

# Distribuição de $\bar{X}$

## Exemplo

Uma variável aleatória  $X$  tem distribuição normal, com média 100 e desvio padrão 10.

- Qual a  $P(90 < X < 110)$ ?
- Se  $\bar{X}$  for a média de uma amostra de 16 elementos retirados dessa população, calcule  $P(90 < \bar{X} < 110)$ .
- Represente, num único gráfico, as distribuições de  $X$  e  $\bar{X}$ .
- Que tamanho deveria ter a amostra para que  $P(90 < \bar{X} < 110) = 0.95$ ?

Fonte: Morettin & Bussab, Estatística Básica 5<sup>a</sup> edição, pág 274.

# Distribuição de $\bar{X}$

- (a) Devemos padronizar o evento, para comparar com a distribuição normal padrão.

$$\begin{aligned} P(90 < X < 110) &= P\left(\frac{90 - 100}{10} < \frac{X - 100}{10} < \frac{110 - 100}{10}\right) \\ &= P(-1 < Z < 1) = P(Z < 1) - P(Z < -1) = \Phi(1) - \Phi(-1) \end{aligned}$$

Consultando a tabela disponível na página da disciplina<sup>1</sup>, vemos que  $\Phi(1) = 0.8413$ . Para encontrar  $\Phi(-1)$ , note que a distribuição normal é simétrica e portanto  $\Phi(-z) = 1 - \Phi(z)$ , daí  $\Phi(-1) = 0.1569$  e portanto  $\Phi(1) - \Phi(-1) = 0.6844$ .

---

<sup>1</sup><http://www.ime.unicamp.br/~veronica/Coordenadas1s/N.pdf>

# Distribuição de $\bar{X}$

(b) Se temos uma amostra e tiramos a média, note agora que

$$\text{Var}(\bar{X}) = \text{Var}\left(\frac{1}{n} \sum_{i=1}^n X_i\right) \stackrel{(1)}{=} \frac{1}{n^2} \sum_{i=1}^n \text{Var}(X_i) \stackrel{(2)}{=} \frac{\text{Var}(X)}{n}$$

onde a igualdade (1) vale por independência, e a igualdade (2) vale por serem identicamente distribuidas. Consequentemente, o desvio padrão novo será  $\sigma/\sqrt{n}$ , ou  $10/4$ . Temos então que

$$P(90 < \bar{X} < 110) = P\left(\frac{90 - 100}{10/4} < \frac{\bar{X} - 100}{10/4} < \frac{110 - 100}{10/4}\right)$$

# Distribuição de $\bar{X}$

(b) Continuando,

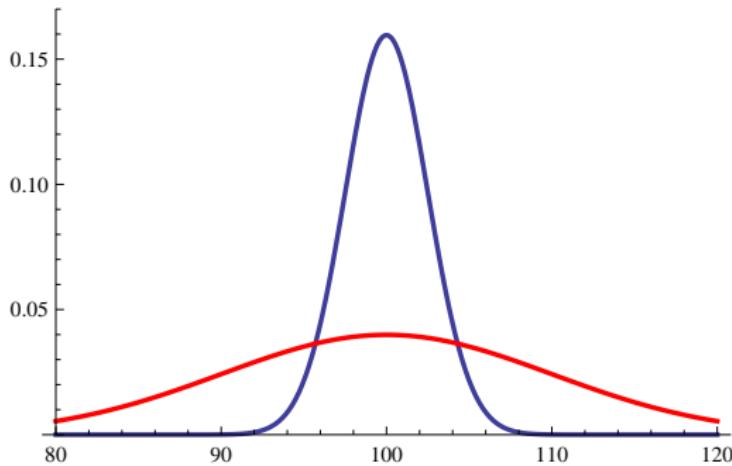
$$= P(-4 < Z < 4) = P(Z < 4) - P(Z < -4) = \Phi(4) - \Phi(-4)$$

Se consultarmos a tabela agora, veremos que a probabilidade  $P(Z < 4)$  é tão grande nem está listada. Ela então pode ser considerada 1.

De fato, com a ajuda de algum método de integração numérica, podemos verificar que  $\Phi(4) - \Phi(-4)$  é igual a 0.9999367.

# Distribuição de $\bar{X}$

- (c) No gráfico, a função de densidade de  $X$  está em vermelho, e a de  $\bar{X}$  em azul:



# Distribuição de $\bar{X}$

(d) Queremos resolver a seguinte equação:

$$P\left(\frac{90 - 100}{10/\sqrt{n}} < \frac{\bar{X} - 100}{10/\sqrt{n}} < \frac{110 - 100}{10/\sqrt{n}}\right) = 0.95$$

Note que, consultando a tabela, vemos que

$P(-q < Z < q) = 0.95$  se  $q = 1.96$ . Então a equação que queremos resolver pode ser reescrita como:

$$\frac{110 - 100}{10/\sqrt{n}} = 1.96 \Leftrightarrow \sqrt{n} \frac{110 - 100}{10} = 1.96 \Leftrightarrow n = 1.96^2$$

Portanto,  $n = 4$  é suficiente para obtermos a confiança desejada.

# Precisão e Tamanho Amostral

## Exemplo

Qual deve ser o tamanho de uma amostra cujo desvio-padrão é 10 para que a diferença da média amostral para a média da população, em valor absoluto, seja menor que 1, com coeficiente de confiança igual a:

- (a) 95%
- (b) 99%

*Fonte: Morettin & Bussab, Estatística Básica 5<sup>a</sup> edição, pág 308.*

## Precisão e Tamanho Amostral

- (a) Note que se  $X \sim N(\mu, \sigma^2)$ , então  $X - \mu \sim N(0, \sigma^2)$ . Sabemos que  $\sigma = 10$ , e que o desvio-padrão do estimador da média,  $\bar{X}$ , será  $10/\sqrt{n}$ . Queremos que  $P(|\bar{X} - \mu| < 1) = 0.95$ . Mas o evento é equivalente a

$$P(-\sqrt{n}/10 < Z < \sqrt{n}/10)$$

Como  $P(-1.96 < Z < 1.96) = 0.95$ , então  $\sqrt{n}/10 = 1.96$  ou  $n \approx 385$ .

- (b) De modo análogo, temos que  $P(-2.57 < Z < 2.57) = 0.99$ , então  $\sqrt{n}/10 = 2.57$  ou  $n \approx 665$ .

# Intervalo de Confiança para proporções

## Exemplo

Suponha que  $p = 30\%$  dos estudantes de uma escola sejam mulheres. Colhemos uma amostra aleatória simples 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? E se  $n = 50$ ?

*Adaptado de: Morettin & Bussab, Estatística Básica 5<sup>a</sup> edição, pág 276.*

# Intervalo de Confiança para proporções

Temos que a probabilidade que desejamos encontrar é dada por

$$P(|\hat{p} - p| < 0.01) = P(-0.01 < \hat{p} - p < 0.01)$$

Onde  $p$  é o valor verdadeiro da proporção de mulheres, e  $\hat{p}$  a proporção observada na amostra. Sabemos que se  $n$  é grande,  $\hat{p} - p$  pode ser aproximada por uma normal  $N(0, p(1 - p)/n)$ . Como  $p = 0.3$ , temos que

$$\text{Var}(\hat{p} - p) = \frac{0.3 \cdot 0.7}{10} = 0.021$$

# Intervalo de Confiança para proporções

Portanto, a probabilidade pedida é igual a

$$P\left(\frac{-0.01}{\sqrt{0.021}} < Z < \frac{0.01}{\sqrt{0.021}}\right) = P(-0.07 < Z < 0.07) = 0.056$$

Mas  $n = 10$  é grande? Podemos comparar essa probabilidade com o resultado exato.

Não sabemos a distribuição de  $\hat{p}$ , mas o evento  $\hat{p} = \alpha$  é igual ao evento  $\sum X_i = n\alpha$ , onde  $X_i$  são v.a. independentes e identicamente distribuidas Bernoulli(0.3). A soma é portanto Binomial(10, 0.3).

# Intervalo de Confiança para proporções

O evento  $\{|\hat{p} - p| < 0.01\}$  é igual ao evento  $\{|\sum X_i - 10 \cdot 0.3| < 0.1\}$ . Como  $\sum X_i$  assume somente valores inteiros, temos que

$$\left\{ \left| \sum_{i=1}^{10} X_i - 10 \cdot 0.3 \right| < 0.1 \right\} = \left\{ \sum_{i=1}^{10} X_i = 3 \right\}.$$

Portanto,

$$P \left( \left\{ \sum_{i=1}^{10} X_i = 3 \right\} \right) = \binom{10}{3} 0.3^3 0.7^7 = 0.267.$$

Temos uma probabilidade que é 5 vezes maior que a aproximação.

# Intervalo de Confiança para proporções

Tome  $n = 50$ , agora. Podemos modificar rapidamente as contas da aproximação normal. A variância agora é 0.0042, e portanto a probabilidade aproximada é

$$P\left(\frac{-0.01}{\sqrt{0.0042}} < Z < \frac{0.01}{\sqrt{0.0042}}\right) = P(-0.154 < Z < 0.154) = 0.12239$$

A probabilidade exata agora é dada pelo evento  
 $\{|\sum X_i - 50 \cdot 0.3| < 0.5\}$ , ou simplesmente  $\{\sum_{i=1}^{50} X_i = 15\}$ .

# Intervalo de Confiança para proporções

Observe agora que

$$P\left(\sum_{i=1}^{50} X_i = 15\right) = \binom{50}{15} 0.3^{15} 0.7^{50-15} = 0.12237$$

A diferença agora é muito menor e, é possível demonstrar, para  $n \rightarrow \infty$  ela desaparece. É preciso contudo ter em mente que a aproximação só é válida para grandes tamanhos de amostra, independentes e identicamente distribuidas.

# Intervalo de Confiança para proporções

## Exemplo

Uma amostra aleatória de 625 donas de casa revela que 70% delas preferem a marca A de detergente. Construir um intervalo de confiança para  $p =$  proporção das donas de casa que preferem A com coeficiente de confiança  $\gamma = 90\%$ .

Fonte: Morettin & Bussab, Estatística Básica 5<sup>a</sup> edição, pág 308.

## Intervalo de Confiança para proporções

Temos que em nossa amostra aleatória  $\hat{p} = 0.7$ . Como  $\hat{p} \sim N(p, p(1 - p)/n)$ , então o intervalo de confiança é dado por

$$\left( \hat{p} - z(\gamma) \sqrt{\hat{p}(1 - \hat{p})/n} ; \hat{p} + z(\gamma) \sqrt{\hat{p}(1 - \hat{p})/n} \right)$$

Temos que para  $\gamma = 0.90$ ,  $z(\gamma) = 1.68$  e portanto o intervalo de confiança para a proporção de donas de casa que preferem o detergente A é dado por

$$\left( 0.7 - 1.68 \sqrt{0.7 \cdot 0.3/625} ; 0.7 + 1.68 \sqrt{0.7 \cdot 0.3/625} \right)$$

$$(0.6692 ; 0.7308)$$

# Intervalo de Confiança para proporções

## Exercício

Suponha que estejamos interessados em estimar a porcentagem de consumidores de um certo produto. Se a amostra de tamanho 300 forneceu 100 indivíduos que consomem o dado produto, determine:

- O intervalo de confiança de  $p$ , com c.c. de 95%; interprete o resultado.
- O tamanho da amostra para que o erro da estimativa não exceda 0.02 unidades com probabilidade de 95%; interprete o resultado.

Fonte: Morettin & Bussab, Estatística Básica 5<sup>a</sup> edição, pág 309.

# Intervalo de Confiança para proporções

- (a) O intervalo de confiança a 95% de confiabilidade é dado por:

$$IC(p; 0.95) = 0.333 \pm 1.96 \sqrt{\frac{0.333 \cdot 0.667}{300}} = 0.333 \pm 0.053$$

Ou simplesmente (0.280; 0.387).

*Interpretação:* Se pudéssemos construir um grande número de intervalos aleatórios para  $p$ , todos baseados em amostras de tamanho  $n$ , 95% deles conteriam o parâmetro  $p$ .

# Intervalo de Confiança para proporções

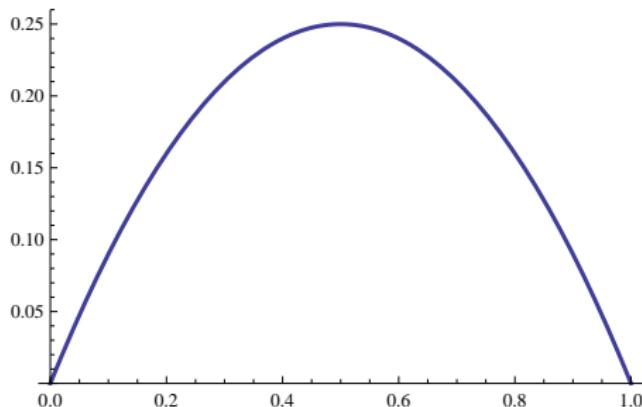
- (b) Utilizando a estimativa da amostra observada ( $\hat{p} = 0.333$ ), temos que  $n$  é dado por

$$n = \left( \frac{1.96}{0.02} \right)^2 \times 0.333 \times 0.667 \cong 2134.$$

Contudo, frequentemente devemos determinar o tamanho da amostra antes de realizar qualquer experimento, isto é, sem nenhuma informação prévia de  $p$ . Se esse for o caso, devemos considerar o caso em que a variância da amostra é a pior possível.

# Intervalo de Confiança para proporções

- (b) Se olhamos a variância como função de  $p$ , obtemos o seguinte gráfico:



Note que a variância é máxima quando  $p = 1/2$ .

# Intervalo de Confiança para proporções

(b) Utilizando o valor máximo de  $p(1 - p)$ , isto é,  $1/4$ , obtemos

$$n = \left( \frac{1.96}{0.02} \right)^2 \times \frac{1}{4} \cong 2401$$

*Interpretação:* Utilizando o tamanho amostral encontrado, teremos uma probabilidade de 95% de que a proporção amostral não difira do verdadeiro valor de  $p$  em menos que 2%.

Note que a prática de obter amostras pequenas para examinar  $p$ , e aí determinar o tamanho amostral sem utilizar o “pior caso”, é no que consiste a idéia de *amostras piloto*.

# Intervalo de Confiança

## Exemplo

Estão sendo estudados dois processos para conservar alimentos, cuja principal variável de interesse é o tempo de duração destes. No processo A, o tempo  $X$  de duração segue a distribuição  $N(\mu_A, 100)$ , e no processo B o tempo  $Y$  obedece à distribuição  $N(\mu_B, 100)$ . Sorteiam-se duas amostras independentes: a de A, com 16 latas, apresentou tempo médio de duração igual a 50, e a de B, com 25 latas, duração média igual a 60.

- (a) Construa um IC para  $\mu_A$  e  $\mu_B$ , separadamente.

# Intervalo de Confiança

## Exemplo

- (b) Para verificar se os dois processos podem ter o mesmo desempenho, decidiu-se construir um IC para a diferença  $\mu_A - \mu_B$ . Caso o zero pertença ao intervalo, pode-se concluir que existe evidência de igualdade dos processos. Qual seria sua resposta?

Fonte: Morettin & Bussab, Estatística Básica 5<sup>a</sup> edição, pág 318.

# Intervalo de Confiança

- (a) Para o caso geral, o intervalo de confiança para  $\mu$ , com coeficiente de confiabilidade  $\gamma$ , é dado por

$$\left( \bar{X} - z(\gamma) \sqrt{\sigma^2/n} ; \bar{X} + z(\gamma) \sqrt{\sigma^2/n} \right)$$

Repare que  $\sigma_A = \sigma_B$ . Para o coeficiente de confiança  $\gamma = 0.95$ , por exemplo, temos  $z(\gamma) = 1.96$ , e os intervalos de confiança serão, respectivamente:

$$IC(\mu_A) = \left( 50 - 1.96 \sqrt{100/16} ; 50 + 1.96 \sqrt{100/16} \right)$$

$$IC(\mu_B) = \left( 60 - 1.96 \sqrt{100/25} ; 60 + 1.96 \sqrt{100/25} \right)$$

# Intervalo de Confiança

(a) (cont.) Fazendo as contas, obtemos que

$$\text{IC}(\mu_A) = (45.1 ; 54.9)$$

$$\text{IC}(\mu_B) = (56.08 ; 63.92)$$

Observe que os intervalos não se interceptam; temos evidência para dizer que as durações médias serão diferentes, a 95% de confiança.

(b) Temos aqui duas amostras diferentes mas independentes. A diferença  $\bar{X}_A - \bar{X}_B$  tem distribuição Normal, com média  $\mu_A - \mu_B$  e variância  $\sigma_A^2/n_A + \sigma_B^2/n_B$ .

# Intervalo de Confiança

(b) (cont.) Então o intervalo de confiança para  $\mu_A - \mu_B$  é dado por

$$\left( \bar{X}_A - \bar{X}_B - z(\gamma) \sqrt{\sigma_A^2/n_A + \sigma_B^2/n_B} ; \right.$$

$$\left. \bar{X}_A - \bar{X}_B + z(\gamma) \sqrt{\sigma_A^2/n_A + \sigma_B^2/n_B} \right)$$

Aplicando os valores conhecidos ou observados, e fixando a confiança em  $\gamma = 0.95$  temos:

$$IC(\mu_A - \mu_B) = \left( 50 - 60 - 1.96 \sqrt{100/16 + 100/25} ; \right.$$

$$\left. 50 - 60 + 1.96 \sqrt{100/16 + 100/25} \right)$$

# Intervalo de Confiança

(b) (cont.) Executando as contas, obtemos finalmente que

$$\text{IC}(\mu_A - \mu_B) = (-16.27 ; -3.72)$$

Em concordância com o item (a), vemos que 0 não está contido no intervalo e, portanto, rejeitamos a hipótese, a  $\gamma = 0.95$  de confiança, das médias  $\mu_A$  e  $\mu_B$  serem iguais.