

Métodos de Estimação Pontual

Ben Dêvide de Oliveira Batista

6 de março de 2016

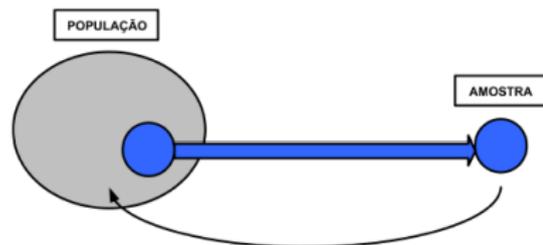
Sumário

1 Inferência Estatística

2 Métodos de estimação pontual

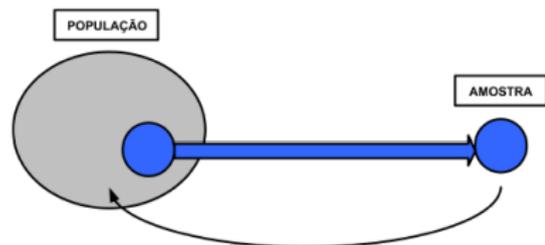
- Método dos momentos
- Método da Máxima Verossimilhança
- Método dos Mínimos Quadrados

Estimação



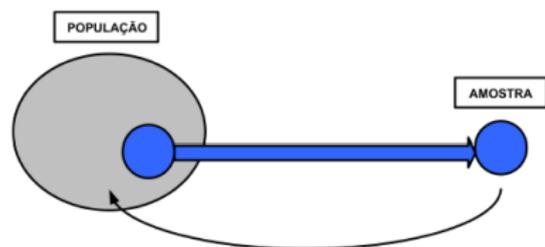
Estimação

- X_1, X_2, \dots, X_n



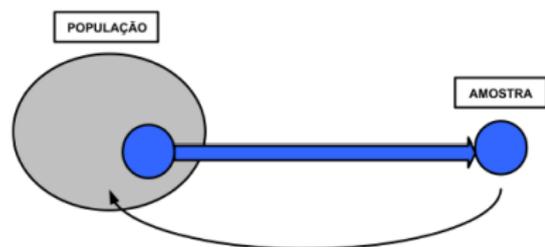
Estimação

- $X_1, X_2, \dots, X_n \Rightarrow T_n = t(X_1, X_2, \dots, X_n)$



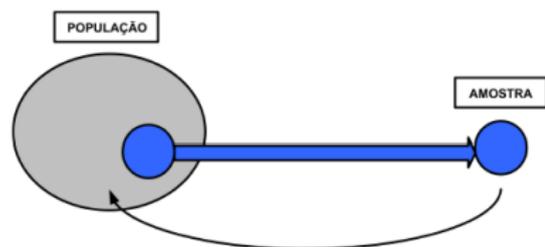
Estimação

- $X_1, X_2, \dots, X_n \Rightarrow T_n = t(X_1, X_2, \dots, X_n)$
- T_n (Estimador Pontual) $\rightarrow \theta$ (Parâmetro)



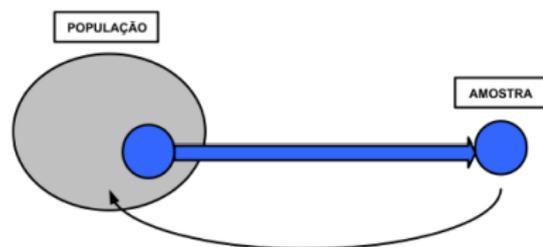
Estimação

- $X_1, X_2, \dots, X_n \Rightarrow T_n = t(X_1, X_2, \dots, X_n)$
- T_n (Estimador Pontual) $\rightarrow \theta$ (Parâmetro)
- Métodos de estimação pontual:



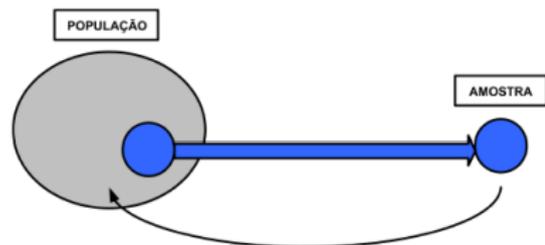
Estimação

- $X_1, X_2, \dots, X_n \Rightarrow T_n = t(X_1, X_2, \dots, X_n)$
- T_n (Estimador Pontual) $\rightarrow \theta$ (Parâmetro)
- Métodos de estimação pontual:
 - Método dos momentos



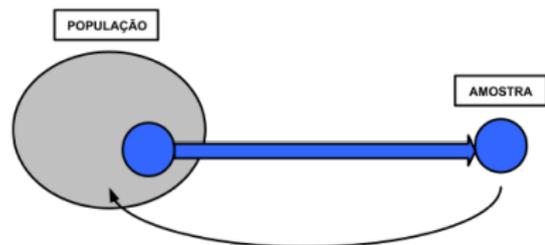
Estimação

- $X_1, X_2, \dots, X_n \Rightarrow T_n = t(X_1, X_2, \dots, X_n)$
- T_n (Estimador Pontual) $\rightarrow \theta$ (Parâmetro)
- Métodos de estimação pontual:
 - Método dos momentos
 - Método da Máxima Verossimilhança



Estimação

- $X_1, X_2, \dots, X_n \Rightarrow T_n = t(X_1, X_2, \dots, X_n)$
- T_n (Estimador Pontual) $\rightarrow \theta$ (Parâmetro)
- Métodos de estimação pontual:
 - Método dos momentos
 - Método da Máxima Verossimilhança
 - Método dos Mínimos Quadrados



Definição 1 (Momentos amostrais)

Seja uma amostra aleatória X_1, X_2, \dots, X_n com fdp ou fp $f_X(x; \theta)$, com $\theta = [\theta_1, \theta_2, \dots, \theta_k]' \in \Theta$ em que Θ é o espaço paramétrico. O k -ésimo momento amostral, denotado por M_k , é definido por

$$M_k = \frac{1}{n} \sum_{i=1}^n X_i^k, \quad (1)$$

e o k -ésimo momento amostral em torno da média amostral \bar{X} , denotado por M'_k , é definido por

$$M'_k = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^k. \quad (2)$$

Definição 2 (Momentos populacionais)

Seja uma amostra aleatória X_1, X_2, \dots, X_n com fdp ou fp $f_X(x; \theta)$, com $\theta = [\theta_1, \theta_2, \dots, \theta_k]'$ $\in \Theta$ em que Θ é o espaço paramétrico. O k -ésimo momento populacional, denotado por μ_k , é definido por

$$\mu_k = E[X^k], \quad (3)$$

e o k -ésimo momento populacional em torno da média populacional $\mu = E[X]$, denotado por μ'_k , é definido por

$$\mu'_k = E[(X - \mu)^k]. \quad (4)$$



Definição 2 (Momentos populacionais)

Seja uma amostra aleatória X_1, X_2, \dots, X_n com fdp ou fp $f_X(x; \theta)$, com $\theta = [\theta_1, \theta_2, \dots, \theta_k]'$ $\in \Theta$ em que Θ é o espaço paramétrico. O k -ésimo momento populacional, denotado por μ_k , é definido por

$$\mu_k = E[X^k], \quad (3)$$

e o k -ésimo momento populacional em torno da média populacional $\mu = E[X]$, denotado por μ'_k , é definido por

$$\mu'_k = E[(X - \mu)^k]. \quad (4)$$



Geralmente μ_k ou μ'_k é função dos k parâmetros $\theta_1, \theta_2, \dots, \theta_k$

Definição 3 (Método dos momentos)

O método dos momentos consiste em igualar (1) e (3) ou (2) e (4), formando as k equações

$$M_j = \mu_j(\theta_1, \theta_2, \dots, \theta_k), \text{ para } j = 1, 2, \dots, k, \quad (5)$$

ou

$$M'_j = \mu'_j(\theta_1, \theta_2, \dots, \theta_k), \text{ para } j = 1, 2, \dots, k, \quad (6)$$

sendo $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k$ suas soluções. Diremos que $\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_k$ são os estimadores de $\theta_1, \theta_2, \dots, \theta_k$ pelo método dos momentos.

Exemplo 1

Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma normal com média μ e variância σ^2 desconhecidos. Denote $(\theta_1, \theta_2) = \mu, \sigma^2$. Vamos estimar os parâmetros μ e σ^2 pelo método dos momentos.

Definição 4 (Função de verossimilhança)

Seja uma amostra aleatória X_1, X_2, \dots, X_n (iid) com fdp ou fp conjunta $f_{\mathbf{X}}(\mathbf{x}; \theta)$, com $\theta \in \Theta$ em que Θ é o espaço paramétrico. Considere ainda x_1, x_2, \dots, x_n a realização da amostra aleatória X_1, X_2, \dots, X_n , então a função de verossimilhança é definida por

$$L(\theta; x_1, x_2, \dots, x_n) = L(\theta; \mathbf{x}) = f_{\mathbf{X}}(\mathbf{x}; \theta) = \prod_{i=1}^n f_X(x_i; \theta). \quad (7)$$

Definição 5 (Método da máxima verossimilhança)

Seja uma função de verossimilhança $L(\theta; x_1, x_2, \dots, x_n)$ para uma amostra aleatória X_1, X_2, \dots, X_n . Então o método da máxima verossimilhança é a forma de encontrar um $\hat{\theta} = \vartheta(x_1, x_2, \dots, x_n)$, que é o valor estimado de $\theta \in \Theta$ que maximiza $L(\theta; x_1, x_2, \dots, x_n)$. Dizemos que $\hat{\theta} = \vartheta(X_1, X_2, \dots, X_n)$ é o estimador de máxima verossimilhança de θ .

- Para maximizar $L(\theta; x_1, x_2, \dots, x_n)$, tomamos a sua derivada em relação a θ , igualamos a zero e resolvemos o sistema para obtenção de $\hat{\theta} = \vartheta(X_1, X_2, \dots, X_n)$;

- Para maximizar $L(\theta; x_1, x_2, \dots, x_n)$, tomamos a sua derivada em relação a θ , igualamos a zero e resolvemos o sistema para obtenção de $\hat{\theta} = \vartheta(X_1, X_2, \dots, X_n)$;
- Posteriormente, devemos identificar se a segunda derivada de $L(\theta; x_1, x_2, \dots, x_n)$ é negativa para saber se $\hat{\theta}$ é um ponto de máximo.

- Para maximizar $L(\theta; x_1, x_2, \dots, x_n)$, tomamos a sua derivada em relação a θ , igualamos a zero e resolvemos o sistema para obtenção de $\hat{\theta} = \vartheta(X_1, X_2, \dots, X_n)$;
- Posteriormente, devemos identificar se a segunda derivada de $L(\theta; x_1, x_2, \dots, x_n)$ é negativa para saber se $\hat{\theta}$ é um ponto de máximo.
- Muitas vezes esse processo torna-se complicado.

Definição 6 (Função de Log-verossimilhança)

Se $L(\theta; x_1, x_2, \dots, x_n)$, expressão (7), é a função de verossimilhança, então

$$l(\theta; \mathbf{x}) = \ln L(\theta; \mathbf{x}) = \log L(\theta; \mathbf{x}), \quad (8)$$

é a função de log-verossimilhança, para $\mathbf{x} = [x_1, x_2, \dots, x_n]'$.

Exemplo 2

Seja uma amostra aleatória X_1, X_2, \dots, X_n de uma normal com média μ e variância $\sigma^2 = 1$. Vamos obter o estimador de μ pelo método da máxima verossimilhança.

■ Modelo de regressão:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\theta} + \boldsymbol{\varepsilon}, \quad (9)$$

$$\mathbf{Y}_{n \times 1} = \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix}, \quad \mathbf{X}_{n \times p'} = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1p} \\ 1 & x_{21} & x_{22} & \dots & x_{2p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{np} \end{bmatrix},$$

$$\boldsymbol{\theta}_{p' \times 1} = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_p \end{bmatrix} \quad \text{e} \quad \boldsymbol{\varepsilon}_{n \times 1} = \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \vdots \\ \varepsilon_n \end{bmatrix}, \quad p' = p + 1$$

- Modelo de regressão:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\theta} + \boldsymbol{\varepsilon}, \quad (10)$$

As pressuposições para esse modelo são:

- $E[\boldsymbol{\varepsilon}] = \mathbf{0}$, sendo $\mathbf{0}$ um vetor de zeros de dimensão $n \times 1$, ou equivalentemente $E[\mathbf{Y}] = \mathbf{X}\boldsymbol{\theta}$;

- Modelo de regressão:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\theta} + \boldsymbol{\varepsilon}, \quad (10)$$

As pressuposições para esse modelo são:

- $E[\boldsymbol{\varepsilon}] = \mathbf{0}$, sendo $\mathbf{0}$ um vetor de zeros de dimensão $n \times 1$, ou equivalentemente $E[\mathbf{Y}] = \mathbf{X}\boldsymbol{\theta}$;
- $Var[\boldsymbol{\varepsilon}] = \mathbf{I}\sigma^2$, sendo \mathbf{I} uma matriz identidade de dimensão $n \times n$, ou equivalentemente $Var[\mathbf{Y}] = \mathbf{I}\sigma^2$;

- Modelo de regressão:

$$\mathbf{Y} = \mathbf{X}\boldsymbol{\theta} + \boldsymbol{\varepsilon}, \quad (10)$$

As pressuposições para esse modelo são:

- $E[\boldsymbol{\varepsilon}] = \mathbf{0}$, sendo $\mathbf{0}$ um vetor de zeros de dimensão $n \times 1$, ou equivalentemente $E[\mathbf{Y}] = \mathbf{X}\boldsymbol{\theta}$;
- $Var[\boldsymbol{\varepsilon}] = \mathbf{I}\sigma^2$, sendo \mathbf{I} uma matriz identidade de dimensão $n \times n$, ou equivalentemente $Var[\mathbf{Y}] = \mathbf{I}\sigma^2$;
- $cov[\varepsilon_i, \varepsilon_j] = 0$ para todo $i \neq j$, ou equivalentemente, $cov[Y_i, Y_j] = 0$.

Teorema 1 (Método de mínimos quadrados)

Se $Y = X\theta + \varepsilon$, em que X é $n \times p'$ de posto $p' < n$, então o valor de $\hat{\theta} = [\hat{\beta}_0, \hat{\beta}_1, \dots, \hat{\beta}_p]'$ que minimiza $\varepsilon'\varepsilon$ é igual a

$$\hat{\theta} = (X'X)^{-1}X'Y. \quad (11)$$

Assim, $\hat{\theta}$ é conhecido como estimador de mínimos quadrados de θ .

Exemplo 3

Seja um modelo de regressão linear simples do tipo

$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i$ para $i = 1, 2, \dots, n$. De modo matricial, temos

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_n \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix},$$

em que está desejando estudar a relação entre a distância (pés) que um carro percorre até sua parada em função da velocidade limite (milhas por hora). (Dados: cars do programa R)