

MAE-212: Introdução à Probabilidade e à Estatística II

Aula 02

Inferência Estatística

Distribuições Amostrais

O problema da inferência estatística: fazer uma afirmação sobre os parâmetros da população θ (média, variância, etc) através da amostra.

Usaremos uma AAS de n elementos sorteados dessa população, nossa decisão será baseada na estatística $T = f(X_1, \dots, X_n)$.

Colhida essa amostra, observamos um particular valor de T : t_0 , e baseados nesse valor é que faremos a afirmação sobre o parâmetro populacional θ .

Parâmetro: quantidade desconhecida de uma característica da população e sobre a qual temos interesse.

Exemplos:

μ - *média da característica da população:*

μ : taxa média de glicose de mulheres com idade superior a 60 anos, em certa localidade.

p – *proporção de “indivíduos” em uma população com determinada característica.*

p : proporção de moradores do município de São Paulo que foram infectados pelo vírus Covid-19 no período de março a agosto de 2020.

População



X - variável de interesse : *Renda*

Vamos observar n elementos, extraídos ao acaso da população, de forma independente;

Amostra



Para cada elemento selecionado, observamos o valor da variável X de interesse.

Obtemos, então, uma **amostra aleatória** (*a.a.*) de tamanho n de X , que representamos por

$$X_1, X_2, \dots, X_n,$$

sendo X_i a variável de interesse para o i -ésimo indivíduo da amostra.

Uma vez selecionada a amostra saberemos a renda de *João* (x_1)

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

→ **Estimador** (ou estatística) $\Rightarrow f(X_1, X_2, \dots, X_n)$.

Ex.: \bar{X} : média amostral (estimador da média μ da característica X da população).

\hat{p} : proporção amostral (estimador da proporção p populacional).

Estimativa: valor numérico assumido pelo estimador, para a amostra selecionada.

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

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**.

População



X - variável de interesse: *Renda*

Por exemplo, obter a distribuição amostral da Média

Amostra 1



Amostra 2



...

Amostra k



...

\bar{x}_1

\bar{x}_2


...

\bar{x}_k

...

População das médias de amostras de tamanho n

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 $\mu_x = E(X) = 4,2$,
 $\sigma_x^2 = \text{Var}(X) = 4,16$.

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

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

sendo

X_1 : valor selecionado na primeira extração; e

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} ,

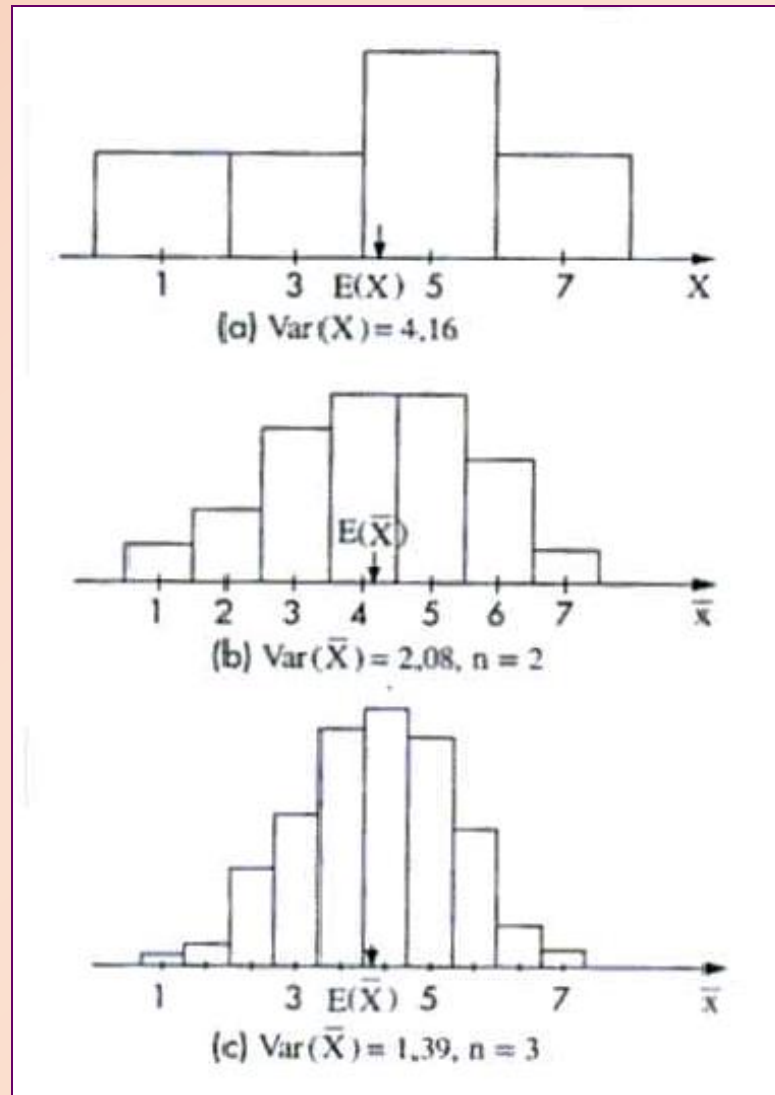
\bar{x}	$P(\bar{X} = \bar{x})$
1	1/125
5/3	3/125
7/3	9/125
3	16/125
11/3	24/125
13/3	27/125
5	23/125
17/3	15/125
19/3	6/125
7	1/125

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

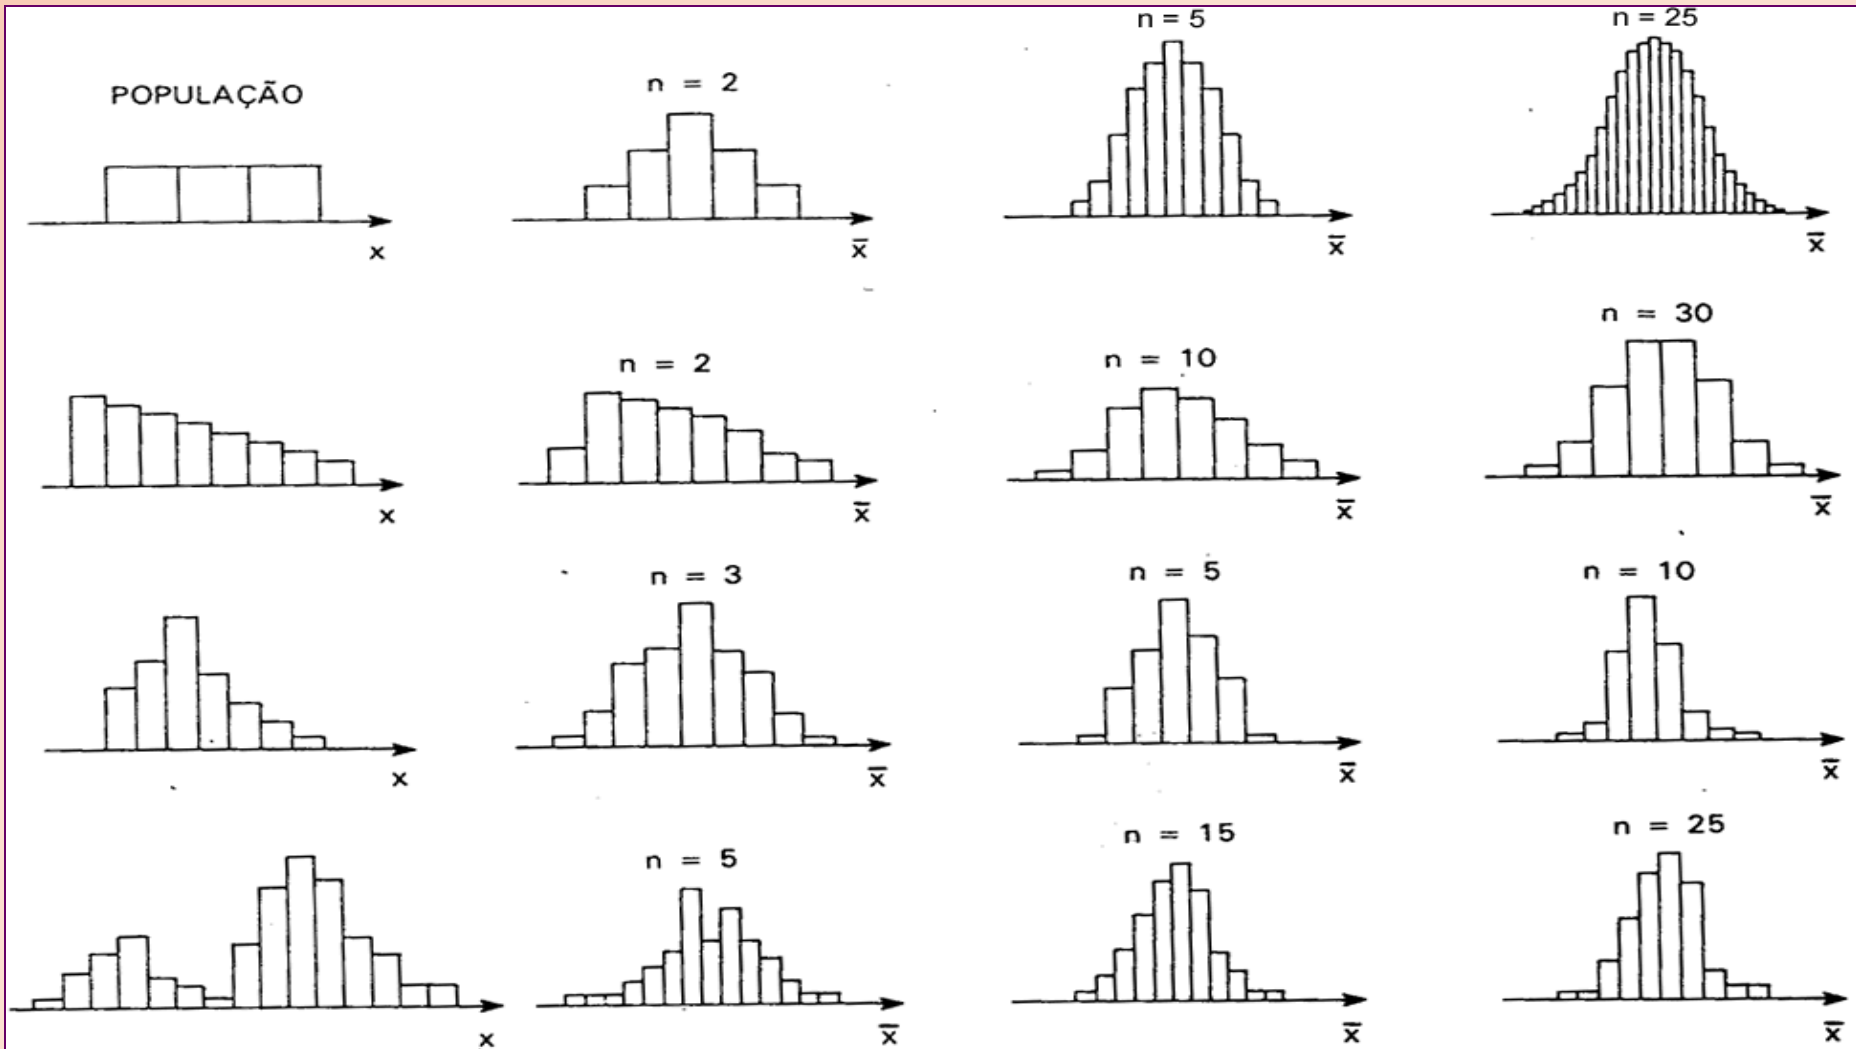
- conforme n aumenta, os valores de \bar{X} tendem a se concentrar cada vez mais em torno de

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

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.



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 uma amostra X_1, X_2, \dots, X_n , retirada 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 $\sqrt{\frac{\sigma^2}{n}} = \frac{\sigma}{\sqrt{n}}$, que é

o desvio padrão da média amostral, também é denominado erro padrão.

Corolário 10.1 Se (X_1, \dots, X_n) for uma amostra aleatória simples da população X , com média μ e variância σ^2 finita, e $\bar{X} = (X_1 + \dots + X_n)/n$, então

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1). \quad (10.2)$$

Basta notar que se usou a transformação usual de reduzir a distribuição de \bar{X} a uma normal padrão. Observe, também, que (10.2) pode ser escrita como

$$Z = \frac{\sqrt{n}(\bar{X} - \mu)}{\sigma} \sim N(0,1). \quad (10.3)$$

Chamemos de e a v.a. que mede a diferença entre a estatística \bar{X} e o parâmetro μ , isto é, $e = \bar{X} - \mu$; e é chamado o *erro amostral da média*. Então, temos o

Corolário 10.2 A distribuição de e aproxima-se de uma distribuição normal com média 0 e variância σ^2/n , isto é,

$$\frac{\sqrt{n} e}{\sigma} \sim N(0,1). \quad (10.4)$$

Exemplo 2:


Uma máquina enche pacotes de café cujos pesos seguiam uma distribuição $N(500, 100)$. Colhendo-se uma amostra de $n=100$ pacotes e pesando-os. Se a máquina estiver regulada, qual a probabilidade de encontrarmos a média de 100 pacotes diferindo de 500g de menos de 2 gramas?

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

\bar{X} terá uma distribuição normal com média 500 e variância $100/100 = 1$.

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \sim N(0,1).$$

(Note: In the original image, the Greek letter mu is circled in red with an arrow pointing to the value 500 above it, and the denominator sigma/sqrt(n) is circled in red with an arrow pointing to the value 1 below it.)



$$P(|\bar{X} - 500| < 2) = P(498 < \bar{X} < 502) = P(-2 < Z < 2) \approx 95\%.$$

