

## 10.2 Distribuição Amostral da Média

Se amostras aleatórias de tamanho  $n$  forem tomadas de uma população com média  $\mu$  e variância  $\sigma^2$ , então a distribuição amostral de  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$ , tem as seguintes propriedades:


$$1) \mu_{\bar{X}} = E(\bar{X}) = \mu$$

$$2) \sigma_{\bar{X}}^2 = \frac{\sigma^2}{n} \Rightarrow \sigma_{\bar{X}} = \frac{\sigma}{\sqrt{n}}$$

Se o tamanho da amostra cresce, o desvio padrão da média amostral decresce.

3) Se a população original tem distribuição Normal, então  $\bar{X}$  também tem distribuição Normal:

$$X \sim N(\mu, \sigma^2) \Rightarrow \bar{X} \sim N\left(\mu, \frac{\sigma^2}{n}\right)$$




#### 4) Teorema Central do Limite:

Se a população original tem uma distribuição qualquer com média  $\mu$  e variância  $\sigma^2$ , para  $n$  "suficientemente grande" (na prática, quando  $n > 30$ ), então  $\bar{X}$  tem distribuição aproximadamente Normal:

$$\left. \begin{array}{l} E(X) = \mu \\ \text{Var}(X) = \sigma^2 \end{array} \right\} \Rightarrow \bar{X} \overset{a}{\sim} N\left(\mu, \frac{\sigma^2}{n}\right)$$

onde  $\overset{a}{\sim}$  significa aproximadamente distribuído



**Exercício.** Faça um esboço das distribuições de  $X$  e de  $\bar{X}$ , assumindo que  $X$  tem distribuição normal com média 40, variância 36 e que o tamanho de amostra foi igual a 9.

**Exercício: Produção de Resina em Pinus elliottii**

Seja  $X$  a produção anual de resina de árvores de Pinus elliottii. Suponha que  $X$  tem distribuição Normal com média 2,3 kg e desvio padrão 0,7kg.

a) Faça um esboço da distribuição de  $X$ .

b) Calcule a proporção esperada de árvores com produção maior do que 2,8 kg.

c) Foi tomada uma amostra aleatória de 16 árvores. Qual é a probabilidade de que a produção média das 16 árvores amostradas seja maior que 2,8 kg?

d) Uma amostra aleatória de 49 árvores foi tomada. Qual é a probabilidade de que a produção média das 49 árvores amostradas seja maior que 2,8 kg?

e) Uma amostra aleatória de 25 árvores foi tomada. Obter  $\bar{x}$  tal que:

- $P(\bar{X} < \bar{x}) = 0,985$
- $P(\bar{X} < \bar{x}) = 0,975$

**Exercício. Visitantes num Parque**

Uma proporção de 37% dos visitantes de um parque favorecem a cobrança de taxas de entrada. Uma amostra aleatória de 200 visitantes foi tomada.

a) Qual é o parâmetro? Qual é a estatística?

b) Qual a probabilidade que na amostra de 200 visitantes pelo menos 40% favoreçam a cobrança de taxas?

c) Qual a probabilidade que na amostra de 200 visitantes, a proporção dos que favorecem a cobrança de taxas fique entre 35 e 39% ?

d) Uma nova amostra de 10 visitantes foi tomada. Qual a probabilidade de que pelo menos 50% dos visitantes na amostra favoreçam a cobrança de taxas ? É válido utilizar o mesmo método utilizado em (b) e (c) ? Por que?  
Qual método deveria ser utilizado neste caso para encontrar a probabilidade?

### Exemplo 13. A Mortalidade de Árvores numa Floresta

Após vários anos de acompanhamento de parcelas permanentes, uma Eng. Florestal concluiu que, das árvores que morrem num fragmento florestal, 75% são devido ao abafamento da copa por cipós. No ano seguinte, ocorreu um período prolongado de intensa seca e 30 árvores morreram durante o ano, das quais 24 mortes podem ser atribuídas ao efeito dos cipós. A Eng. Florestal afirma que a proporção de árvores que morreram devido aos cipós ( $p$ ) foi maior neste ano de seca intensa do que nos anos anteriores.

a. Estabeleça  $H_0$  e  $H_a$ .

$H_0$ : A proporção de árvores mortas por cipós no ano de seca intensa é igual a 75%.

$H_a$ : A proporção de árvores mortas por cipós no ano de seca intensa é maior que 75%.

b. Estabeleça  $H_0$  e  $H_a$  de forma quantitativa.

$H_0 : p = 0.75$

$H_a : p > 0.75$

c. De acordo com a afirmação da Eng. Florestal, a hipótese nula foi rejeitada ou aceita? Explique

d. Se o teste de hipótese utilizou o nível de 5% de significância, o valor-p foi maior ou menor que 0.05? Explique.

e. Qual o tamanho de amostra utilizado para os resultados no ano de seca intensa?

### Testando Hipóteses sobre a Proporção de uma População

Como a hipótese acima pode ser testada?

Como a taxa de mortalidade do último ano (ano de seca intensa) foi baseada numa amostra, o valor

$$\frac{24}{30} \times 100 = 80\%$$

é uma estatística da amostra e deve ser representado por  $\hat{p}$ . Nós sabemos que  $\hat{p}$  varia de amostra para amostra. Se a amostragem fosse repedita e outras 30 árvores mortas observadas, nós provavelmente obteríamos um outro valor para  $\hat{p}$ .

Como já foi visto, a distribuição amostral de  $\hat{p}$  tem as seguintes propriedades:

1. a média da distribuição de  $\hat{p}$  será  $p$ ;
2. a variância da distribuição de  $\hat{p}$  será

$$\frac{p(1-p)}{n}$$

3. a distribuição de  $\hat{p}$  será aproximadamente Normal.

Com base nestas propriedades sabemos que a variável aleatória:

$$Z = \frac{\hat{p} - p}{\sqrt{p(1-p)/n}}$$


terá distribuição aproximadamente Normal Padronizada, isto é, distribuição Normal com média 0 e desvio padrão 1.

Assumindo que a hipótese nula é verdadeira ( $H_0 : p = 0.75$ ),  $\hat{p}$  seria aproximadamente Normal com média 0.75 e desvio padrão

$$\sqrt{\frac{0.75(1-0.75)}{30}}$$

(distribuição ao lado).

Podemos agora quantificar, sob as condições de  $H_0$ , a probabilidade de observarmos um valor de  $\hat{p} = 0.80$  ou mais extremo, .



O que quer dizer um valor mais extremo ?

A hipótese alternativa ( $H_a$ ) estabelece que  $p > 0.75$ , portanto a Eng. Florestal acredita que a mortalidade no ano de seca intensa é maior do que nos anos normais. Se isso de fato ocorrer, o valor amostral  $\hat{p}$  poderia ser ainda maior do que 0.80.

$$H_a : p > 0.75 \Rightarrow P[\hat{p} \geq 0.80]$$

$$H_0 : p = 0.75 \Rightarrow P[\hat{p} \geq 0.80] = P\left[Z \geq \frac{0.80 - 0.75}{\sqrt{0.75(1-0.75)/30}}\right] = P[Z \geq 0.63] = 0.2643$$

Portanto, sob  $H_0$ , a probabilidade de se observar um valor de  $\hat{p}$  ou maior é 0.2643. Se rejeitarmos  $H_0$  com base no valor observado de  $\hat{p} = 0.80$ , teremos a probabilidade de 0.2643 de cometermos um erro tipo I. Logo, 0.2643 é o valor-p, mas a margem de erro tipo I aceitável nas Ciências Florestais é de 0.05 ( $\alpha$  - nível de significância). Como o valor-p (0.2643) é bem maior do que o nível de significância ( $\alpha = 0.05$ ) nós não rejeitamos  $H_0$  e podemos concluir que, do ponto de vista estatístico, a afirmação da Eng. Florestal não procede.

## Testando Hipóteses sobre a Média de uma População

Até agora foi visto o teste  $Z$  para se testar a proporção de uma população. Qual seria o teste mais apropriado para testarmos hipóteses sobre a média de uma população?

### Exemplo 13.D Testando o pH do Solo

Um cientista deseja saber se o pH de um solo é ácido. Ele toma uma amostra com cinco unidades e obteve os valores de pH:

5.8; 6.3; 6.9; 6.2; 5.5

Considere os seguintes aspectos:

- O cientista considera o solo ácido se o seu pH for menor que 7. Portanto as hipóteses a serem testadas são:

$H_0$ : \_\_\_\_\_

$H_a$ : \_\_\_\_\_

- Utilizando a teoria da distribuição da média amostral podemos utilizar o seguinte raciocínio: Seja  $X$  o pH do solo e possui distribuição Normal com média  $\mu$  e desvio padrão  $\sigma$ , então:

$\bar{x}_5$  terá média igual  $\mu$ ;

$\bar{x}_5$  terá desvio padrão igual a  $\sigma/\sqrt{5}$ ;

$\bar{x}_5$  terá distribuição Normal.

- Logo, pela teoria da distribuição amostral, a estatística:

$$Z = \frac{\bar{x}_5 - \mu}{\sigma/\sqrt{5}}$$

terá distribuição Normal com média 0 e desvio padrão 1. Poderíamos utilizá-la para testar  $H_0$ .

Estas considerações apresentam um problema: a hipótese nula ( $H_0$ ) nos fornece uma indicação para a média da população ( $\mu$ ), mas não nos dá qualquer dica sobre o desvio padrão da população ( $\sigma$ ). O desvio padrão da população ( $\sigma$ ) permanece desconhecido e, não há modo de se obter a estatística  $Z$  com base na amostra tomada pelo cientista.

## Estatística $t$


Este tipo de problema já foi estudado no começo do século pelo matemático inglês William Gosset, que usava o pseudônimo "Student" para publicar os seus trabalhos. Student desenvolveu a seguinte estatística:

$$t = \frac{\bar{x}_n - \mu}{s_n / \sqrt{n}}$$

onde  $s_n$  é o desvio padrão amostral (amostra de tamanho  $n$ ).

A estatística  $t$  é uma variável aleatória cuja distribuição tem as seguintes propriedades:

1. Tem forma de sino (como a dist. Normal).
2. É simétrica em relação ao zero (como a dist. Normal Padronizada).
3. É mais "achatada" no centro e tem as caudas mais "pesadas".
4. Possui somente um parâmetro:  $\nu = n - 1$  chamado de graus de liberdade.
5. À medida que  $\nu \rightarrow \infty$ , então  $t \rightarrow Z$ , isto é, para grandes amostras a distribuição de  $t$  se aproxima da Normal Padronizada.



É importante notar que para cada valor dos graus de liberdade ( $\nu = n - 1$ ) temos uma distribuição diferente para o  $t$  de Student. A distribuição Normal Padronizada é uma única distribuição (o valor dos parâmetros são fixos), mas a distribuição  $t$  de Student é na verdade uma *família de distribuições*, pois cada valor particular de  $\nu$  gera uma distribuição distinta das demais.

## Testando Hipóteses sobre a Média de uma População

Até agora foi visto o teste  $Z$  para se testar a proporção de uma população. Qual seria o teste mais apropriado para testarmos hipóteses sobre a média de uma população?

### Exemplo 13.D Testando o pH do Solo

Um cientista deseja saber se o pH de um solo é ácido. Ele toma uma amostra com cinco unidades e obteve os valores de pH:

5.8; 6.3; 6.9; 6.2; 5.5

Considere os seguintes aspectos:

- O cientista considera o solo ácido se o seu pH for menor que 7. Portanto as hipóteses a serem testadas são:

$H_0$ : \_\_\_\_\_

$H_a$ : \_\_\_\_\_

- Utilizando a teoria da distribuição da média amostral podemos utilizar o seguinte raciocínio: Seja  $X$  o pH do solo e possui distribuição Normal com média  $\mu$  e desvio padrão  $\sigma$ , então:

$\bar{x}_5$  terá média igual  $\mu$ ;

$\bar{x}_5$  terá desvio padrão igual a  $\sigma/\sqrt{5}$ ;

$\bar{x}_5$  terá distribuição Normal.

- Logo, pela teoria da distribuição amostral, a estatística:

$$Z = \frac{\bar{x}_5 - \mu}{\sigma/\sqrt{5}}$$

terá distribuição Normal com média 0 e desvio padrão 1. Poderíamos utilizá-la para testar  $H_0$ .

Estas considerações apresentam um problema: a hipótese nula ( $H_0$ ) nos fornece uma indicação para a média da população ( $\mu$ ), mas não nos dá qualquer dica sobre o desvio padrão da população ( $\sigma$ ). O desvio padrão da população ( $\sigma$ ) permanece desconhecido e, não há modo de se obter a estatística  $Z$  com base na amostra tomada pelo cientista.

### Exemplo 13.D Testando o pH do Solo

Podemos agora testar as hipótese a respeito do pH do solo utilizando a estatística  $t$ . Seja  $\mu$  o pH médio do solo e  $\bar{x}$  a média amostral dos pHs na amostra:

- Hipóteses

$$H_0 : \mu = 7$$

$$H_a : \mu < 7$$

- Dados

$$\bar{x} = (5.8 + 6.3 + 6.9 + 6.2 + 5.5)/5 = 6.14$$

$$s = 0.5320$$

- Estatística  $t$ :

$$t = \frac{6.14 - 7}{0.5320/\sqrt{5}} = -3.61$$

- Valor-p


$$H_a : \mu < 7 \Rightarrow P[\bar{x} < 6.14] \Rightarrow P[t < -3.61] \Rightarrow P[t > 3.61] \quad (\text{Simétrica em relação ao zero})$$

$$H_0 : \mu = 7 \Rightarrow P[t > 3.61] = \text{valor-p}$$

Na tabela do  $t$  de Student (Anexo C) encontramos o valor 2.13 para  $t_{\alpha=0.05; \nu=4}$ .

Logo:

$$\begin{aligned} P[t > 3.61] < P[t > 2.13] &\Rightarrow P[t < -3.61] < P[t < -2.13] \\ &\Rightarrow \text{valor-p} < \alpha = 0.05 \end{aligned}$$



- Decisão: Rejeita-se  $H_0$  (ao nível de 5% de probabilidade) e conclui-se que existe evidência estatística para afirmar que o pH médio do solo é menor que 7.

## 10.2 Distribuição Amostral da Proporção

Seja  $p$  a proporção das unidades de uma população que possuem uma certa característica (proporção de “sucessos”), como por exemplo:

- árvores com cancro numa floresta de eucalipto;
- árvores cobertas por cipós numa mata;
- árvores dominadas (árvores vivas com altura inferior a 1,30m) numa floresta plantada de *Pinus*;
- capivaras do sexo masculino.

Se amostras aleatórias de tamanho  $n$  forem tomadas de uma população com proporção  $p$ , então a distribuição amostral de  $\hat{p}_n$  tem as seguintes propriedades:

$$1. \mu_{\hat{p}} = p \Rightarrow \hat{p}_n \text{ é um estimador sem viés de } p.$$

$$2. \sigma_{\hat{p}}^2 = \frac{p(1-p)}{n} \Rightarrow \sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{n}}$$

Se o tamanho da amostra cresce, o desvio padrão da proporção amostral decresce.

3. Se a população original tem uma distribuição qualquer, para  $n$  suficientemente grande ( $n \geq 30$ ),  $\hat{p}_n$  terá distribuição aproximadamente normal:

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

## Teste de hipóteses para a média de uma população

1º Passo: Hipóteses

$$H_0 : \mu = \mu_0$$

vs

$$H_a : \mu \neq \mu_0 \rightarrow \text{bilateral}$$

$$H_a : \begin{cases} \mu < \mu_0 \\ \mu > \mu_0 \end{cases} \left. \vphantom{H_a} \right\} \text{unilateral}$$

2º Passo: Estatística do teste

2.1. Variância conhecida  $\Rightarrow z_{\text{calc}} = \frac{\bar{x} - \mu_0}{\sqrt{\frac{\sigma^2}{n}}}$

2.2. Variância desconhecida  $\Rightarrow t_{\text{calc}} = \frac{\bar{x} - \mu_0}{\sqrt{\frac{s^2}{n}}}$  com (n-1) g.l.

2.3. Variância desconhecida com  $n > 30$  (aproximação normal)  $\Rightarrow z_{\text{calc}} = \frac{\bar{x} - \mu_0}{\sqrt{\frac{s^2}{n}}}$




3º Passo: Regiões de Rejeição

3.1. Variância conhecida ou aproximação normal

$$H_a : \mu \neq \mu_0$$

$$H_a : \mu < \mu_0$$

$$H_a : \mu > \mu_0$$






3.2. Variância desconhecida

$$H_a : \mu \neq \mu_0$$

$$H_a : \mu < \mu_0$$

$$H_a : \mu > \mu_0$$



4º Passo: Conclusões

### Teste de hipóteses para a proporção de uma população

1º Passo: Hipóteses


$$H_0 : p = p_0 \quad \text{vs} \quad \begin{array}{l} H_a : p \neq p_0 \rightarrow \text{bilateral} \\ H_a : \left. \begin{array}{l} p < p_0 \\ p > p_0 \end{array} \right\} \text{unilateral} \end{array}$$

2º Passo: Estatística do teste


$$z_{\text{calc}} = \frac{\hat{p} - p_0}{\sqrt{\frac{p_0(1-p_0)}{n}}}$$

3º Passo: Regiões de Rejeição


$$H_a : p \neq p_0$$



$$H_a : p < p_0$$



$$H_a : p > p_0$$



4º Passo: Conclusões

### Teste para a diferença de médias de 2 populações – amostra pareada

1º Passo: Hipóteses

$$H_0 : \mu_1 - \mu_2 = \theta_0$$

vs

$$H_a : \mu_1 - \mu_2 \neq \theta_0 \rightarrow \text{bilateral}$$

$$H_a : \left. \begin{array}{l} \mu_1 - \mu_2 < \theta_0 \\ \mu_1 - \mu_2 > \theta_0 \end{array} \right\} \text{unilateral}$$

2º Passo: Estatística do teste

					Média	Var.
Amostra 1	$x_{11}$	$x_{12}$	...	$x_{1n}$	$\bar{x}_1$	$s_1^2$
Amostra 2	$x_{21}$	$x_{22}$	...	$x_{2n}$	$\bar{x}_2$	$s_2^2$
diferença ( $d_i$ )	$d_1$	$d_2$	...	$d_n$	$\bar{d}$	$s_d^2$




$$t_{\text{calc}} = \frac{\bar{d} - \theta_0}{\sqrt{\frac{s_d^2}{n}}} \text{ com } (n-1) \text{ g.l., sendo } n = \text{número de pares}$$

3º Passo: Regiões de Rejeição

$$H_a : \mu_1 - \mu_2 \neq \theta_0$$

$$H_a : \mu_1 - \mu_2 < \theta_0$$

$$H_a : \mu_1 - \mu_2 > \theta_0$$



4º Passo: Conclusões

**Teste para a diferença de médias de 2 populações – amostra não pareada**

1º Passo: Hipóteses

$$H_0 : \mu_1 - \mu_2 = \theta_0 \quad \text{vs} \quad \left. \begin{array}{l} H_a : \mu_1 - \mu_2 \neq \theta_0 \rightarrow \text{bilateral} \\ H_a : \begin{cases} \mu_1 - \mu_2 < \theta_0 \\ \mu_1 - \mu_2 > \theta_0 \end{cases} \rightarrow \text{unilateral} \end{array} \right\}$$

2º Passo: Estatística do teste

					Média	Var.
Amostra 1	$x_{11}$	$x_{12}$	...	$x_{1n}$	$\bar{x}_1$	$s_1^2$
Amostra 2	$x_{21}$	$x_{22}$	...	$x_{2n}$	$\bar{x}_2$	$s_2^2$

2.1. Variâncias homogêneas

$$t_{\text{calc}} = \frac{\bar{x}_1 - \bar{x}_2 - \theta_0}{\sqrt{\left(\frac{1}{n_1} + \frac{1}{n_2}\right) \left(\frac{(n_1-1)s_1^2 + (n_2-1)s_2^2}{n_1 + n_2 - 2}\right)}} \text{ com } (n_1+n_2-2) \text{ g.l.}$$

2.1. Variâncias heterogêneas




$$t_{\text{calc}} = \frac{\bar{x}_1 - \bar{x}_2 - \theta_0}{\sqrt{\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}}} \text{ com } v = \frac{\left(\frac{s_1^2}{n_1} + \frac{s_2^2}{n_2}\right)^2}{\frac{\left(\frac{s_1^2}{n_1}\right)^2}{n_1-1} + \frac{\left(\frac{s_2^2}{n_2}\right)^2}{n_2-1}}$$

3º Passo: Regiões de Rejeição

$H_a : \mu_1 - \mu_2 \neq \theta_0$

$H_a : \mu_1 - \mu_2 < \theta_0$

$H_a : \mu_1 - \mu_2 > \theta_0$



4º Passo: Conclusões

### Teste de variância de 2 populações

#### 1º Passo: Hipóteses

$$H_0 : \sigma_1^2 = \sigma_2^2$$

vs

$$H_a : \sigma_1^2 > \sigma_2^2 \rightarrow \text{unilateral}$$


$$H_a : \sigma_1^2 \neq \sigma_2^2 \rightarrow \text{bilateral}$$

#### 2º Passo: Estatística do teste

					Média	Var.
Amostra 1	$x_{11}$	$x_{12}$	...	$x_{1n}$	$\bar{x}_1$	$s_1^2$
Amostra 2	$x_{21}$	$x_{22}$	...	$x_{2n}$	$\bar{x}_2$	$s_2^2$

$$F_{\text{calc}} = \frac{S_{\text{max}}^2}{S_{\text{min}}^2} \quad \text{com} \quad \begin{matrix} v_1 = (n_1 - 1) \text{ g.l.} & (\text{g.l. do numerador}) \\ v_2 = (n_2 - 1) \text{ g.l.} & (\text{g.l. do denominador}) \end{matrix}$$

#### 3º Passo: Regiões de Rejeição



#### 4º Passo: Conclusões

- Obs:** Se  $H_0$  é rejeitada – variância heterogênea
- Se  $H_0$  não é rejeitada – variância homogênea