

Inferência Estatística

1

$$X \sim N(\mu, \sigma^2) \quad E(X) = \mu \quad \text{Var}(X) = \sigma^2$$

$$Y \sim \text{Bernoulli}(p) \quad E(Y) = p \quad \text{Var}(Y) = p(1-p)$$

$$W \sim \text{Exp}(\alpha) \quad E(W) = \frac{1}{\alpha} \quad \text{Var}(W) = \frac{1}{\alpha^2}$$

Geralmente $\mu, \sigma^2, p, \alpha \rightarrow$ parâmetros populacionais desconhecidos

Inferência Estatística - conjunto de técnicas destinadas a tirar conclusões sobre uma população (ou sobre seus parâmetros) com base em evidências fornecidas pela amostra.

Quando utilizamos uma distribuição de probabilidades para modelar a variável de interesse, a característica populacional desconhecida (média, variância populacionais, proporção populacional) se torna um parâmetro de uma distribuição de probabilidades (p. ex.: μ, σ^2, p, α)

Ex: X - altura de indivíduos de uma população

$E(X) = \mu$ - altura média dos indivíduos dessa população

$$Y = \begin{cases} 1 & \text{se o aluno vai fazer vestibular} \\ 0 & \text{caso contrário} \end{cases}$$

$Y \sim \text{Bernoulli}(p)$

p - proporção de alunos na população que vai fazer vestibular

$\mu, p \rightarrow$ parâmetros desconhecidos

Procedimentos Inferenciais: Estimação

Testes de Hipóteses

Tomada uma amostra aleatória (a.c.s. com rep.) da população, os estimadores de μ , σ^2 e p são respectivamente

$$\bar{X} = \frac{X_1 + \dots + X_n}{n} \quad \text{média amostral}$$

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \quad \text{variância amostral}$$

\hat{p} - proporção amostral

Definição 6 - Consistência


Um estimador $\hat{\theta}$ é consistente se

i) $\lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$ (o estimador é assintoticamente não viesado)

e

ii) $\lim_{n \rightarrow \infty} \text{Var}(\hat{\theta}) = 0 \rightarrow$ Para n grande, os

valores de $\hat{\theta}$ são altamente concentrados em torno de sua média que, pelo item a), é aproximadamente θ .



Obs:

Se $\hat{\theta}$ é não viciado, $E(\hat{\theta}) = \theta \quad \forall n$ e

$$\therefore \lim_{n \rightarrow \infty} E(\hat{\theta}) = \theta$$

Se $\hat{\theta}$ é viciado mas é consistente então será não viciado apenas para n grande.

No exemplo 3) de estimação

$$E(X) = \mu \quad \text{Var}(X) = \sigma^2$$

X_1, X_2, \dots, X_n amostra aleatória de X

$$\Rightarrow \bar{X} = \frac{\sum_{i=1}^n X_i}{n} \text{ é não viciado para } \mu \text{ e}$$

$$\text{Var}(\bar{X}) = \frac{\sigma^2}{n}$$

$$\lim_{n \rightarrow \infty} \text{Var}(\bar{X}) = \lim_{n \rightarrow \infty} \frac{\sigma^2}{n} = 0 \quad (1)$$

$$e \quad \lim_{n \rightarrow \infty} E(\bar{X}) = \lim_{n \rightarrow \infty} \mu = \mu \quad (2)$$

(1) e (2)

$\Rightarrow \bar{X}$ é um estimador consistente de μ .

Para n grande, \bar{X} é altamente concentrado em torno de sua média, que é μ , o parâmetro que desejamos estimar.

Exemplo

$X \sim N(\mu, \sigma^2)$. Amostra aleatória de tamanho n .

$$\left. \begin{array}{l} E(\bar{X}) = \mu \\ \text{Var}(\bar{X}) = \frac{\sigma^2}{n} \end{array} \right\} \bar{X} \text{ é não viciado e consistente para } \mu.$$

$$\hat{\mu}_1 = \bar{X}$$

Seja $\hat{\mu}_2 = \text{Med}(X_1, X_2, \dots, X_n) \rightarrow$ mediana

$$\text{Verifica-se que } \left\{ \begin{array}{l} E(\hat{\mu}_2) = \mu \quad (\text{não viciado para } \mu) \\ \text{Var}(\hat{\mu}_2) = \frac{\pi}{2} \frac{\sigma^2}{n} \end{array} \right.$$

$$\text{Como } \lim_{n \rightarrow \infty} \text{Var}(\hat{\mu}_2) = \lim_{n \rightarrow \infty} \frac{\pi \sigma^2}{2n} = 0,$$

$\hat{\mu}_2 = \text{Med}(X_1, X_2, \dots, X_n)$ é um estimador consistente para μ .

$$\text{Mas } \frac{\text{Var}(\hat{\mu}_1)}{\text{Var}(\hat{\mu}_2)} = \frac{\frac{\sigma^2}{n}}{\frac{\pi \sigma^2}{2n}} = \frac{2}{\pi} = 0,63 \Rightarrow$$

$\text{Var}(\hat{\mu}_1) < \text{Var}(\hat{\mu}_2) \Rightarrow \hat{\mu}_1$ é mais eficiente que $\hat{\mu}_2$.

Estimadores para média, proporções e Variância

Parâmetro	Estimador	Propriedades
$\mu = E(X)$	$\bar{X} = \frac{X_1 + X_2 + \dots + X_n}{n}$	Não viciado e Consistente
p	$\hat{p} = \text{proporções amostral}$	Não viciado e Consistente
σ^2	$s^2 = \frac{1}{n-1} (\sum X_i^2 - n\bar{X}^2)$	Não viciado e Consistente

↳ Variância amostral

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad \text{é viciado e consistente}$$

$$E(\hat{\sigma}^2) = \frac{n-1}{n} \sigma^2$$

Demonstração: Pag. 232 Magalhães e Lima

s^2 e $\hat{\sigma}^2$ são consistentes

Como s^2 é não viciado para σ^2 , é usualmente adotado para estimar σ^2 .

Obs;

- A variância ou o desvio padrão de um estimador não viciado fornecem uma ideia de sua precisão, por isso, o desvio padrão do estimador é denominado erro padrão.

$$\text{Erro Padrão}(\bar{x}) = \frac{\sigma}{\sqrt{n}}$$

- Fórmula para cálculo

$$s^2 = \frac{1}{n-1} \left[\sum_{i=1}^n x_i^2 - n\bar{x}^2 \right]$$

Métodos de Obtenção de Estimadores

- Momentos
- Máxima Verossimilhança
- Mínimos Quadrados

Método da Máxima Verossimilhança

X variável aleatória com distribuições de probabilidades que depende de um parâmetro desconhecido θ .

Tomada uma amostra aleatória da v.a. X , X_1, X_2, \dots, X_n , a função de verossimilhança é definida como

$$L(\theta, x_1, x_2, \dots, x_n) = P(X_1 = x_1) P(X_2 = x_2) \dots P(X_n = x_n)$$

se X for discreta e

$$L(\theta, x_1, x_2, \dots, x_n) = f(x_1, \theta) f(x_2, \theta) \dots f(x_n, \theta)$$

$f(x, \theta)$ função densidade de X for contínua

Vista como função de θ .

Definição

O estimador de máxima verossimilhança de θ é o valor $\hat{\theta}_{mv}$ que maximiza $L(\theta, x_1, x_2, \dots, x_n)$.

Exemplo 1

$X \sim \text{Bernoulli}(p)$

x	0	1
$P(X=x)$	1-p	p

↖ fracasso
↗ sucesso

$$P(X=x) = p^x (1-p)^{1-x}$$

↗ $x=0$ $p^0 (1-p)^{1-0} = 1-p$
 ↘ $x=1$ $p^1 (1-p)^{1-1} = p$

↳ forma condensada de escrever a distribuição de Bernoulli

Se p é desconhecido, tomada uma amostra aleatória X_1, X_2, \dots, X_n dessa distribuição

$$\begin{aligned}
 L(\theta, x_1, x_2, \dots, x_n) &= P(X_1=x_1) P(X_2=x_2) \times \dots \times P(X_n=x_n) \\
 &= p^{x_1} (1-p)^{1-x_1} p^{x_2} (1-p)^{1-x_2} \dots p^{x_n} (1-p)^{1-x_n} \\
 &= p^{\sum x_i} (1-p)^{n - \sum x_i} = L(p)
 \end{aligned}$$

$$\ln L(p) = \sum x_i \ln p + (n - \sum x_i) \ln(1-p)$$

$$\frac{\partial \ln L(p)}{\partial p} = \frac{\sum x_i}{p} + (-1) \frac{n - \sum x_i}{1-p}$$

$$\frac{\partial \ln L(p)}{\partial p} = 0 \Rightarrow$$

$$\frac{\sum x_i}{p} - \frac{n - \sum x_i}{1-p} = 0$$

$$\frac{(1-p)\sum x_i - p(n - \sum x_i)}{p(1-p)} = 0$$

$$-np = -\sum x_i$$

$$\hat{p} = \frac{\sum X_i}{n} = \frac{\text{no}^\circ \text{ de sucessos nas } n \text{ repetiç\u00f5es}}{n}$$

Prova-se que $\frac{\partial^2 \ln L(p)}{\partial p^2} < 0$

Exemplo 2

X_1, X_2, \dots, X_n amostra aleatória da dist. exponencial

$$f(x) = \alpha e^{-\alpha x} \quad x > 0$$

$$\begin{aligned} L(\alpha, x_1, x_2, \dots, x_n) &= \alpha e^{-\alpha x_1} \alpha e^{-\alpha x_2} \dots \times \alpha e^{-\alpha x_n} \\ &= \alpha^n e^{-\alpha \sum x_i} \end{aligned}$$

$$\ln L(\alpha) = n \ln \alpha + \ln e^{-\alpha \sum x_i} = n \ln \alpha - \alpha \sum x_i$$

$$\frac{\partial \ln L}{\partial \alpha} = \frac{n}{\alpha} - \sum x_i = 0$$

$$n - \alpha \sum x_i = 0$$

$$\hat{\alpha} = \frac{n}{\sum x_i} = \frac{1}{\bar{X}}$$

$$\frac{\partial^2 \ln L}{\partial \alpha^2} = \frac{-n}{\alpha^2} < 0 \Rightarrow \hat{\alpha} \text{ é ponto de máximo}$$

$$X \sim \text{Exp}(\alpha) \quad E(X) = \mu = \frac{1}{\alpha}$$

$$\therefore \hat{\mu} = \frac{1}{\hat{\alpha}} = \frac{1}{n/\sum x_i} = \frac{\sum x_i}{n} = \bar{X} \text{ é o est. m.v. de } \mu$$

Exemplo 3

X_1, X_2, \dots, X_n amostra aleatória da distribuição $N(\mu, \sigma^2)$, μ e σ^2 desconhecidos.

Obter os estimadores de máxima verossimilhança de μ e σ^2 .

$$f(x) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-\mu)^2}$$

$$L(\mu, \sigma^2, x_1, x_2, \dots, x_n) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi} \sigma} e^{-\frac{1}{2\sigma^2}(x_i-\mu)^2}$$

$$= \left(\frac{1}{2\pi \sigma^2} \right)^{n/2} \exp \left[-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \right]$$

$$\begin{aligned} \ell(\mu, \sigma^2) &= \ln L(\mu, \sigma^2, x_1, x_2, \dots, x_n) = \\ &= -\frac{n}{2} \ln(2\pi) - \frac{n}{2} \ln(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2 \end{aligned}$$

$$\frac{\partial \ell(\mu, \sigma^2)}{\partial \mu} = -\frac{1}{2\sigma^2} (-1) \sum_{i=1}^n 2(x_i - \mu) = 0$$

\Rightarrow

$$\sum (x_i - \mu) = 0 \quad \left[\sum x_i - n\mu = 0 \right]$$

$$\hat{\mu} = \frac{\sum x_i}{n} = \bar{X} \quad \text{Não viciado para } \mu$$

$$\frac{\partial \ell(\mu, \sigma^2)}{\partial \sigma^2} = -\frac{n}{2} \cdot \frac{1}{\sigma^2} + \frac{1}{2\sigma^4} \sum (x_i - \mu)^2$$

$$\frac{-n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum (x_i - \mu)^2 = 0$$

$$\frac{-n\sigma^2 + \sum (x_i - \mu)^2}{2\sigma^4} = 0$$

$$\hat{\sigma}^2 = \frac{\sum (x_i - \bar{X})^2}{n} \quad \text{viciado para } \sigma^2$$

Aproximações da Binomial pela Normal

A aproximação é boa se $np(1-p) > 3$.

Bussolo e Morettin $np > 5$
 $n(1-p) > 5$