

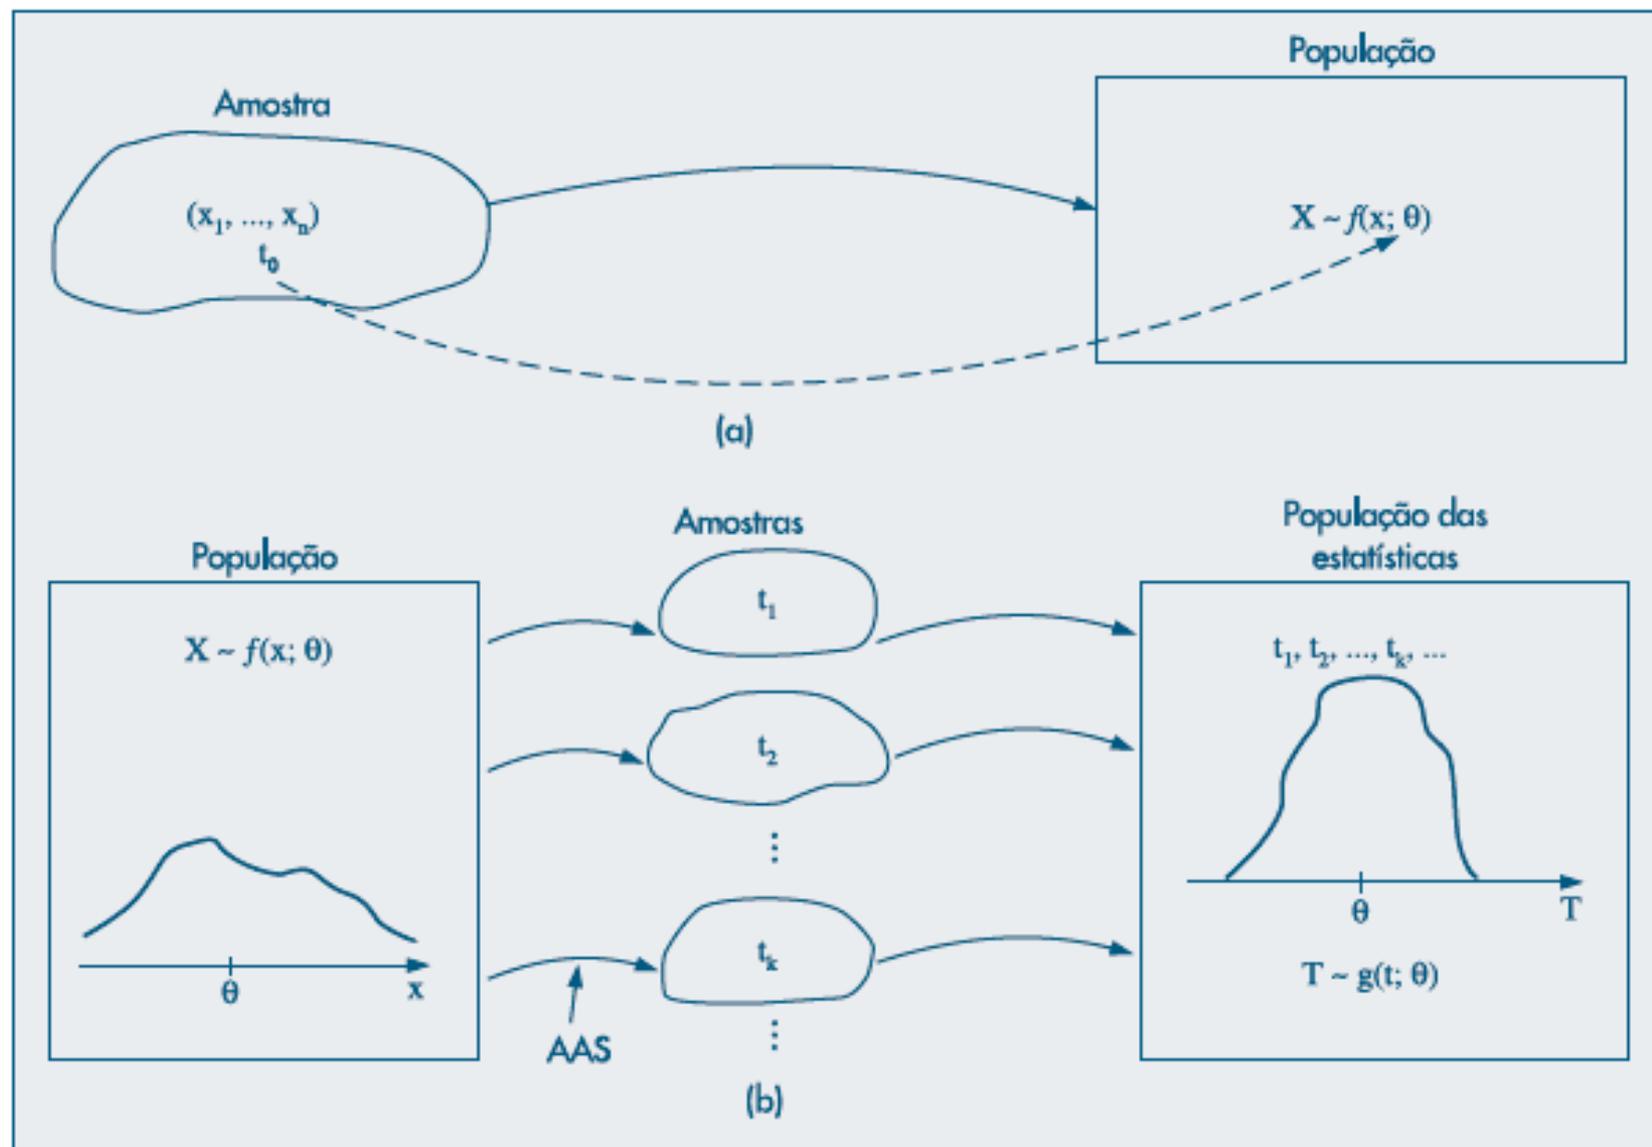
Distribuições Amostrais

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 .

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



- Vamos observar n elementos, extraídos ao acaso e com reposição da população;
- Para cada elemento selecionado, observamos o valor da variável X de interesse.

Obtemos, então, uma amostra aleatória de tamanho n de X , que representamos por

X_1, X_2, \dots, X_n .

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} ,

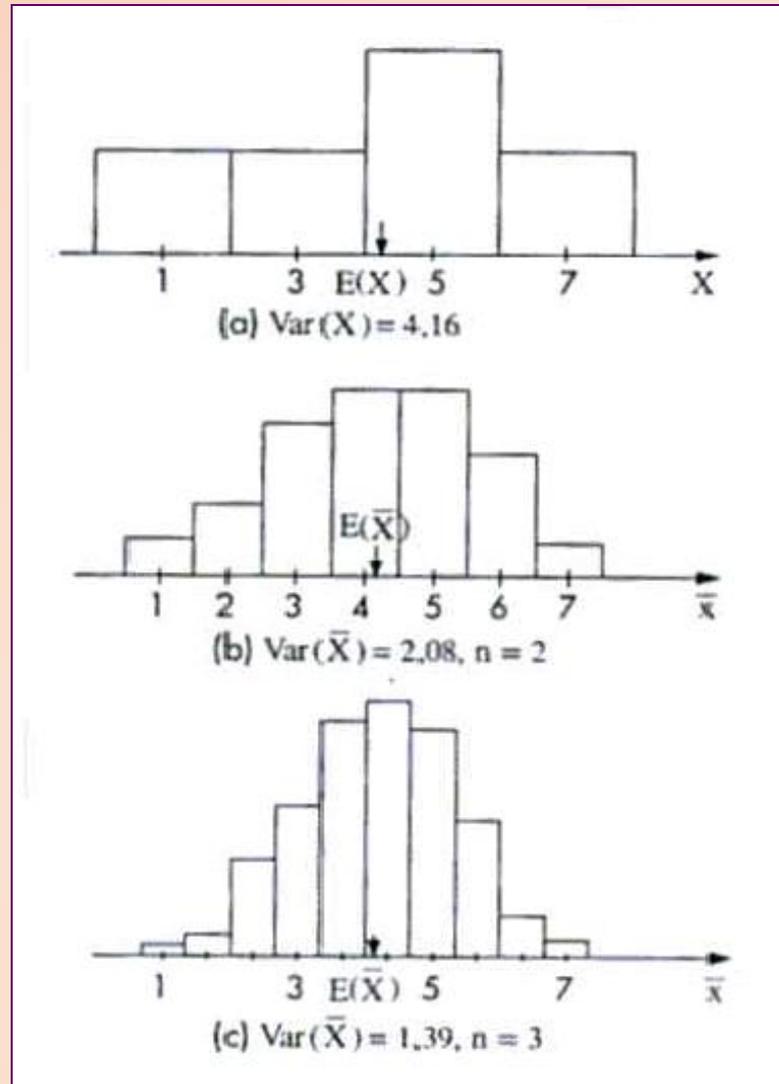
\bar{x}	$P(\bar{X} = \bar{x})$
1	1/125
5/3	3/125
7/3	9/125
3	16/125
11/3	24/125
13/3	27/125
5	23/125
17/3	15/125
19/3	6/125
7	1/125

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

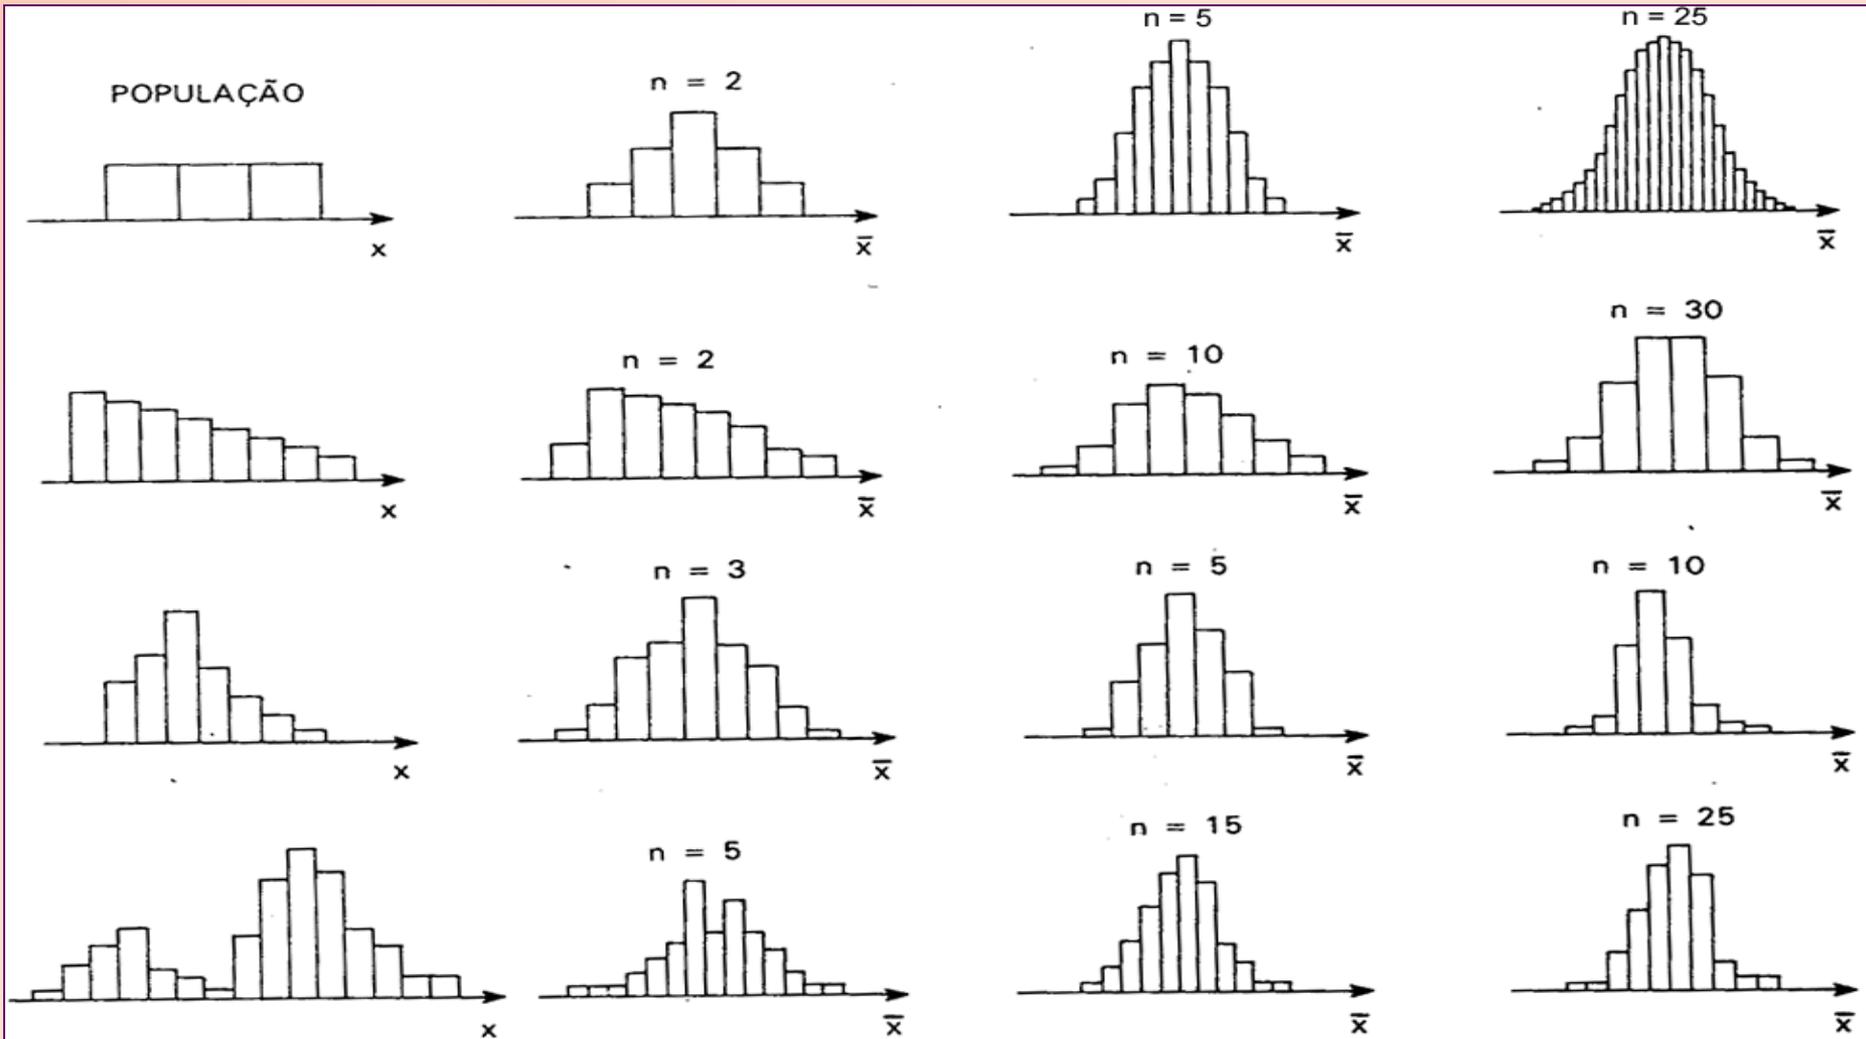
- conforme n aumenta, os valores de \bar{X} tendem a se concentrar cada vez mais em torno de

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

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.

Exemplo 2:

Uma máquina enchia 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?

Exemplo 3:

Suponha que $p = 30\%$ dos estudantes de uma escola sejam mulheres. Colhemos uma AAS de $n=10$ estudantes e calculamos proporção de mulheres na amostra. Qual a probabilidade de que a proporção amostral difira de p em menos de 0,01?

Distribuição amostral de uma Proporção

$X = 1$, se o indivíduo for portador da característica;
 $= 0$, caso contrário;

É fácil ver que $\mu_x = E(X) = p$,
 $\sigma_x^2 = \text{Var}(X) = p(1-p)$

Retirada de uma AAS(amostragem aleatória simples) dessa população, e indicando por Y_n o total de indivíduos portadores da característica na amostra, então

$$Y_n = X_1 + X_2 + \dots + X_n,$$

$$Y_n \sim b(n, p)$$

$$\hat{p} \sim N\left(p, \frac{p(1-p)}{n}\right).$$

$$\hat{p} = \frac{Y_n}{n}.$$

Outras Distribuições Amostrais

Exemplo 10.13. Na Tabela 10.6 apresentamos a distribuição de três outras estatísticas; a variância da amostra,

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

a mediana amostral, md , e o estimador

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

Tabela 10.6: Distribuição amostral de algumas estatísticas obtidas de amostra de tamanho $n = 3$, retiradas da população $\{1, 3, 5, 5, 7\}$ ($\mu = 4,2$, $\sigma^2 = 4,16$ e $Md = 5$).

Tipo de amostra	Frequência (prob. \times 125)	Soma	Soma dos quadrados	Média \bar{x}	Mediana md	Variância	
						s^2	$\hat{\sigma}^2$
111	1	3	3	1,00	1	0	0
113	3	5	11	1,67	1	4/3	8/9
115	6	7	27	2,33	1	16/3	32/9
117	3	9	51	3,00	1	12	8
133	3	7	19	2,33	3	4/3	8/9
135	12	9	35	3,00	3	4	8/3
137	6	11	59	3,67	3	28/3	56/9
155	12	11	51	3,67	5	16/3	32/9
157	12	13	75	4,33	5	28/3	56/9
177	3	15	99	5,00	7	12	8
333	1	9	27	3,00	3	0	0
335	6	11	43	3,67	3	4/3	8/9
337	3	13	67	4,33	3	16/3	32/9
355	12	13	59	4,33	5	4/3	8/9
357	12	15	83	5,00	5	4	8/3
377	3	17	107	5,67	7	16/3	32/9
555	8	15	75	5,00	5	0	0
557	12	17	99	5,67	5	4/3	8/9
577	6	19	123	6,33	7	4/3	8/9
777	1	21	147	7,00	7	0	0
Total	125						

Tabela 10.7: Distribuição amostral da variância S^2 , para amostras de tamanho 3, retiradas da população $\{1, 3, 5, 5, 7\}$.

s^2	0,00	1,33	4,00	5,33	9,33	12,00
$P(S^2 = s^2)$	11/125	42/125	24/125	24/125	18/125	6/125

$$E(S^2) = 4,16, \quad \text{Var}(S^2) = 11,28.$$

Tabela 10.8: Distribuição amostral da mediana da amostra md para amostras de tamanho 3, retiradas da população $\{1, 3, 5, 5, 7\}$.

md	1	3	5	7
Prob.	13/125	31/125	68/125	13/125

$$E(md) = 4,30, \quad \text{Var}(md) = 2,54.$$

Tabela 10.9: Distribuição amostral da variância $\hat{\sigma}^2$, para amostras de tamanho 3, retiradas da população $\{1, 3, 5, 5, 7\}$.

$\hat{\sigma}^2$	0,00	0,89	2,67	3,56	6,22	8,00
Prob.	11/125	42/125	24/125	24/125	18/125	6/125

$$E(\hat{\sigma}^2) = 2,77, \quad \text{Var}(\hat{\sigma}^2) = 5,04.$$

Figura 10.6: Distribuição amostral de S^2 para amostras de tamanho $n = 3$ extraídas de $\{1, 3, 5, 5, 7\}$.

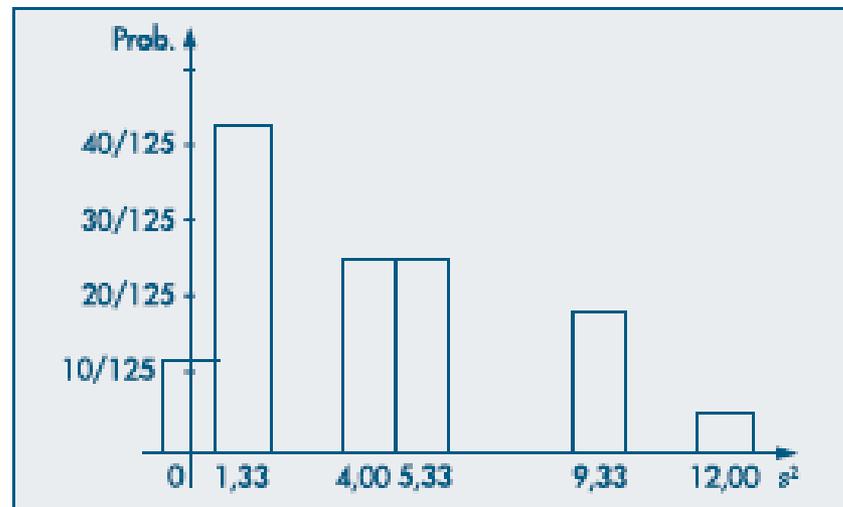


Figura 10.7: Distribuição amostral de md para amostras de tamanho $n = 3$ de $\{1, 3, 5, 5, 7\}$.

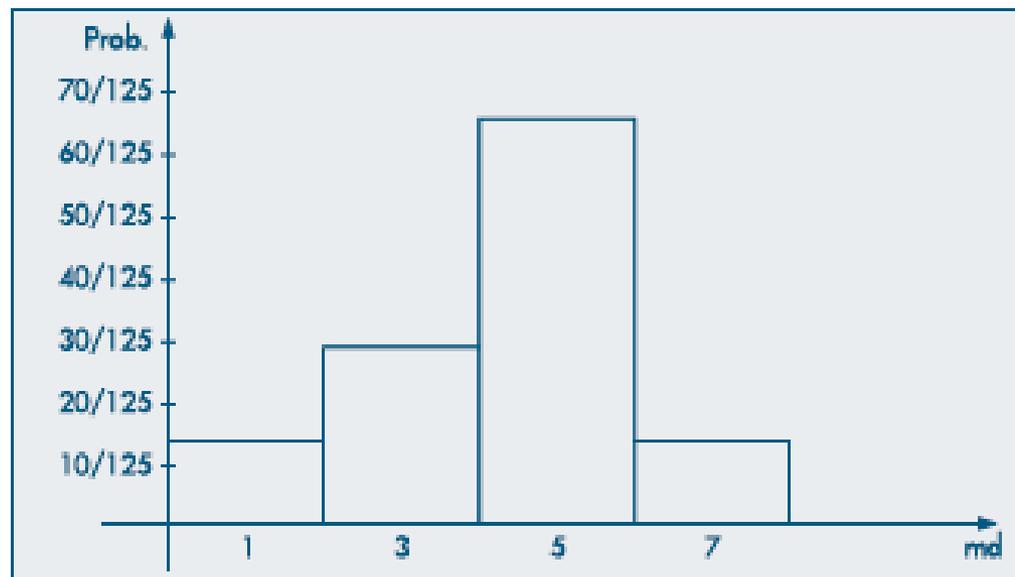
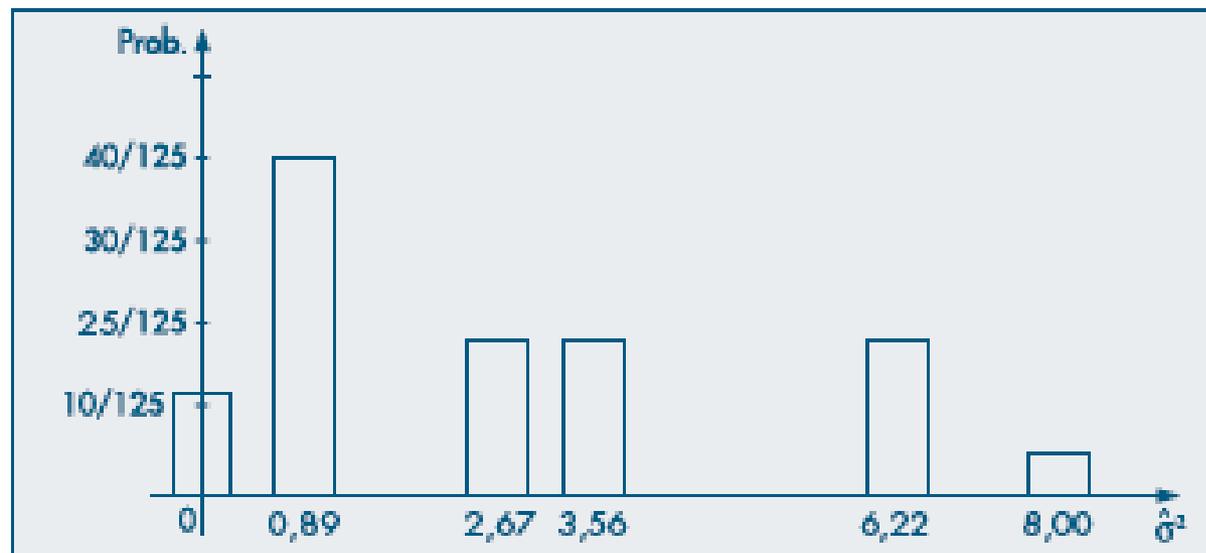


Figura 10.8: Distribuição amostral de $\hat{\sigma}^2$ para amostras de tamanho $n = 3$ extraídas de $\{1, 3, 5, 5, 7\}$.



Por exemplo, note que $E(S^2) = 4,16 = \sigma^2$, logo S^2 satisfaz uma propriedade análoga a $E(\bar{X}) = \mu$; dizemos que \bar{X} e S^2 são estimadores *não-viesados* dos respectivos parâmetros μ e σ^2 . Esta propriedade já não vale para md e $\hat{\sigma}^2$, pois $E(md) = 4,3$, enquanto $Md = 5,0$ e $E(\hat{\sigma}^2) = 2,77$ e não 4,16. Vemos que $\hat{\sigma}^2$ sub-estima a verdadeira variância.

Dimensionamento da amostra

Seja $P(\varepsilon) = \gamma$, a probabilidade da média amostral \bar{X} estar a uma distância de, no máximo ε , da média populacional μ (desconhecida), ou seja,

$$\begin{aligned} \gamma &= P\left(\left|\bar{X} - \mu\right| \leq \varepsilon\right) = P\left(\mu - \varepsilon \leq \bar{X} \leq \mu + \varepsilon\right) \\ &= P\left(\frac{-\varepsilon}{\frac{\sigma}{\sqrt{n}}} \leq \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \leq \frac{\varepsilon}{\frac{\sigma}{\sqrt{n}}}\right) \cong P\left(\frac{-\varepsilon \sqrt{n}}{\sigma} \leq \mathbf{Z} \leq \frac{\varepsilon \sqrt{n}}{\sigma}\right), \end{aligned}$$

sendo $\mathbf{Z} \sim N(0,1)$.

Dimensionamento da amostra

A partir da relação $\varepsilon = z \frac{\sigma}{\sqrt{n}}$,

o tamanho da amostra n é determinado por

$$n = \left(\frac{z}{\varepsilon} \right)^2 \sigma^2,$$

conhecendo-se o desvio padrão σ de X , o erro ε da estimativa e o coeficiente de confiança γ do intervalo, sendo z tal que

$$\gamma = P(-z \leq Z \leq z) \text{ e } Z \sim N(0,1).$$

Exemplo 4:

A renda per-capita domiciliar numa certa região tem distribuição normal com desvio padrão $\sigma = 250$ reais e média μ desconhecida. Se desejamos estimar a renda média μ com erro $\varepsilon = 50$ reais e com uma confiança $\gamma = 95\%$, quantos domicílios devemos consultar?

X : renda per-capita domiciliar na região

$$X \sim N(\mu; 250^2)$$

$n = ??$ tal que $\varepsilon = 50$ reais,

$$\gamma = 0,95 \Rightarrow z = 1,96$$

Então,

$$\begin{aligned}n &= \left(\frac{\mathbf{z}}{\varepsilon} \right)^2 \sigma^2 \\ &= \left(\frac{\mathbf{1,96}}{\mathbf{50}} \right)^2 (\mathbf{250})^2 \\ &= \mathbf{96,04}\end{aligned}$$

Aproximadamente 97 domicílios devem ser consultados.

Exemplo 5:

A quantidade de colesterol X no sangue das alunas de uma universidade segue uma distribuição de probabilidades com desvio padrão $\sigma = 50$ mg/dl e média μ desconhecida. Se desejamos estimar a quantidade média μ de colesterol com erro $\varepsilon = 20$ mg/dl e confiança de 90%, quantas alunas devem realizar o exame de sangue?

X : quantidade de colesterol no sangue das alunas da universidade

$\sigma = 50$ mg/dl

$n = ??$ tal que $\varepsilon = 20$ mg/dl

$\gamma = 0,90 \Rightarrow z = 1,65$

Supondo que o tamanho da amostra a ser selecionada é suficientemente grande, pelo Teorema do Limite Central temos:

$$\begin{aligned} \mathbf{n} &= \left(\frac{\mathbf{z}}{\varepsilon} \right)^2 \sigma^2 \\ &= \left(\frac{1,65}{20} \right)^2 (50)^2 \\ &= 17,02 \end{aligned}$$

Assim, aproximadamente 18 alunas devem realizar o exame de sangue.

No caso de proporção, usando a aproximação normal para proporção amostral, temos

$$n = \left(\frac{z}{\varepsilon} \right)^2 p(1-p)$$

Como não conhecemos p , podemos usar o fato de que $p(1-p) \leq 1/4$, para todos p .

Dimensionamento da amostra

Da relação $\varepsilon = z \sqrt{\frac{p(1-p)}{n}}$,

segue que o **tamanho amostral** n , dados γ e a margem de erro ε , tem a forma

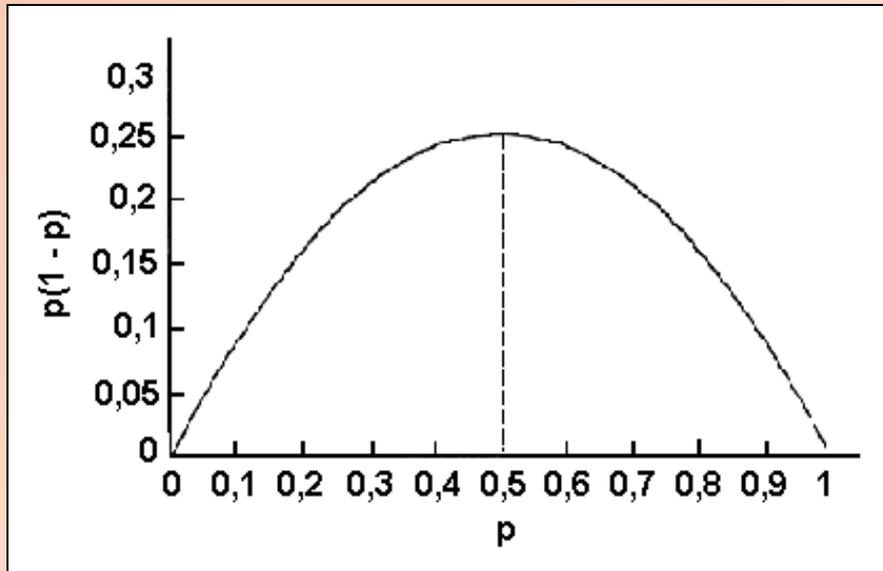
$$n = \left(\frac{z}{\varepsilon} \right)^2 p(1-p),$$

onde z é tal que $\gamma = P(-z \leq Z \leq z)$ e $Z \sim N(0,1)$.

Entretanto, nesta expressão, n depende de $p(1-p)$, que é desconhecido.

- **Como calcular o valor de n ?**

Gráfico da função $p(1-p)$, para $0 \leq p \leq 1$.



Pela figura observamos que:

- a função $p(1-p)$ é uma parábola simétrica em torno de $p = 0,5$;
- o máximo de $p(1-p)$ é 0,25, alcançado quando $p = 0,5$.

Assim, na prática, substituímos $p(1-p)$ por seu valor máximo, obtendo

$$n = \left(\frac{z}{\varepsilon} \right)^2 0,25 ,$$

que pode fornecer um valor de n maior do que o necessário.

Exemplo 6:

No exemplo da USP (Exemplo 1) suponha que nenhuma amostra foi coletada. Quantos estudantes precisamos consultar de modo que a estimativa pontual esteja, no máximo, a 0,02 da proporção verdadeira p , com uma probabilidade de 0,95?

Dados do problema:

$\varepsilon = 0,02$ (erro da estimativa);

$P(\varepsilon) = \gamma = 0,95 \Rightarrow z = 1,96.$

$$n = \left(\frac{1,96}{0,02} \right)^2 p(1-p) \leq \left(\frac{1,96}{0,02} \right)^2 0,25 = 2401 \text{ estudantes.}$$

Pergunta: *É possível reduzir o tamanho da amostra quando temos alguma informação a respeito de p ?*

Por exemplo, sabemos que:

- p não é superior a 0,30, ou
- p é pelo menos 0,80, ou
- p está entre 0,30 e 0,60.

Resposta: *Depende do tipo de informação sobre p .*

Em alguns casos, podemos substituir a informação $p(1-p)$, que aparece na expressão de n , por um valor menor que 0,25.

Redução do tamanho da amostra

Vimos que, se nada sabemos sobre o valor de p , no cálculo de n , substituímos $p(1-p)$ por seu valor máximo, e calculamos

$$n = \left(\frac{z}{\varepsilon} \right)^2 0,25 .$$

Se temos a informação de que p é *no máximo 0,30* ($p \leq 0,30$), então o valor máximo de $p(1-p)$ será dado por $0,3 \times 0,7 = 0,21$.

Logo, reduzimos o valor de n para

$$n = \left(\frac{z}{\varepsilon} \right)^2 0,21 .$$

Agora, se p é pelo menos 0,80 ($p \geq 0,80$), então o máximo de $p(1-p)$ é $0,8 \times 0,2 = 0,16$ e temos

$$n = \left(\frac{z}{\varepsilon} \right)^2 0,16 .$$

Mas, se $0,30 \leq p \leq 0,60$, o máximo de $p(1-p)$ é $0,5 \times 0,5 = 0,25$ e, neste caso, não há redução, ou seja,

$$n = \left(\frac{z}{\varepsilon} \right)^2 0,25 .$$

Exemplo 7:

No Exemplo 6, suponha que temos a informação de que no máximo 30% dos alunos da USP foram ao teatro no último mês. Portanto, temos que $p \leq 0,30$ e, como vimos, o máximo de $p(1-p)$ neste caso é 0,21.

Assim, precisamos amostrar

$$n = \left(\frac{z}{\varepsilon} \right)^2 0,21 = \left(\frac{1,96}{0,02} \right)^2 0,21 = 2017 \text{ estudantes,}$$

conseguindo uma redução de $2401 - 2017 = 384$ estudantes.