

Estadística Paramétrica : Estimogāo Pontual
Intervalos de Confiança

Contexto: Se assume q' x_1, \dots, x_n é uma amostra de X_1, \dots, X_n

desde $f(\cdot; \theta)$ onde a forma de f é conhecida e θ é desconhecido mas θ é estima.

Tipos de Estimogāo P/θ com base em x_1, \dots, x_n .

estatística

(i) Estimogāo pontual: é quando temos função $l(x_1, \dots, x_n)$ e $l(x_1, \dots, x_n)$ estimou o valor desconhecido de $\theta(\theta)$ (função do parâmetro θ desconhecido)

(ii) Estimogāo por intervalo: são definidas duas estatísticas $l_1(x_1, \dots, x_n)$, $l_2(x_1, \dots, x_n)$ tais q' $l_1 < l_2$; assim $(l_1(x_1, \dots, x_n); l_2(x_1, \dots, x_n))$ constitue um intervalo a onde se estima. pertence $\theta(\theta)$.

Exemplo simples: se em n ensaios independentes, com probabilidade de sucesso constante p , (p desconhecido é objeto da estimogāo) observamos k sucessos e $n-k$ fracassos, a nossa estimativa pontual de p .

pode ser: $\frac{k}{n}$ = frequência relativa de sucessos.

Planejamento estatístico

1) Modelos

Métodos para calcular estimadores:

Contexto: x_1, \dots, x_n amostra de $f(\cdot; \theta)$, forma de f conhecida
 θ desconhecido.

θ : pode ser vetor $\theta = (\theta_1, \dots, \theta_k)$

(+) "espaço paramétrico" = conjunto de possíveis valores desse vetor para θ .

Metodologia para P/ estimar θ :

baseados na amostra x_1, \dots, x_n , podemos estimar $(\theta_1, \dots, \theta_k) = \theta$
 ou $\mathcal{G}_1(\theta), \dots, \mathcal{G}_r(\theta)$ construindo estatísticas $l_1(x_1, \dots, x_n), \dots, l_r(x_1, \dots, x_n)$

Def: se $l(x_1, \dots, x_n)$ pode ser usado P/ estimar $\mathcal{G}(\theta)$, digemos q'
 l é um estimador de $\mathcal{G}(\theta)$.

Uma estimativa de $\mathcal{G}(\theta)$ é obtida na hora q' a amostra x_1, \dots, x_n é fixada
 $l(x_1, \dots, x_n)$ = estimativa de $\mathcal{G}(\theta)$.

1) Método dos Momentos: seja $f(\cdot; \theta_1, \dots, \theta_k)$ a densidade de v.a. X
 s. q. $\mu'_r = E(X^r)$ é o momento central de X . Em que $\mu'_r = \mu'_r(\theta_1, \dots, \theta_k)$
 se x_1, \dots, x_n é uma amostra de $f(\cdot; \theta_1, \dots, \theta_k)$ e $M_j^!$ é o j-ésimo
 momento amostral $M_j^! = \frac{1}{n} \sum_{i=1}^n x_i^j$ estimador.
 Os $M_j^!$ $j=1, \dots, k$ constituem k equações $M_j^! = M_j^!(\hat{\theta}_1, \dots, \hat{\theta}_k)$
 com k incógnitas; As soluções de $\{M_j^!\}_{j=1}^k$; $\hat{\theta}_1, \dots, \hat{\theta}_k$ são
 denominadas estimadores. obtidos pelo método dos momentos
 (estimadores de $\theta_1, \dots, \theta_k$).

(3)

Exemplo $\{x_i\}_{i=1}^n$ amostra de $N(\mu, \sigma^2)$.

$$\mu_1 = E(X) = \mu \quad \leftarrow \text{1a m.} \quad \mu_1 = \mu_1(\mu, \sigma^2)$$

$$\mu_2 = E(X^2) = \sigma^2 + \mu^2 \quad \leftarrow \text{2do m.} \quad \mu_2 = \mu_2(\mu, \sigma^2)$$

$$M_1 = \frac{1}{n} \sum_{i=1}^n x_i \quad \leftarrow \text{1a m. amostral}$$

$$M_2 = \frac{1}{n} \sum_{i=1}^n x_i^2 \quad \leftarrow \text{2do m. amostral}$$

$$\begin{cases} M_1 = \mu_1(\hat{\mu}, \hat{\sigma}^2) & ; \quad \frac{1}{n} \sum_{i=1}^n x_i = \hat{\mu} & ; \quad \hat{\mu}_M = \bar{x}_n \\ M_2 = \mu_2(\hat{\mu}, \hat{\sigma}^2) & ; \quad \frac{1}{n} \sum_{i=1}^n x_i^2 = \hat{\sigma}^2 + \hat{\mu}^2 & ; \quad \hat{\sigma}_M^2 = \frac{1}{n} \sum_{i=1}^n x_i^2 - \bar{x}_n^2 \end{cases}$$

$$\boxed{\hat{\mu}_M = \bar{x}_n \quad ; \quad \hat{\sigma}_M^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x}_n)^2}$$

$$* \quad \frac{1}{n} \sum x_i^2 = \hat{\sigma}^2 + \hat{\mu}^2 \Leftrightarrow \frac{1}{n} \sum x_i^2 - \hat{\mu}^2 = \hat{\sigma}^2 \quad \text{i.e. } \frac{1}{n} \sum x_i^2 - (\bar{x})^2 = \hat{\sigma}^2$$

$$** \quad \text{note que } \frac{1}{n} \sum (x_i - \bar{x})^2 = \frac{1}{n} \sum (x_i^2 - 2x_i \bar{x} + \bar{x}^2) =$$

$$= \frac{1}{n} \sum x_i^2 - 2 \bar{x} \sum x_i + n \bar{x}^2 = \frac{1}{n} \sum x_i^2 - 2 \bar{x}^2 + \bar{x}^2 = \frac{1}{n} \sum x_i^2 - \bar{x}^2$$

ou seja $(*)**$ é valido

2) Método de Máximo Verossimilhança:

(3)

Def: Umo fuscão de densidade de n variáveis x_1, \dots, x_n e um parâmetro θ (pode ser k-dimensional), digomos $f(x_1, \dots, x_n; \theta)$ e' chomado verossimilhanga. (a fuscão q' expressa como os dados (amostra) se relaciona com o parâmetro θ)

Nota 1: Se x_1, \dots, x_n e' uma amostra $f(x_1, \dots, x_n; \theta) = \prod_{i=1}^n f(x_i; \theta)$

Nota 2: $f(x_1, \dots, x_n; \theta)$ e' comumente denôdo por $L(\theta; x_1, \dots, x_n)$ e' visto como fuscão de θ para uma sequêcia x_1, \dots, x_n fixa.

Def: Estimador de máximo verossimilhança.

Se $L(\theta) = L(\theta; x_1, \dots, x_n)$ onde (x_1, \dots, x_n) é o vetor observado por (x_1, \dots, x_n) ; então $\hat{\theta} = \hat{\theta}(x_1, \dots, x_n)$ é o estimador de máx. verossimilhança se $\hat{\theta}$ maximiza a função $L^*(\cdot)$. (ou maximiza $\log(L^*)$).

i.e. se $\theta = (\theta_1, \dots, \theta_k)$ e (x_1, \dots, x_n) é uma amostra aleatória.

L satisfez condições de regularidade., $\hat{\theta}$ é tq.

$$\frac{\partial L}{\partial \theta_j}(\hat{\theta}) = 0 \quad \forall j = 1, \dots, k; \quad L(\hat{\theta}) \geq L(\theta) \quad \forall \theta \in \Theta \quad (\text{após prova, metade de } \Theta)$$

i.e. $\hat{\theta} = (\hat{\theta}_1(x_1, \dots, x_n), \hat{\theta}_2(x_1, \dots, x_n), \dots, \hat{\theta}_k(x_1, \dots, x_n))$

Exemplo x_1, \dots, x_n da $N(\mu, \sigma^2)$ (μ, σ^2) desconhecidos.

$$L(\mu, \sigma^2) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x_i-\mu)^2}{2\sigma^2}} = \left(\frac{1}{\sqrt{2\pi\sigma^2}} \right)^n \cdot \exp \left\{ -\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2 \right\}$$

$$\log L(\mu, \sigma^2) = -\frac{n}{2} \cdot \log(2\pi) - \frac{n}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2; \quad \Theta = \left\{ (\mu, \sigma^2), \mu \in \mathbb{R}, \sigma^2 > 0 \right\}$$

$$\frac{\partial \log L}{\partial \mu} = \frac{1}{\sigma^2} \sum_{i=1}^n (x_i-\mu) \quad ; \quad \frac{\partial \log L}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (x_i-\mu)^2$$

$$\boxed{\hat{\mu} = \bar{x} \quad ; \quad \hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2} \quad \begin{matrix} \downarrow \\ \text{estimadores de MV.} \end{matrix}$$

$$\hat{\theta} = (\hat{\mu}, \hat{\sigma}^2)$$

$$\frac{d}{dx} \left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i-\mu)^2 \right) = -\frac{2(x_i-\mu)}{\sigma^2} (-1) \bar{x}^2$$

Seite ④ EP

$$O = \frac{1}{\sigma^2} \sum (x_i - \mu)^2 \quad \text{Sei } \sum x_i = n\mu \quad \text{seu } \hat{\mu} = \frac{\sum x_i}{n}$$

$$O = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum (x_i - \mu)^2 \quad \text{seu } n = \frac{1}{\sigma^2} \sum (x_i - \mu)^2$$

$$\text{i.e. } \hat{\sigma}^2 = \frac{\sum (x_i - \hat{\mu})^2}{n}$$

Estimogar Pontoal, cosos específicos.

EP, catro
spéc.

(5)

- Dist Binomial.
- " Poisson .
- " Normal
- " Exponencial .

Binomial (1) Suponhamos q' uma urna contém um nº de bolas pretas e um nº de bolas brancas . , supz q' conhecemos o radio $\frac{3}{4}$, mas não conhecemos se são 3 pretas + branca ou 3 brancas e 1 preta . Isto é a prob de extraer uma bola preta da urna pode ser $\frac{3}{4}$ ou $\frac{1}{4}$. (se 3 é o nº de bolas pretas na urna ou 1 respectivamente) .

Se n bolas sāo extraídas da urna com reposição e $X = \#$ de bolas extraídas no final das m extacções . $X \sim \text{Bin}(p, n)$

i.e $f(x; p) = \binom{n}{x} p^x q^{n-x} \quad x = 0, 1, 2, \dots, n$

Se tiramos uma amostra de tamanho $n=3$. e pretendemos estimar o val. de p . (ele pode ser $\frac{3}{4}$ ou $\frac{1}{4}$) . tendremos

x	0	1	2	3
$f(x; \frac{3}{4})$	$\frac{1}{64}$	$\frac{9}{64}$	$\frac{27}{64}$	$\frac{27}{64}$
$f(x; \frac{1}{4})$	$\frac{27}{64}$	$\frac{27}{64}$	$\frac{9}{64}$	$\frac{1}{64}$

Então se $x=0$ $\hat{p}(x=0) = \frac{1}{4}$ pois $f(0; \frac{1}{4}) > f(0; \frac{3}{4})$.

Se $x=1$ $\hat{p}(x=1) = \frac{1}{4}$ " $f(1; \frac{1}{4}) > f(1; \frac{3}{4})$

x	\hat{p}
0	0,25
1	0,25
2	0,75
3	0,75

Claramente temos & colhido \hat{p} em função da amostra, obtendo a probabilidade maior.

Esse procedimento confunde a estimativa por máxima verossimilhança.

$$f(x; p) = \binom{n}{x} p^x q^{n-x} \quad x=0, 1, \dots, n$$

uma vez conhecido o valor da amostra x

$$L(p) = \binom{n}{x} p^x (1-p)^{n-x} \quad x \text{ fixo.}$$

$$\begin{aligned} \frac{\partial L}{\partial p} &= x \cdot p^{x-1} \cdot (1-p)^{n-x} \cdot \binom{n}{x} + \binom{n}{x} p^x \cdot (n-x) \cdot (1-p)^{n-x-1} (-1) \\ &= \binom{n}{x} p^{x-1} \cdot (1-p)^{n-x-1} \left\{ x(1-p) - p(n-x) \right\} = 0. \end{aligned}$$

$$\text{Se } p=0, p=1 \text{ ou } x(1-p) - p(n-x) = 0 \\ x - xp + px - np \\ x \neq pn = 0.$$

$$\hat{p} = \frac{x}{n}$$

$$\therefore \hat{p} = \frac{x}{n} = \frac{\# \text{ de bolas pretas encontradas no experimento}}{\# \text{ total de bolas}}$$

: estimador de máxima verossimilhança.

(2) Apresentamos a seguir a estimativa de p proposta pelo método dos momentos

Como é simples de notar, $X \sim \text{Bin}(p, n)$, $X = \sum_{i=1}^n X_i$ e $X_i \sim \text{Bin}(p)$ indep

Então se considerarmos X_1, \dots, X_n , n realizações indep de Y

$Y \sim \text{Bin}(p)$ temos $\mu_1 = E(Y) = p$

Tendo n realizações x_1, \dots, x_n

$$\underbrace{\text{o momento amostral}}_{= M_1} = \frac{1}{n} \sum_{i=1}^n x_i$$

Logo: $\hat{P}_{M_1} = \frac{\sum x_i}{n} = \bar{x}$

$x_i \sim \text{Bin}(n, p)$
 $x_i \sim \text{B}(p)$

Notar que ambos me todos oferecem o mesmo estimador de

$$p: \hat{p} = \bar{x}, \quad \bar{x} = \frac{\sum x_i}{n}, \quad x_i \sim \text{B}(p)$$

(3)

Propriedades do estimador de p : \bar{x}

Visei: $E(\hat{p}) = E(\bar{x}) = E\left(\frac{\sum x_i}{n}\right) = \frac{1}{n} \sum_{i=1}^n E(x_i) = p$

$x_i \sim \text{B}(p)$

 $\therefore \hat{p} = \bar{x} \quad \text{e' mao enunciado}$

(4) Se o objetivo for estimar $p(1-p)$. : fórmulas nãao 1:1 de p . \therefore nãao vale o 1º teo do anexo anterior, se vale o seguinte

(seja $\hat{\theta}$ est. MV. de θ na densidade $f(\cdot, \theta)$ se $\mathcal{C}(\theta)$ = função transf do esforço paramétrico, então $\hat{\theta}$ est. de MV. de $\mathcal{C}(\theta)$, e' $\mathcal{C}(\hat{\theta})$)

Então o estimador de MV de $p(1-p)$ e' $\bar{x}(1-\bar{x})$

(5) Estatística suficiente e critério de fatoração

$$f(x_i) = p^{x_i} (1-p)^{1-x_i} \quad x_i = 0, 1 \quad 0 \leq p \leq 1$$

$$\Rightarrow f(\theta, x_1, \dots, x_n) = p^{\sum x_i} (1-p)^{n-\sum x_i}$$

$\Rightarrow \sum_{i=1}^n x_i$ e' est. suficiente p/ p pelo critério de fatoração

E P 8

Coos portugueses

Continuando com a estimativa não embeleckada de p :

$$\hat{p}_n = \bar{x}_n \quad \bar{x}_n = \frac{\sum x_i}{n}$$

$$\text{Var}(\hat{p}_n) = \frac{1}{n^2} \cdot n \text{Var}(x_i) = \frac{\text{Var}(x_i)}{n} = \frac{p \cdot (1-p)}{n} \xrightarrow{n \rightarrow \infty} 0 \quad x_i \sim \text{Ber}(p)$$

$$\boxed{\hat{p}_n = \bar{x}_n \Rightarrow \text{Var}(\hat{p}_n) \xrightarrow{n \rightarrow \infty} 0}$$

∴ Se considerarmos uma sequência de estimadores de p , baseados em um nº (novo) de realizações de Bernoulli's indep x_1, \dots, x_n .
onde $\left\{ \hat{p}_n = \bar{x}_n \right\}_{n=1}^{\infty}$ a sequência é erro quadrático consistente

pois \hat{p}_n é estimador não embeleckado de p e $\text{Var}(\hat{p}_n) \xrightarrow{n \rightarrow \infty} 0$.

Então \hat{p}_n é consistente simples estimador de p