2 \sum_{i=1}^n (x_i - \bar{x})^2$

相关系数 $r = \frac{l_{xy}}{\sqrt{l_{xx} l_{yy}}}$

$0 < |r| < 1$

$r=1$ 时 确定的线性关系

S-1.5 预测

点预测

$X = X_0$ 时

$$\hat{y}_0 = \hat{a} + \hat{b} X_0 = \bar{y} + \hat{b} (X_0 - \bar{X})$$

$$t = \frac{y_0 - \hat{y}_0}{\hat{\sigma}^* \sqrt{1 + \frac{1}{n} + \frac{(X_0 - \bar{X})^2}{L_{XX}}}} \sim t(n-2)$$

$$P\{|t| < t_{\alpha/2}(n-2)\} = 1 - \alpha$$

$$P\{\hat{y}_0 - \delta(X_0) < y_0 < \hat{y}_0 + \delta(X_0)\} = 1 - \alpha$$

$$\delta(X_0) = t_{\alpha/2}(n-2) \hat{\sigma}^* \sqrt{1 + \frac{1}{n} + \frac{(X_0 - \bar{X})^2}{L_{XX}}}$$

y_0 的置信度为 $1 - \alpha$ 的预测区间是 $(\hat{y}_0 - \delta(X_0), \hat{y}_0 + \delta(X_0))$.

$X = \bar{X}$ 时 预测精确度最好.

X 在 \bar{X} 附近时 $\delta(X) \approx t_{\alpha/2} \hat{\sigma}^*$.

5.2 多元线性回归.

5.2.1 模型.

$$\mu(x_1, \dots, x_k) = E(y | x_1, \dots, x_k)$$

$$y = b_0 + b_1 x_1 + \dots + b_k x_k + \varepsilon, \varepsilon \sim N(0, \sigma^2)$$

k 元线性回归模型.

n 组数.

$$Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix} \quad B = \begin{bmatrix} b_0 \\ b_1 \\ \vdots \\ b_k \end{bmatrix} \quad \varepsilon = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}$$

$$\begin{cases} Y = XB + \varepsilon \\ \varepsilon \sim N(0, \sigma^2 I_n) \end{cases}$$

5.2.2 参数估计

$$\hat{B} = (X^T X)^{-1} X^T Y \quad \hat{y} = \hat{b}_0 + \hat{b}_1 x_1 + \dots + \hat{b}_k x_k$$

$$\hat{\sigma}^2 = \frac{Q_e}{n-k-1} \quad \text{是 } \sigma^2 \text{ 的无偏估计.}$$

多元回归模型 $y = b_0 + b_1 \frac{x}{x_1} + b_2 \frac{x^2}{x_2} + \dots + \varepsilon \quad \varepsilon \sim N(0, \sigma^2)$

5.2.3 参数估计量的分布及性质

性质 1. $\hat{B} \sim N_{k+1}(B, \sigma^2 (X^T X)^{-1})$.

2. \hat{B} 是 B 的最优线性无偏估计. (最优指 \hat{B} 具有最小协方差)

3. $E\varepsilon = 0$, $\text{cov}(\varepsilon, \varepsilon) = \sigma^2 [I_n - X(X^T X)^{-1} X^T]$
 ε 与 \hat{B} 不相关

$$e = Y - X\hat{B}$$

4. $E(e^T e) = \sigma^2 (n - k - 1)$

5. (1) $\begin{pmatrix} \hat{B} \\ e \end{pmatrix}$ 为正态向量且 \hat{B} 与 e 相互独立.

(2) \hat{B} 与 Q_e 相互独立.

(3) $\frac{Q_e}{\sigma^2} \sim \chi^2(n - k - 1)$

5.2.4 多元线性回归的假设检验

1. 显著性检验

$$Q_r = \frac{n}{k}$$

$$Q_e = \frac{n}{n-k} (y_i - \bar{y})^2$$

$$= \frac{n}{n-k} (\hat{y}_i - \bar{y})^2 + \frac{n}{n-k} (y_i - \hat{y}_i)^2$$

$$Q_t = Q_r + Q_e$$

$$F = \frac{Q_r/k}{Q_e/(n-k-1)} \sim F(k, n-k-1)$$

$$H_0: b_1 = b_2 = \dots = b_k = 0$$

$$W = \{F \geq F_{\alpha}\} \quad C = F_{\alpha}(k, n-k-1)$$

2. 回归系数的显著性检验

$$C = (X^T X)^{-1} \quad C_{jj} \text{ 为对称阵上第 } j \text{ 个元素 } C_{00} \text{ 为第 } 1 \text{ 个}$$

$H_0: b_j = 0$

$$t_j = \frac{\hat{b}_j / \sqrt{C_{jj}}}{\sqrt{Q_e/(n-k-1)}} \sim t(n-k-1)$$

$$W_j = \{|t_j| \geq t_{\alpha/2}(n-k-1)\}$$

5.2.5 预测

$$\hat{y}_0 = \hat{b}_0 + \hat{b}_1 X_{01} + \dots + \hat{b}_k X_{0k}$$

$$t = \frac{y_0 - \hat{y}_0}{\sqrt{\left(1 + \sum_{i=1}^k \sum_{j=1}^k C_{ij} X_{0i} X_{0j}\right) \sqrt{\frac{Q_e}{n-k-1}}}} \sim t(n-k-1)$$

$$P\{|t| \leq t_{\alpha/2}(n-k-1)\}$$

第6章 统计决策与贝叶斯推断

6.1

样本 \rightarrow 行动 $d(x)$ \rightarrow 损失函数 $L(\theta, d(x)) \rightarrow$ 风险 $R(\theta, d)$

最大最小决策函数

$$\text{后验分布 } \pi(\theta|x) = \frac{\pi(\theta)p(x|\theta)}{m(x)} = \frac{\pi(\theta)p(x|\theta)}{\int \pi(\theta)p(x|\theta)d\theta}$$

贝叶斯后验风险

决策区间

6.2 贝叶斯推断

1) 贝叶斯估计

点估计

后验期望估计

$$\pi(\mu|x) \propto \pi(\mu)p(x|\mu)$$

关于 μ 的分布

求出 $\mu|x$ 的分布

$$\hat{\mu} = E(\mu|x)$$

$p(x|\mu)$ 为 X 取到 $x_0 = x$ 的概率 (即密度)

最大后验估计, 后验众数估计

对 $\pi(\mu|x)$ 求导 (可取对数后)

后验中位数估计

求出 $\mu|x$ 的分布函数 F , 令 $F = \frac{1}{2}$

2. 区间估计

属于的分布, 直接求出 $\mu|x$ 的区间

例 $\mu|x \sim N(0,1)$

$$P\{|\mu| < \mu_{\frac{\alpha}{2}} | x\} = 1 - \alpha$$

2) 贝叶斯假设检验.

$$H_0: \mu \in I \Leftrightarrow H_1: \mu \notin I$$

求出 $M|X$ 分布后, 直接求出在以上区间的概率比较

3) 先验分布的选取.

1. 无信息分布 $\pi(\theta) \propto 1$.
信息

2. 共轭先验分布

$\pi(\theta|x)$ 与 $\pi(\theta)$ 是同一类型