

# Estimação

**Parâmetro:** funções de valores populacionais.

**Estatística:** funções de valores amostrais.

**Exemplo 11.1.** Uma amostra de  $n = 500$  pessoas de uma cidade é escolhida, e a cada pessoa da amostra é feita uma pergunta a respeito de um problema municipal, para o qual foi apresentada uma solução pela prefeitura. A resposta à pergunta poderá ser SIM (favorável à solução) ou NÃO (contrária à solução). Deseja-se estimar a proporção de pessoas na cidade favoráveis à solução apresentada.

Se 300 pessoas responderam SIM à pergunta, então uma estimativa natural para essa proporção seria 300/500 ou 60%. Nossa resposta é baseada na suposição de que a amostra é representativa da população. Sabemos, também, que outra amostra poderia levar a outra estimativa. Conhecer as propriedades desses *estimadores* é um dos propósitos mais importantes da Inferência Estatística.

Definamos as v.a.  $X_1, \dots, X_n$ , tais que:

$$X_i = \begin{cases} 1, & \text{se a } i\text{-ésima pessoa na amostra responder SIM,} \\ 0, & \text{se a } i\text{-ésima pessoa na amostra responder NÃO,} \end{cases}$$

e seja  $p = P$  (sucesso), onde aqui *sucesso* significa resposta SIM à questão formulada.

$$\hat{p} = \frac{Y_n}{n} = \frac{\sum_{i=1}^n X_i}{n} = \frac{\text{número de SIM}}{\text{número de indivíduos}}. \quad (11.1)$$

$$E(\hat{p}) = p, \quad (11.2)$$

$$\text{Var}(\hat{p}) = p(1 - p)/n. \quad (11.3)$$

(11.2): estimador **não-viesado** (ou não-viciado) de  $p$ .

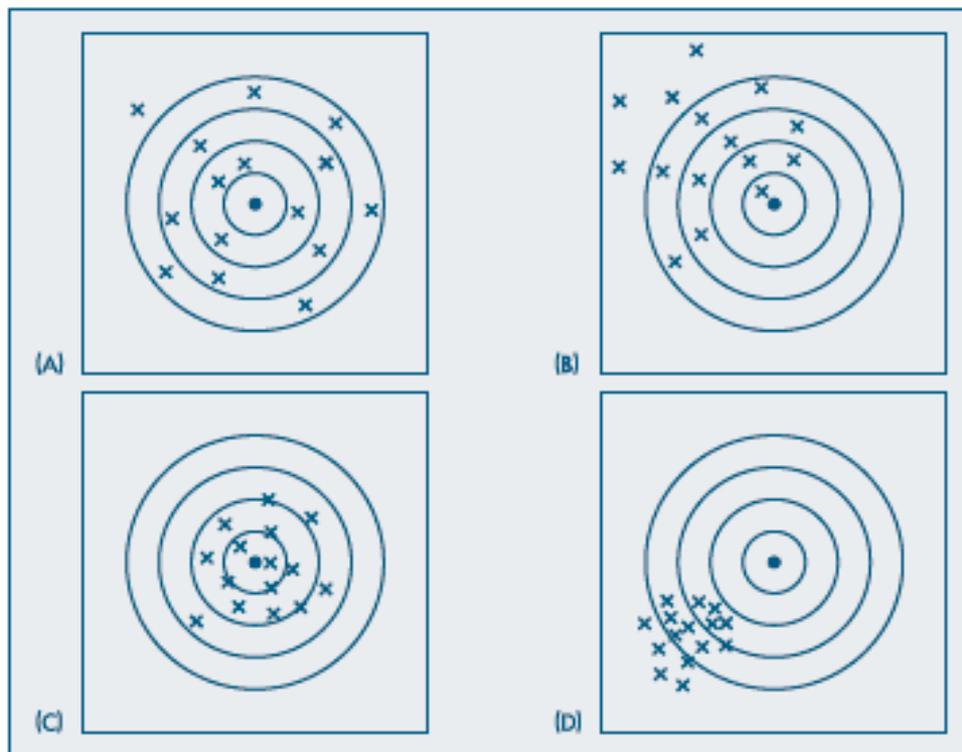
(11.3): estimador **consistente** de  $p$ .

# Estimação

Em algumas situações, podemos ter mais de um estimador para um mesmo parâmetro, e desejamos saber qual deles é “melhor”. O julgamento pode ser feito analisando as propriedades desses estimadores.

**Exemplo:** Desejamos comprar um rifle e, após algumas seleções, restaram quatro alternativas, que chamaremos de rifles A, B, C e D. Foi feito um teste com cada rifle, que consistiu em fixá-lo num cavalete, mirar o centro de um alvo e disparar 15 tiros. Qual é a melhor arma?

Figura 11.1: Resultados de 15 tiros dados por 4 rifles.



Desse modo, podemos descrever cada arma da seguinte maneira:

Arma A: não-viesada, pouco acurada e baixa precisão.

Arma B: viesada, pouco acurada e baixa precisão.

Arma C: não-viesada, muito acurada e boa precisão.

Arma D: viesada, pouco acurada e alta precisão.

## Critérios:

1. Em média acertar o alvo: A e C;
2. Não ser muito dispersivo: C e D.

**Acurácia:** mede a proximidade de cada observação do **valor alvo** que se procura atingir.

**Precisão:** mede a proximidade de cada observação da **média** de todas as observações

# Estimação

## Propriedades de estimadores

**Definição:** um **estimador**  $T$  do parâmetro  $\theta$  é qualquer função das observações da amostra, ou seja,

$$T=f(X_1, \dots, X_n).$$

**Definição:** o estimador  $T$  é **não viesado** para  $\theta$  se

$$E(T) = \theta$$

**Definição:** **Estimativa** é o valor assumido pelo estimador em uma particular amostra.

Uma sequência  $\{T_n\}$  de estimadores de  $\theta$  é **consistente** se

$$\lim_{n \rightarrow \infty} E(T_n) = \theta \text{ e } \lim_{n \rightarrow \infty} \text{Var}(T_n) = 0$$

**Definição:** Se  $T$  e  $T'$  são dois estimadores **não-viesados** de um mesmo parâmetro  $\theta$ , e ainda  $\text{Var}(T) < \text{Var}(T')$ , então  $T$  diz-se **mais eficiente** do que  $T'$ .

**Exemplo 11.4.** Considere uma população com  $N$  elementos e a variância populacional

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (X_i - \mu)^2, \quad (11.5)$$

onde  $\mu = \frac{1}{N} \sum_{i=1}^N X_i$  é a média populacional. Um possível estimador para  $\sigma^2$ , baseado numa AAS de tamanho  $n$  extraída dessa população, é

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (X_i - \bar{X})^2. \quad (11.6)$$

Mostremos que esse estimador é viesado. Pela fórmula (3.11), temos que

$$\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n X_i^2 - \bar{X}^2,$$

logo

$$E(\hat{\sigma}^2) = \frac{1}{n} \sum_{i=1}^n E(X_i^2) - E(\bar{X}^2).$$

Mas, pela definição de AAS e definição de variância de uma v.a.,  $E(X_i^2) = \text{Var}(X_i) + [E(X_i)]^2 = \sigma^2 + \mu^2$ . Também, usando o Teorema 10.1, temos que  $E(\bar{X}^2) = \text{Var}(\bar{X}) + [E(\bar{X})]^2 = \frac{\sigma^2}{n} + \mu^2$ .

Seque-se que

$$E(\hat{\sigma}^2) = \frac{1}{n} \sum_{i=1}^n (\sigma^2 + \mu^2) - \left( \frac{\sigma^2}{n} + \mu^2 \right),$$

ou seja,

$$E(\hat{\sigma}^2) = \frac{1}{n} (n(\sigma^2 + \mu^2)) - \frac{\sigma^2}{n} - \mu^2 = \sigma^2 - \frac{\sigma^2}{n} = \sigma^2 \left( 1 - \frac{1}{n} \right).$$

Finalmente,

$$E(\hat{\sigma}^2) = \left( \frac{n-1}{n} \right) \sigma^2. \quad (11.7)$$

De (11.7) vemos que  $\hat{\sigma}^2$  é viesado para  $\sigma^2$  e o viés é dado por

$$V = V(\hat{\sigma}^2) = E(\hat{\sigma}^2) - \sigma^2 = -\frac{\sigma^2}{n}. \quad (11.8)$$

Como esse viés é negativo, o estimador  $\hat{\sigma}^2$  em geral subestima o verdadeiro parâmetro  $\sigma^2$ . Por outro lado, por (11.8), o viés diminui com  $n$ , ou seja, formalmente, para  $n \rightarrow \infty$ , o viés de  $\hat{\sigma}^2$  tende a zero. Note também que o viés de  $\hat{\sigma}^2$  é uma função de  $\sigma^2$ . Uma estimativa do viés seria dada por

$$\hat{V} = -\frac{\hat{\sigma}^2}{n},$$

ou seja, substituímos o valor desconhecido de  $\sigma^2$  por uma estimativa, como por exemplo  $\hat{\sigma}^2$ .

É fácil ver que para obter um estimador não-viesado de  $\sigma^2$  basta considerar  $(n/(n-1))\hat{\sigma}^2$ , pois de (11.7) segue-se que

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

Logo, se definirmos

$$S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2, \quad (11.9)$$

então  $E(S^2) = \sigma^2$  e  $S^2$  é um estimador não-viesado para  $\sigma^2$ . Essa é a razão para se usar  $n-1$ , em vez de  $n$ , como denominador da variância da amostra.

**Exemplo 11.5.** Vimos que  $S^2$ , dado por (11.9), é não-viesado para  $\sigma^2$ . É possível demonstrar, no caso que  $X_1, \dots, X_n$  são observações de uma distribuição  $N(\mu, \sigma^2)$ , que

$$\text{Var}(S^2) = \frac{2\sigma^4}{n-1}. \quad (11.13)$$

Como  $E(S^2) = \sigma^2$ , e  $\lim_{n \rightarrow \infty} \text{Var}(S^2) = 0$ , segue-se que  $S^2$  é um estimador consistente para  $\sigma^2$ . Dado o que foi dito acima, talvez fosse melhor escrever  $S_n^2$ .

**Exemplo 11.6.** Vimos que  $E(\hat{\sigma}^2) = \sigma^2(1 - 1/n)$ , de modo que  $\lim_{n \rightarrow \infty} E(\hat{\sigma}^2) = \sigma^2$ . Também, de (11.6) e (11.13) e supondo que as observações são de uma distribuição normal  $N(\mu, \sigma^2)$ , temos que

$$\text{Var}(\hat{\sigma}^2) = \left(\frac{n-1}{n}\right)^2 \text{Var}(S^2) = \frac{n-1}{n^2} (2\sigma^4), \quad (11.14)$$

o que mostra que  $\text{Var}(\hat{\sigma}^2) \rightarrow 0$ , quando  $n \rightarrow \infty$ , logo  $\hat{\sigma}^2 = \hat{\sigma}_n^2$  também é consistente para  $\sigma^2$ .

De (11.14) obtemos, também, que

$$\text{Var}(\hat{\sigma}^2) < \frac{2\sigma^4}{n-1} = \text{Var}(S^2). \quad (11.15)$$

# Estimação

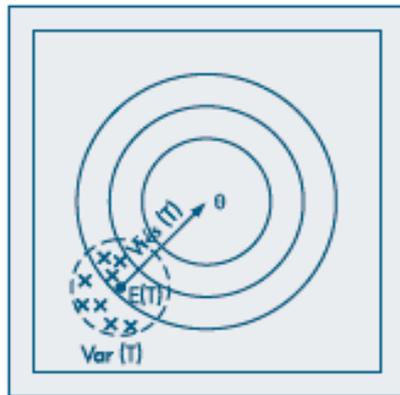
## Propriedades de estimadores

$e = T - \theta$ : o erro amostral que cometemos ao estimar o parâmetro  $\theta$  da distribuição da v.a.  $X$  pelo estimador  $T=f(X_1, \dots, X_n)$ , baseado na amostra  $(X_1, \dots, X_n)$ .

Definição: Chama-se erro quadrático médio (EQM) do estimador  $T$  ao valor

$$\text{EQM}(T; \Theta) = E(e^2) = E(T - \theta)^2 = \text{Var}(T) + (\text{viés de } T)^2$$

Figura 11.2: Representação gráfica para o EQM.



Um estimador preciso tem variância pequena, mas pode ter EQM grande.