

**- Inferência Estatística -
Distribuição Amostral**

Objetivo: tirar conclusões sobre uma população com base na informação de uma amostra.

→ estimação

→ testes de hipóteses

Parâmetro: quantidades desconhecidas da população e sobre as quais temos interesse.

Ex: μ - média da população

Estimador: combinação dos elementos da amostra, construída com a finalidade de representar, ou estimar, um parâmetro de interesse na população.

Ex: \bar{X} - média da amostra (estimador de μ)

Estimativa: valor numérico assumido pelo estimador.

Ex: \bar{x} é o valor de \bar{X} para a amostra observada.

Estudamos algumas distribuições teóricas de probabilidade: distribuição *binomial* e *normal*.

Probabilidade \Rightarrow os parâmetros da distribuição eram conhecidos \Rightarrow calculamos probabilidades

Inferência \Rightarrow os valores desses parâmetros não são conhecidos.

A amostra deve ser “representativa” da população da qual ela é selecionada.

Se não for, as conclusões extraídas sobre a população podem estar distorcidas ou viesadas.

Exemplos:

1. Fazer uma afirmação sobre o nível sérico médio de colesterol para todos os homens de 20 a 74 anos de idade \Rightarrow amostramos somente homens acima de 60 anos \Rightarrow é provável que nossa estimativa da média da população seja muito alta.
2. Estimar a proporção de eleitores que pretendem votar no candidato A \Rightarrow amostra é selecionada dentro da USP.

\rightarrow Que estimador usar nos exemplos acima?


(X_1, X_2, \dots, X_n) \Rightarrow representa uma amostra de tamanho n .
Estimador $\Rightarrow f(X_1, X_2, \dots, X_n)$.

Os estimadores \bar{X} (média amostral) e \hat{p} (proporção amostral) são intuitivos e têm boas propriedades.

Estimadores são funções de variáveis aleatórias e, portanto, eles também são variáveis aleatórias.

Conseqüentemente, têm uma distribuição de probabilidades, denominada **distribuição amostral** do estimador.

Figura 10.1: (a) Esquema de inferência sobre θ .
(b) Distribuição amostral da estatística T .



Distribuição amostral da média

Exemplo 1: Considere uma população em que uma variável X assume um dos valores do conjunto $\{1, 3, 5, 5, 7\}$. A distribuição de probabilidade de X é dada por

x	1	3	5	7
$P(X = x)$	1/5	1/5	2/5	1/5

É fácil ver que $\mu_x = E(X) = 4,2$
e $\sigma_x^2 = \text{Var}(X) = 4,16$.

Vamos relacionar todas as amostras possíveis de tamanho $n = 2$, selecionadas ao acaso e com reposição dessa população, e encontrar a distribuição da média amostral de

$$\bar{X} = \frac{X_1 + X_2}{2},$$

sendo

X_1 : valor selecionado na primeira extração,

X_2 : valor selecionado na segunda extração.

Amostra (X_1, X_2)	Probabilidade	Média Amostral
(1,1)	1/25	1
(1,3)	1/25	2
(1,5)	2/25	3
(1,7)	1/25	4
(3,1)	1/25	2
(3,3)	1/25	3
(3,5)	2/25	4
(3,7)	1/25	5
(5,1)	2/25	3
(5,3)	2/25	4
(5,5)	4/25	5
(5,7)	2/25	6
(7,1)	1/25	4
(7,3)	1/25	5
(7,5)	2/25	6
(7,7)	1/25	7
	1	

A distribuição de probabilidade de \bar{X} para $n = 2$ é

\bar{x}	1	2	3	4	5	6	7
$P(\bar{X} = \bar{x})$	1/25	2/25	5/25	6/25	6/25	4/25	1/25

Neste caso, $E(\bar{X}) = 4,2 = \mu_X$

e $\text{Var}(\bar{X}) = 2,08 = \frac{\sigma_X^2}{2}$.

Repetindo o mesmo procedimento, para amostras de tamanho $n = 3$, temos a seguinte distribuição de probabilidade de \bar{X} ,


\bar{x}	$P(\bar{X} = \bar{x})$
1	1/125
5/3	3/125
7/3	9/125
3	16/125
11/3	24/125
13/3	27/125
5	23/125
17/3	15/125
19/3	6/125
7	1/125

Neste caso,

$$E(\bar{X}) = 4,2 = \mu_X$$

$$\text{e } \text{Var}(\bar{X}) = 1,39 = \frac{\sigma_X^2}{3} .$$

Figura 1: Histogramas correspondentes às distribuições de X e de \bar{X} , para amostras de $\{1,3,5,5,7\}$.



Dos histogramas, observamos que


- conforme n aumenta, os valores de \bar{X} tendem a se concentrar cada vez mais em torno de

$$E(\bar{X}) = 4,2 = \mu_x ,$$

uma vez que a variância vai diminuindo;

- os casos extremos passam a ter pequena probabilidade de ocorrência;
- para n suficientemente grande, a forma do histograma *aproxima-se de uma distribuição normal*.

Figura 2: Histogramas correspondentes às distribuições de \bar{X} para amostras de algumas populações



Fonte: BUSSAB & MORETTIN. *Estatística Básica*. São Paulo, Atual, 4ª edição, 2002, pp. 273.

Esses gráficos sugerem que,

quando n aumenta, independentemente da forma da distribuição de X , a distribuição de probabilidade da média amostral \bar{X} aproxima-se de uma distribuição normal.

Teorema do Limite Central

Seja X uma v. a. que tem média μ e variância σ^2 .
Para amostras X_1, X_2, \dots, X_n , retiradas ao acaso e com reposição de X , a distribuição de probabilidade da média amostral \bar{X} aproxima-se, para n grande, de uma distribuição normal, com média μ e variância σ^2 / n , ou seja,

$$\bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right), \text{ para } n \text{ grande, aproximadamente.}$$

Comentários:

- Se a distribuição de X é normal, então \bar{X} tem distribuição normal *exata*, ***para todo n*** .

- O desvio padrão $\sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$ é denominado

erro padrão da média.

Considere uma amostra aleatória de tamanho n de uma variável $N(10, 16)$.

→ Como se comporta \bar{X} em função de n ?

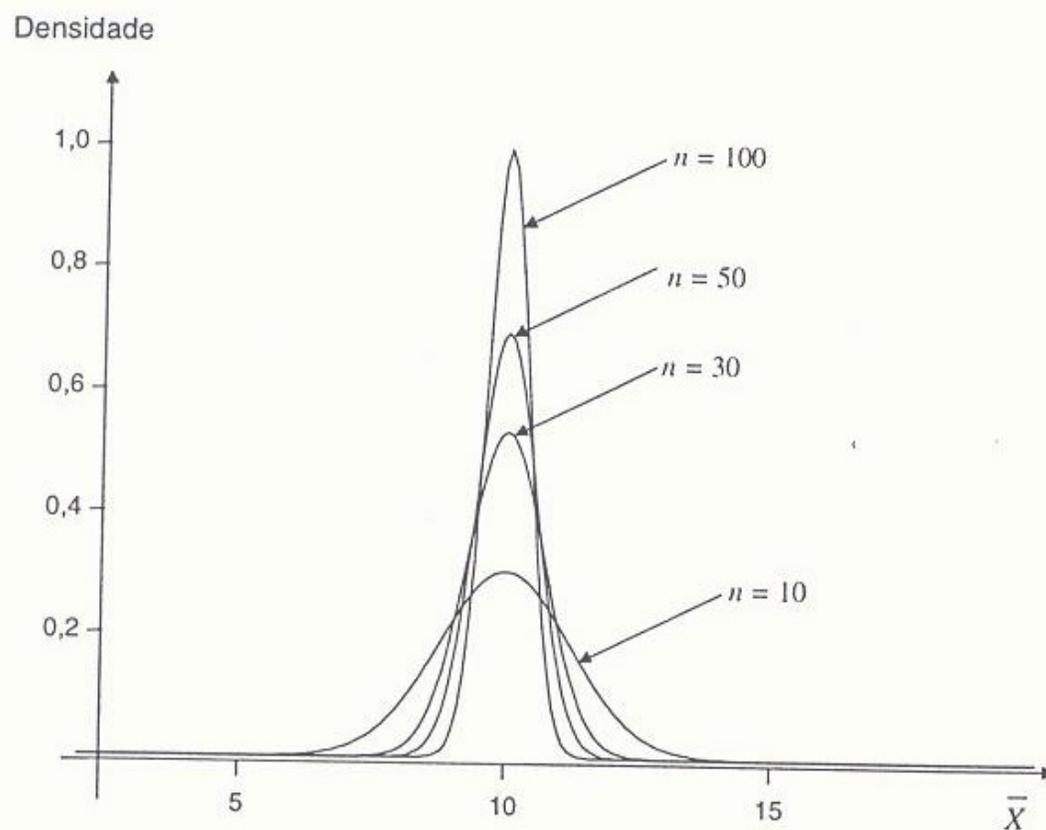


Figura 7.1: Efeito de n na distribuição amostral de $\bar{X} \sim N(10, 16/n)$

Exemplo 2:

Uma v.a. X tem média $\mu = 5,4$ e variância $\sigma^2 = 4,44$. Uma amostra com 40 observações é sorteada. Qual a probabilidade da média amostral ser maior do que 5?

$$X \begin{cases} \mu = 5,4 \\ \sigma^2 = 4,44 \end{cases}$$

Consideramos que $n = 40$ observações é uma amostra grande o suficiente para usar o Teorema do Limite Central. Assim,

$$\bar{X} \sim N\left(\mu; \frac{\sigma^2}{n}\right), \text{ isto é, } \bar{X} \sim N\left(5,4; \frac{4,44}{40}\right) \text{ e}$$

$$P(\bar{X} > 5) \cong P\left(Z > \frac{5 - 5,4}{\sqrt{\frac{4,44}{40}}}\right) = P(Z > -1,20) = A(1,20) = 0,8849 ,$$

lembrando que $Z \sim N(0, 1)$.

Exemplo 3:

Sabe-se que o faturamento diário de um posto de gasolina segue uma certa distribuição de média R\$ 20 mil e desvio padrão de R\$ 2 mil. Qual a probabilidade, em um período de 60 dias, do faturamento total ultrapassar R\$ 1230 mil?

Seja X o faturamento diário de um posto de gasolina, em mil reais. Sabemos que

$$\mu = E(X) = 20$$

$$\sigma^2 = \text{Var}(X) = 4$$

Obtemos uma amostra aleatória de 60 valores de X , denotada por X_1, X_2, \dots, X_{60} , sendo X_i o faturamento do posto no dia i , $i = 1, 2, \dots, 60$.

Então,

$$\begin{aligned} P(X_1 + X_2 + \dots + X_{60} > 1230) &= P\left(\frac{X_1 + X_2 + \dots + X_{60}}{60} > \frac{1230}{60}\right) \\ &= P(\bar{X} > 20,5) \cong P\left(Z > \frac{20,5 - 20}{\sqrt{\frac{4}{60}}}\right) = P(Z > 1,94) = 0,026. \end{aligned}$$

Exemplo 4: Considere que a distribuição dos níveis séricos de colesterol para todos os homens de 20 a 74 anos é normal com média $\mu = 211$ mg/100ml e o desvio padrão $\sigma = 46$ mg/100ml.

Selecionamos amostras de tamanho 25 da população.

→ Que proporção de amostras terá um valor médio maior do que 230 mg/100ml?

$$P(\bar{X} > 230) = ?$$

A distribuição da média amostral ($n = 25$) é normal com média $\mu = 211$ mg/100ml e erro padrão $\sigma/\sqrt{n} = 46/5 = 9,2$ mg/100ml.




FIGURA 8.1

$$P(\bar{X} > 230) = P\left(Z > \frac{230 - 211}{9,2}\right) = P(Z > 2,07) = 0,019.$$

Somente 1,9% das amostras terão uma média maior do que 230 mg/100ml.

Equivalentemente, se selecionamos uma amostra de tamanho 25 da população de homens de 20 a 74 anos, a probabilidade de que o nível sérico médio de colesterol para essa amostra seja maior do que 230 mg/100ml é de 0,019.

→ Que valor médio de nível sérico de colesterol limita os 10% valores mais baixos da distrib. amostral?

$$P(\bar{X} > x) = 0,1 \Rightarrow P(Z > \frac{x-211}{9,2}) = 0,1.$$

$$\frac{x-211}{9,2} = -1,28 \Rightarrow x = 211 - 1,28 \times 9,2 = 199,2.$$

≅ 10% das amostras de tamanho 25 têm médias que são menores ou iguais a 199,2 mg/100ml.

→ Calcular os limites superior e inferior que incluem 95% das médias das amostras de tamanho 25.

$$P(\mu - x < \bar{X} < \mu + x) = 0,95 \Rightarrow$$

$$P\left(\frac{211 - x - 211}{9,2} < Z < \frac{211 + x - 211}{9,2}\right) = 0,95 \Rightarrow$$

$$P\left(\frac{-x}{9,2} < Z < \frac{x}{9,2}\right) = 0,95 \Rightarrow$$

$$\frac{x}{9,2} = 1,96 \Rightarrow x = 1,96 \times 9,2 = 18,03.$$

Limites: $211 - 18 = 193,0$ e $211 + 18 = 229,0$

$\cong 95\%$ das médias das a.a. de tamanho 25 estão entre 193,0 mg/100ml e 229,0 mg/100ml.

\Rightarrow se selecionamos uma a.a. de tamanho 25 e a amostra tem uma média maior que 229,0 ou menor que 193,0 mg/100ml então, ou a a.a. foi extraída de uma população diferente ou um evento raro se realizou.

→ Suponha que selecionamos amostras de tamanho 10 da população.

Nesse caso, o erro padrão de \bar{X} é
 $\sigma/\sqrt{n} = 46/\sqrt{10} = 14,5$ mg/100ml.

$$P(\mu - x < \bar{X} < \mu + x) = 0,95 \Rightarrow$$

$$\frac{x}{14,5} = 1,96 \Rightarrow x = 1,96 \times 14,5 = 28,5.$$

Limites: $211 - 28,5 = 182,5$ e $211 + 28,5 = 239,5$

$\Rightarrow \cong 95\%$ das médias das a.a. de tamanho 10 estão entre 182,5 mg/100ml e 239,5 mg/100ml.

n	σ/\sqrt{n}	Intervalo contendo 95% das médias	Comprimento do intervalo
1	46,0	$120,8 \leq \bar{X} \leq 301,2$	180,4
10	14,5	$182,5 \leq \bar{X} \leq 239,5$	57,0
25	9,2	$193,0 \leq \bar{X} \leq 229,0$	36,0
50	6,5	$198,2 \leq \bar{X} \leq 223,8$	25,6
100	4,6	$102,0 \leq \bar{X} \leq 220,0$	18,0

Conforme o tamanho das amostras aumenta, a variabilidade entre as médias da amostra (erro padrão) diminui \Rightarrow os limites englobando 95% dessas médias se aproximam.

comprimento do intervalo = limite superior - limite inferior.

Os intervalos que construímos foram simétricos ao redor da média da população de 211 mg/100ml.

Existem outros intervalos que contém a proporção apropriada de médias da amostra.

Suponha que desejamos construir um intervalo que contenha 95% das médias das amostras de tamanho 25.

$P(x_1 < \bar{X} < x_2) = 0,95$, mas com 1% da área acima de x_2 e 4% abaixo de x_1 .

$$\frac{x_1 - 211}{9,2} = -1,75 \Rightarrow x_1 = 211 - 1,75 \times 9,2 = 194,9.$$

$$\frac{x_2 - 211}{9,2} = 2,32 \Rightarrow x_2 = 211 + 1,75 \times 9,2 = 232,9.$$

Podemos dizer que aproximadamente 95% das médias das amostras de tamanho 25 se encontram entre 194,9 mg/100ml e 232,3 mg/100ml.

Em geral, é preferível construir um intervalo simétrico.

intervalo assimétrico \Rightarrow comprimento =

$$232,3 - 194,9 = 37,4 \text{ mg/100ml};$$

intervalo simétrico \Rightarrow comprimento =

$$229,0 - 193,0 = 36,0 \text{ mg/100ml}.$$

→ Qual deve ser o tamanho das amostras para que 95% de suas médias se encontrem a ± 5 mg/100ml da média μ da população?

Para responder isso, não é necessário conhecer o valor do parâmetro μ .

Precisamos encontrar o tamanho da amostra n para o qual $P(\mu - 5 < \bar{X} < \mu + 5) = 0,95$

$$\Rightarrow P\left(\frac{\mu - 5 - \mu}{46/\sqrt{n}} < Z < \frac{\mu + 5 - \mu}{46/\sqrt{n}}\right) = 0,95$$

$$\Rightarrow \frac{5}{46/\sqrt{n}} = 1,96 \Rightarrow \sqrt{n} = \frac{1,96 \times 46}{5} \Rightarrow n = 325,2.$$

Amostras de tamanho 326 seriam exigidas para que 95% das médias das amostra se encontrem a ± 5 mg/100ml da média μ da população.

Ou, se selecionamos uma amostra de tamanho 326 da população e calculamos sua média, a probabilidade de que a média da amostra esteja a ± 5 mg/100ml da verdadeira média μ da população é 0,95.

This document was created with Win2PDF available at <http://www.daneprairie.com>.
The unregistered version of Win2PDF is for evaluation or non-commercial use only.