

MAE-212: Introdução à Probabilidade e à Estatística II

Aula 03

Inferência Estatística

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

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

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

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

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

Exemplo 10.12 Suponha que $p = 30\%$ dos estudantes de uma escola sejam mulheres. Colhemos uma AAS de $n = 10$ estudantes e calculamos \hat{p} = proporção de mulheres na amostra. Qual a probabilidade de que \hat{p} difira de p em menos de 0,01? Temos que essa probabilidade é dada por

$$P(|\hat{p} - p| < 0,01) = P(-0,01 < \hat{p} - p < 0,01).$$

Mas, $\hat{p} - p \sim N\left(0, \frac{p(1-p)}{n}\right)$ e como $p = 0,3$, temos que

$$\text{Var}(\hat{p}) = (0,3)(0,7)/10 = 0,021,$$

e, portanto, a probabilidade pedida é igual a

$$P\left(\frac{-0,01}{\sqrt{0,021}} < Z < \frac{0,01}{\sqrt{0,021}}\right) = P(-0,07 < Z < 0,07) = 0,056.$$

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 $\{1, 3, 5, 5, 7\}$.

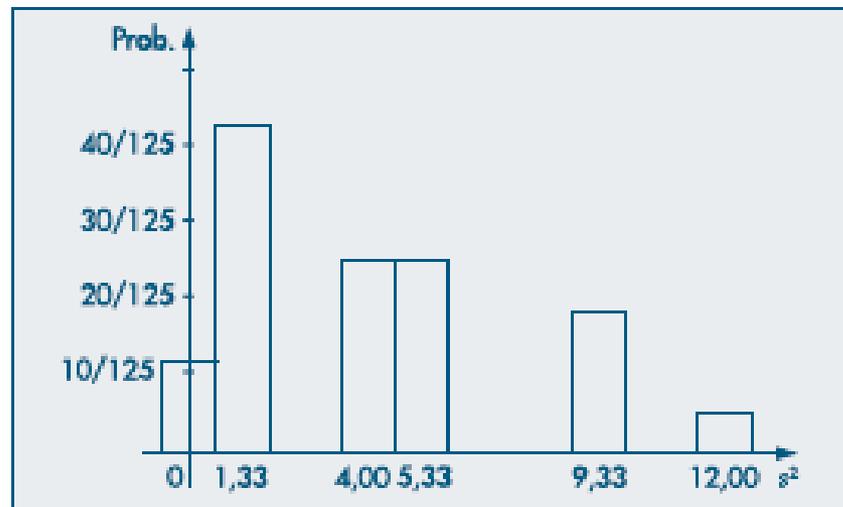


Figura 10.7: Distribuição amostral de md para amostras de tamanho $n = 3$ de $\{1, 3, 5, 5, 7\}$.

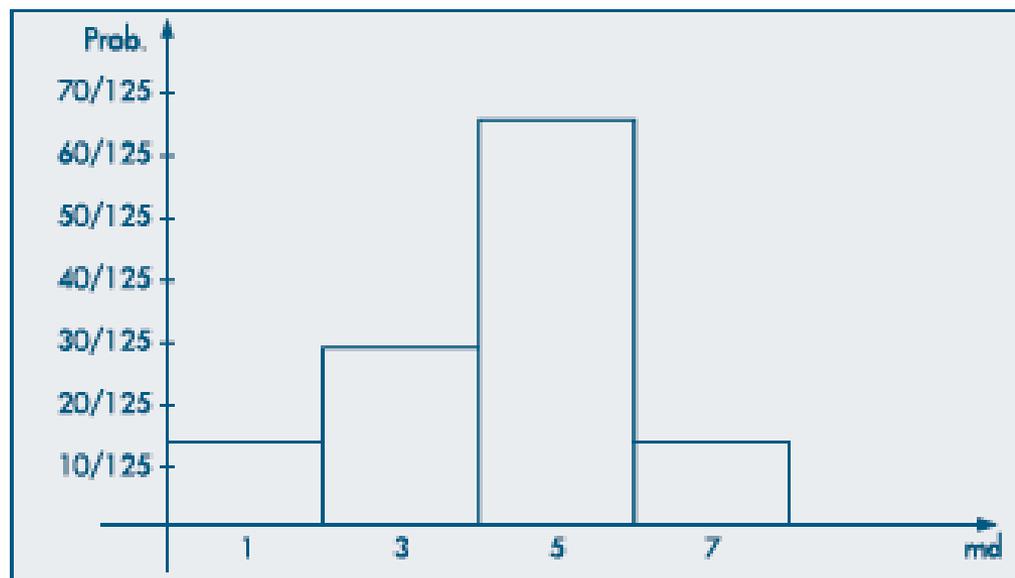
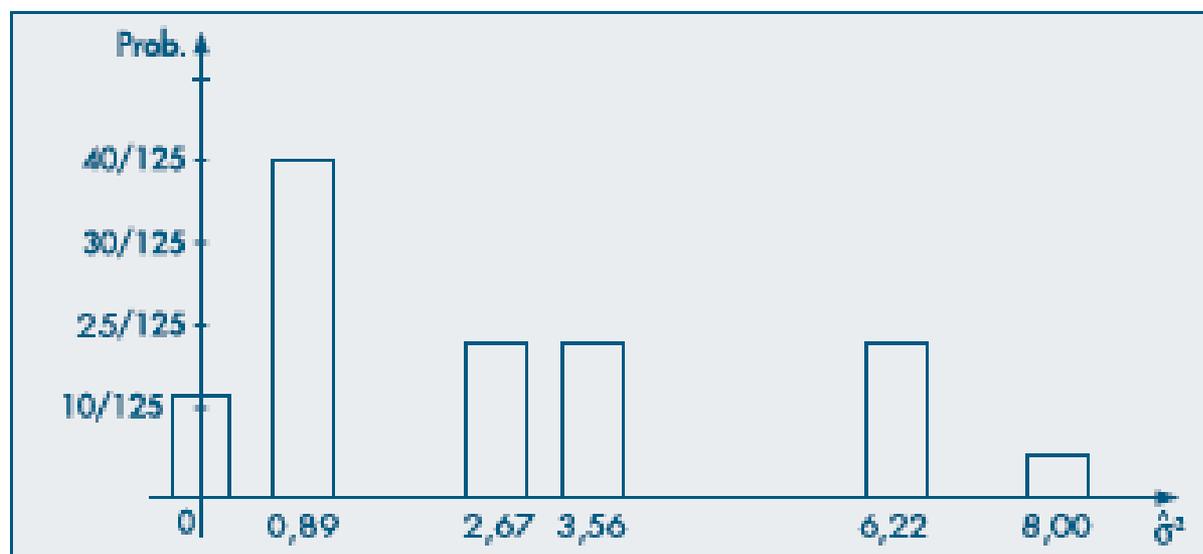


Figura 10.8: Distribuição amostral de $\hat{\sigma}^2$ para amostras de tamanho $n = 3$ extraídas de $\{1, 3, 5, 5, 7\}$.



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,

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

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

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,

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

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

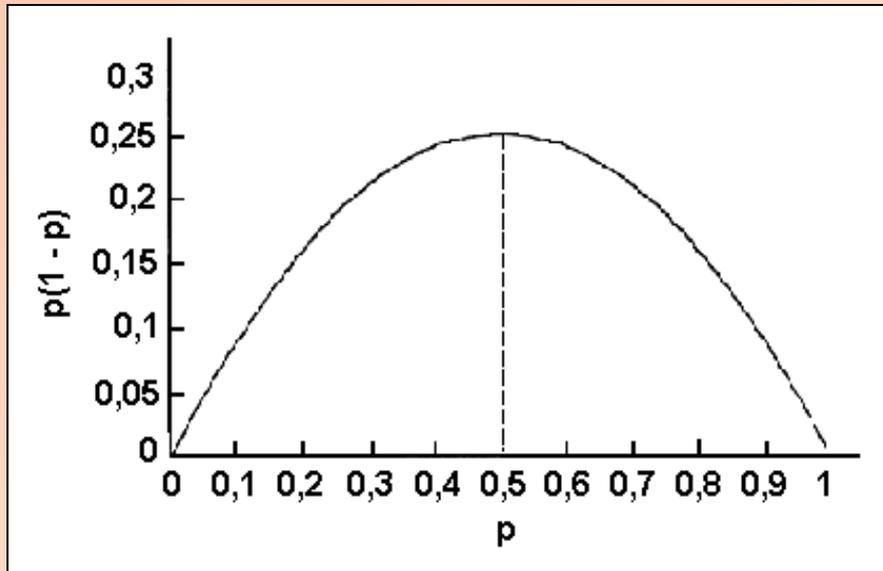
$$n = \left(\frac{z}{\varepsilon} \right)^2 p(1-p),$$

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.

