

# Intervalo de Confiança

para a media de uma variavel aleatoria  $\mu = EX$  qualquer

para uma proporcao  $p = EX$  quando  $X \sim \text{Bernoulli}(p)$

parâmetros  $\mu$  e  $p$

Na aula passada foi discutida a ideia de **estimador** e algumas de suas propriedades.

Amostra

$X_1$   
 $X_2$   
 $\vdots$   
 $X_n$

$\rightarrow T(X_1, X_2, \dots, X_n)$

Variavel aleatoria

Fornece uma estimativa pontual para um parametro.

Lembrando que temos

Estimadores e

Parametros

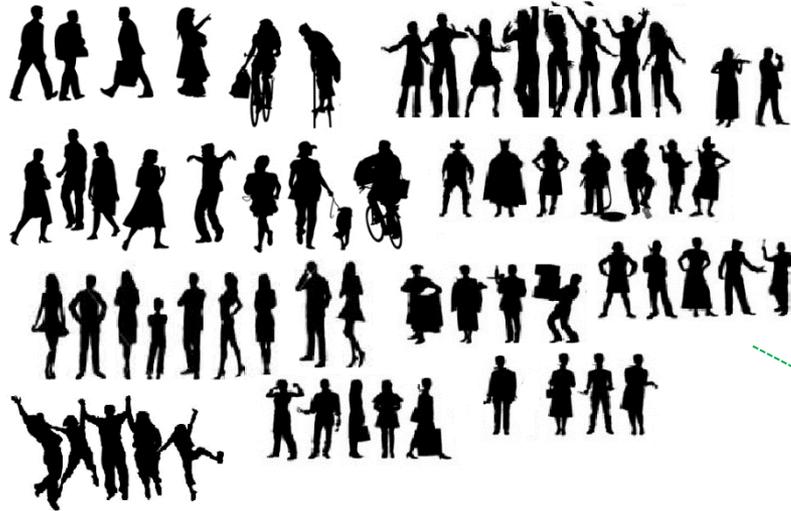
**Parâmetro:** quantidade desconhecida de uma característica da população e sobre a qual temos interesse.

Exemplos:  $\mu$  - *média da característica da população:*

$\mu$  : 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 pacientes com menos de 40 anos diagnosticados com câncer nos pulmões.



$X$ : variável de interesse : *Renda*

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



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

$X_{(\text{João})}$

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

$X_1, X_2, \dots, X_n$ , *i.i.d.*

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)  $\Rightarrow f(X_1, X_2, \dots, X_n)$ .

$$T(X_1, X_2, \dots, X_n)$$

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

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

*Vamos discutir estes dois exemplos mais importantes:  $\bar{X}$  e  $\hat{p}$*

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

Suponha que queremos estimar  $\mu = EX$  onde  $X$  é a variável aleatória de interesse.

Digamos  $X$  = "renda de um indivíduo escolhido ao acaso de certa população"

Usamos o estimador  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$

Pelo TLC temos para a diferença entre  $\bar{X}$  e  $\mu$

$$e = (\bar{X} - \mu) \sim N(0; \sigma_{\bar{X}}^2)$$

↑  
"erro"

↑  
aprox.

$$\sigma_{\bar{X}}^2 = \frac{\sigma_X^2}{n}$$

$$\frac{\bar{X} - \mu}{\sigma_{\bar{X}}} = \frac{e}{\sigma_{\bar{X}}} \sim N(0; 1)$$

↑  
Aprox.

O erro  $e = \bar{X} - \mu$

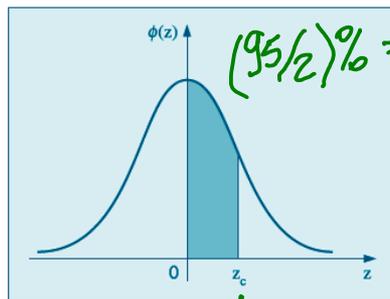
$e$  é uma variável aleatória. Pelo TLC podemos estimar a chance dele ser "grande".

Por exemplo, temos

$$P(|e| < 1,96 \sigma_{\bar{X}}) \approx 0,95$$

↑  
"aprox"

Figura 7.16:  $P(0 \leq Z \leq z_c)$  fornecido pela Tabela III.




$(95/2)\% = 47,5\%$

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

$$P(-1,96 < Z < 1,96) = 0,95$$

95%

1,96



$X$  - variável de interesse: *Renda*

Por exemplo, obter a distribuição amostral da Média

Amostra 1



$\bar{x}_1$

Amostra 2



$\bar{x}_2$

...

...

Amostra  $k$



$\bar{x}_k$

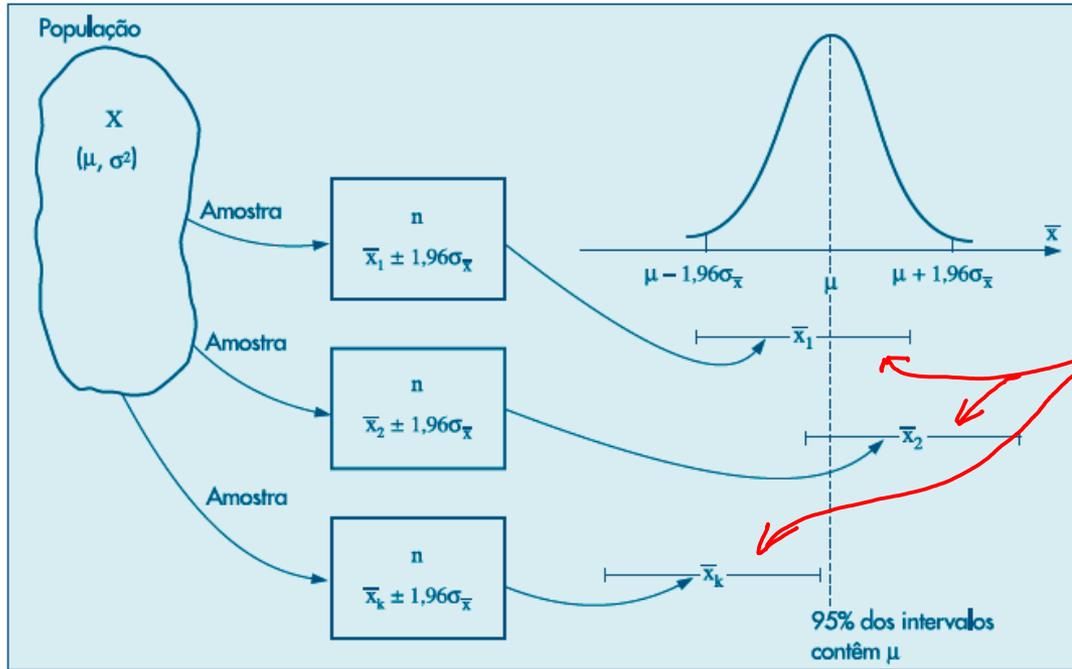
...

População das médias de amostras de tamanho  $n$

$$\bar{X} = \frac{1}{n} \sum_{i=1}^n x_i$$

Média amostral  
=  
estimador de  $\mu$

Figura 11.3: Significado de um IC para  $\mu$ , com  $\gamma = 0,95$  e  $\sigma^2$  conhecido.



$$\bar{X} - \epsilon \quad \bar{X} + \epsilon$$

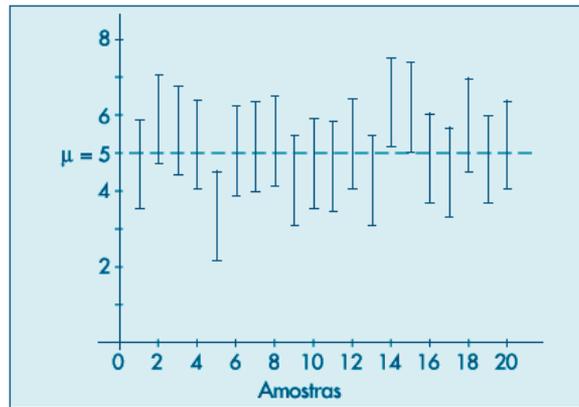
~~populacao~~

$\bar{X}$

"sao intervalos aleatorios"

Para um certo  $\epsilon$   
e um certo n

Figura 11.4: Intervalos de confiança para a média de uma  $N(5, 9)$ , para 20 amostras de tamanho  $n = 25$ .



qual e' a probabilidade  
deste intervalo  
conter o parametro?

$\gamma$  (letra gama)

# Estimativa por intervalo ou intervalo de confiança

- Para uma amostra observada, os estimadores pontuais fornecem como estimativa um único valor numérico para o parâmetro.
- Os estimadores pontuais são variáveis aleatórias e, portanto, possuem uma distribuição de probabilidade, em geral, denominada *distribuição amostral do estimador*.

**Ideia:** construir **intervalos de confiança**, que incorporem à estimativa pontual informações a respeito de sua variabilidade (erro amostral).

Intervalos de confiança são obtidos por meio da ***distribuição amostral do estimador pontual***.

Lembrando:

## *(Teorema Limite Central)*

Se a variável aleatória  $X$ , na população, tem distribuição com média  $\mu$  e variância  $\sigma^2$ , então, para uma amostra aleatória de tamanho  $n$  de  $X$ ,

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


*Aproximadamente,  
para n grande*

*e, portanto*

$$Z = \frac{\bar{X} - \mu}{\sqrt{\frac{\sigma^2}{n}}} \sim N(0, 1)$$


*Aproximadamente,  
para n grande*

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

$$\gamma = P(\varepsilon) = P(|\bar{X} - \mu| \leq \varepsilon).$$

"a distância entre  $\bar{X}$  e  $\mu$  é menor ou igual a  $\varepsilon$ "

"Intervalo contem  $\mu$ "

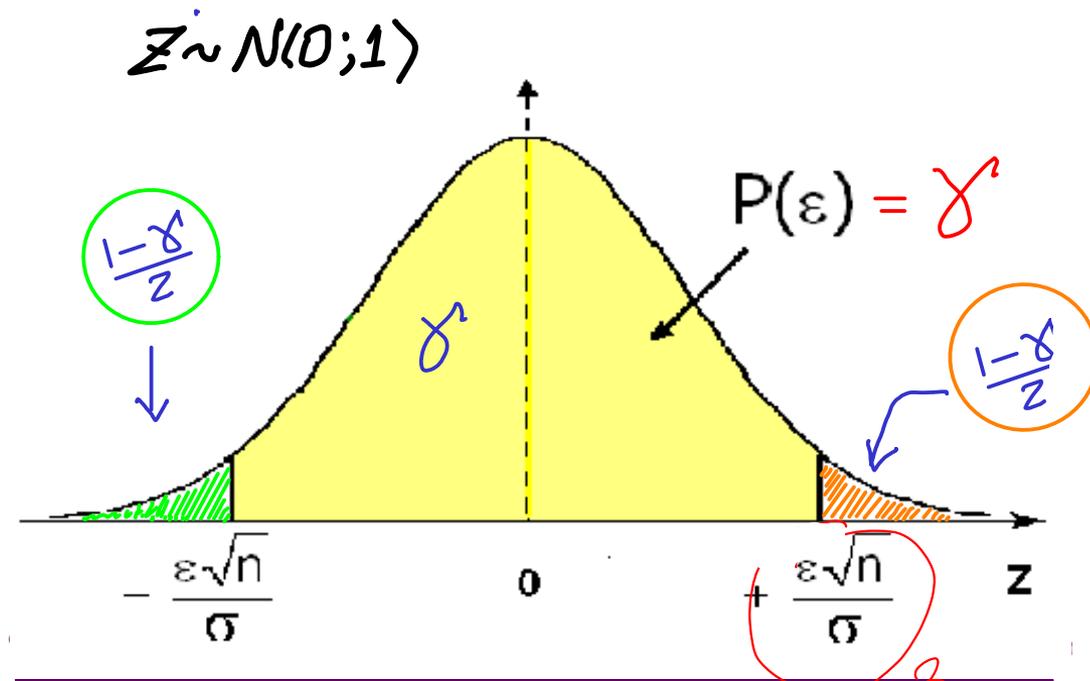
A probabilidade  $P(\varepsilon)$  é também denominada coeficiente de confiança do intervalo, que denotamos por  $\gamma$  (gama).

Desse modo, temos

$$P(\varepsilon) = P(|\bar{X} - \mu| \leq \varepsilon) = P(\mu - \varepsilon \leq \bar{X} \leq \mu + \varepsilon)$$

$$= P\left(\frac{-\varepsilon}{\sigma/\sqrt{n}} \leq \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \leq \frac{\varepsilon}{\sigma/\sqrt{n}}\right) = P\left(-\frac{\varepsilon\sqrt{n}}{\sigma} \leq Z \leq \frac{\varepsilon\sqrt{n}}{\sigma}\right)$$

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



Denotando  $\frac{\varepsilon\sqrt{n}}{\sigma} = z$ ,

temos que  $\gamma = P(-z \leq Z \leq z)$ .

*Determinado a partir da  
"Tabela da Normal-Padrão"*

$$A(\gamma) = \gamma + \frac{(1-\gamma)}{2}$$

Assim, conhecendo-se o coeficiente de confiança  $\gamma$  obtemos  $z$ .

# Erro na estimativa intervalar

Da igualdade  $z = \varepsilon \frac{\sqrt{n}}{\sigma}$ , segue que a margem de erro  $\varepsilon$  é dada por

$$\varepsilon = z \frac{\sigma}{\sqrt{n}},$$

sendo  $z$  tal que  $\gamma = P(-z \leq \mathbf{Z} \leq z)$ , com  $\mathbf{Z} \sim N(0, 1)$ .

O intervalo de confiança para a média  $\mu$ , com coeficiente de confiança  $\gamma$  está dado por

$$\left[ \bar{X} - z \frac{\sigma}{\sqrt{n}} ; \bar{X} + z \frac{\sigma}{\sqrt{n}} \right],$$

sendo  $\sigma$  o desvio padrão (conhecido) de  $X$ .

"amostra aleatória"

Antes de selecionarmos uma *a.a.*, a probabilidade de que o intervalo

$$\left[ \bar{X} - z \frac{\sigma}{\sqrt{n}} ; \bar{X} + z \frac{\sigma}{\sqrt{n}} \right],$$

contenha a média  $\mu$  verdadeira da população é  $\gamma$ .

Para o valor observado  $\bar{x}$  de  $\bar{X}$ , o intervalo de 95% de confiança será  $\left[ \bar{x} - 1,96 \frac{\sigma}{\sqrt{n}} ; \bar{x} + 1,96 \frac{\sigma}{\sqrt{n}} \right]$ ;

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

## Exemplo

Deseja-se estimar o tempo médio de estudo (em anos) da população adulta de um município. Sabe-se que o tempo de estudo tem distribuição normal com desvio padrão  $\sigma = 2,6$  anos. Foram entrevistados  $n = 25$  indivíduos, obtendo-se para essa amostra, um tempo médio de estudo igual a 10,5 anos. Obter um intervalo de 90% de confiança para o tempo médio de estudo na população.

$X$ : tempo de estudo, em anos, então  $X \sim N(\mu; 2,6^2)$

$$n = 25 \quad \Rightarrow \quad \bar{x} = 10,5 \text{ anos}$$

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

A estimativa intervalar com 90% de confiança é dada por:

$$\left[ \bar{X} - z \frac{\sigma}{\sqrt{n}}; \bar{X} + z \frac{\sigma}{\sqrt{n}} \right] =$$

$$\left[ 10,5 - 1,65 \frac{2,6}{\sqrt{25}}; 10,5 + 1,65 \frac{2,6}{\sqrt{25}} \right] =$$

$$[10,5 - 0,86; 10,5 + 0,86] =$$

$$[9,64; 11,36]$$

## Exemplo um pouco melhor de "media desconhecida mas variancia conhecida"

**Exemplo 11.13.** Uma máquina enche pacotes de café com uma variância igual a  $100 \text{ g}^2$ . Ela estava regulada para encher os pacotes com  $500 \text{ g}$ , em média. Agora, ela se desregulou, e queremos saber qual a nova média  $\mu$ . Uma amostra de  $25$  pacotes apresentou uma média igual a  $485 \text{ g}$ . Vamos construir um intervalo de confiança com  $95\%$  de confiança para  $\mu$ .

$$\left[ \bar{X} - z \frac{\sigma}{\sqrt{n}}; \bar{X} + z \frac{\sigma}{\sqrt{n}} \right]$$

então

$$\text{IC}(\mu; 0,95) = 485 \pm 1,96 \times 2,$$

ou seja,

$$\text{IC}(\mu; 0,95) = ]481, 489[,$$

pois  $\sigma_{\bar{x}} = \sigma/\sqrt{n} = 10/5 = 2\text{g}$ .

# Dimensionamento da amostra

*"Qual é o  $n$ ?"*

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

o tamanho da amostra  $n$  é determinado por

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

onde  $\varepsilon$  é a margem de erro,  $z$  é tal que

$$\gamma = P(-z \leq Z \leq z), \quad Z \sim N(0, 1)$$

e  $\sigma$  é o desvio padrão (conhecido) de  $X$ .

## Exemplo

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

$X$ : renda per-capita domiciliar na região  $\Rightarrow X \sim N(\mu; 250^2)$

$$\varepsilon = 50$$

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

$$n = ??$$

Então,

$$n = \left( \frac{z}{\varepsilon} \right)^2 \sigma^2 = \left( \frac{1,96}{50} \right)^2 \times (250)^2 = 96,04$$

Aproximadamente, **97** domicílios devem ser consultados.

Na prática, em geral, não conhecemos a variância populacional  $\sigma^2$ .

(Ou seja, tanto  $\mu$  quanto  $\sigma$  são desconhecidos)

## RESULTADO

Se  $X$  tem distribuição normal, com média  $\mu$  e variância  $\sigma^2$ , então, para uma amostra aleatória de tamanho  $n$  de  $X$ , temos que

$t_{n-1}$

Distribuição  
"t de Student"

$$T = \frac{\bar{X} - \mu}{\sqrt{\frac{S^2}{n}}} \sim t_{n-1},$$

A distribuição t  
depende de n,  
MAS

$$T \sim N(0,1)$$

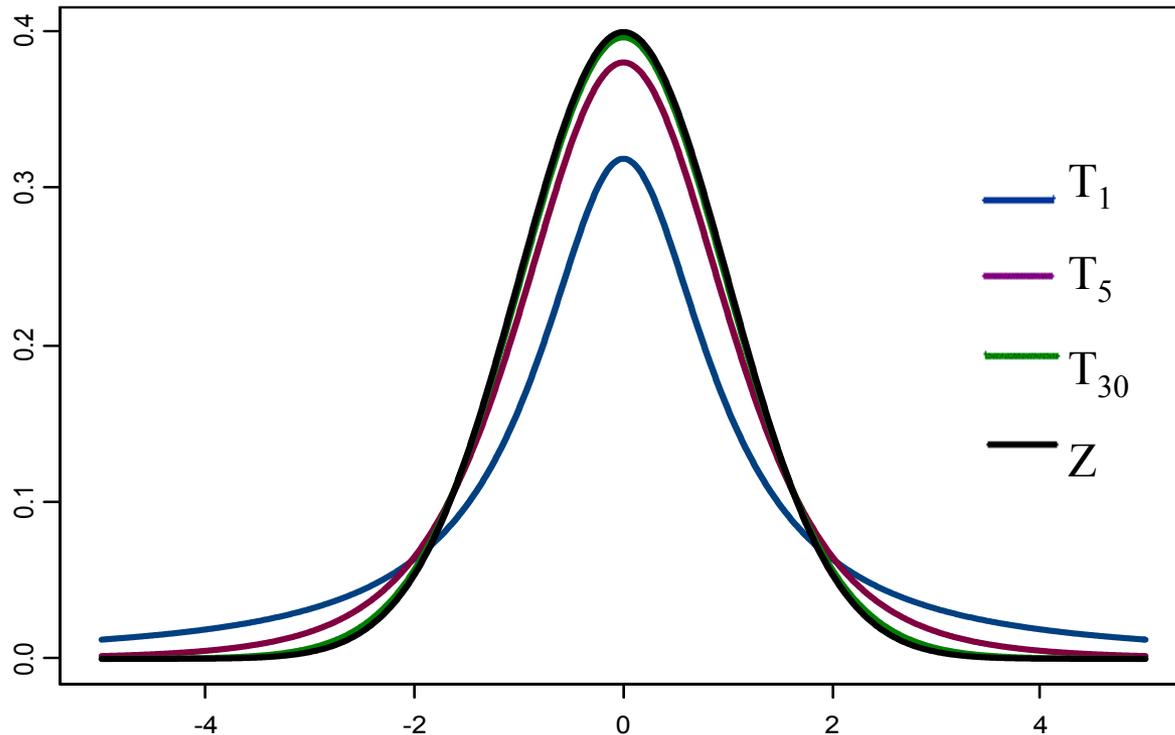
"aproximadamente  
se n for grande"

Estimador da variância  $\sigma^2$ :

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

é a variância amostral.

# Distribuição $t$ de Student



- tem caudas mais densas do que a distribuição normal;
- valores extremos são mais prováveis de ocorrer com a distribuição  $t$  do que com a normal padrão;

Vamos considerar agora o caso de "n grande" quando ha' pouca diferenca entre as duas distribuicoes.

Essa questao sera' retomada em "Testes de Hipoteses".

## Exemplo

A quantidade de colesterol  $X$  no sangue das alunas de uma universidade tem uma distribuição aproximadamente normal com média e desvio padrão desconhecidos.

Para estimar a quantidade média de colesterol  $\mu$  é selecionada uma amostra de 60 alunas. A média e o desvio padrão amostrais encontrados são 182 *mg/dl* e 50 *mg/dl*, respectivamente. Determine um intervalo de confiança com coeficiente de confiança de 90% para  $\mu$ .

$X$ : quantidade de colesterol no sangue das alunas da universidade  $\Rightarrow X \sim N(\mu, \sigma^2)$

$$n = 60 \Rightarrow \bar{x} = 182 \text{ e } s = 50$$

$$\gamma = 0,90 \Rightarrow z=1,65, \text{ usando a tabela da Normal Padrão}$$

Substituindo os valores:

$$IC(\mu; 90\%) = \left( 182 - 1,65 \cdot \frac{50}{\sqrt{60}} ; 182 + 1,65 \cdot \frac{50}{\sqrt{60}} \right) = ( 171,35 ; 192,25 )$$

## Estimador para uma proporção

Suponha que  $X \sim \text{Bernoulli}(p)$

$p = EX$       parâmetro de interesse

Estimador

$$\hat{p} = \frac{1}{n} \sum_{i=1}^n X_i = \text{"proporção amostral"}$$

onde  $X_1, X_2, \dots, X_n$  são os valores amostrais.

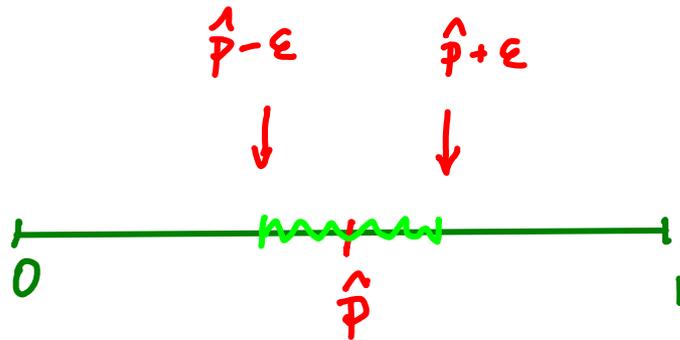
Pelo TLC

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

ou

$$e = \hat{p} - p \sim N\left(0; \frac{p(1-p)}{n}\right) = \text{"erro"}$$

Intervalo de confiança para  $p$  com coeficiente de confiança  $\gamma$

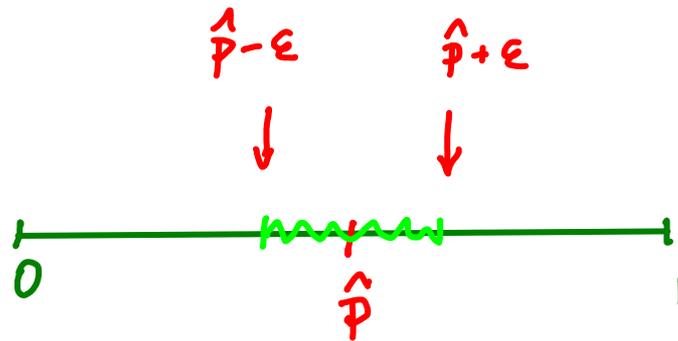


com

"Probabilidade do intervalo conter  $p$  é  $\gamma$ "

$$IC[p; \gamma] = [\hat{p} - \epsilon; \hat{p} + \epsilon]$$

"Probabilidade do intervalo conter  $p$  é  $\gamma$ "



$$\begin{aligned} \hat{p} - \epsilon < p &\Rightarrow \hat{p} < p + \epsilon \\ \hat{p} + \epsilon > p &\Rightarrow \hat{p} > p - \epsilon \end{aligned} \left. \vphantom{\begin{aligned} \hat{p} - \epsilon < p \\ \hat{p} + \epsilon > p \end{aligned}} \right\} p - \epsilon < \hat{p} < p + \epsilon$$

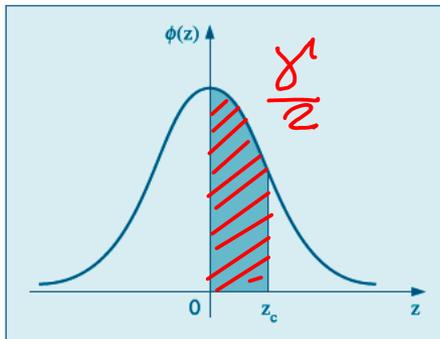
$$P(p - \epsilon < \hat{p} < p + \epsilon) = \gamma$$

$$P\left( \frac{p - \epsilon - p}{\sqrt{\frac{p(1-p)}{n}}} < \frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} < \frac{p + \epsilon - p}{\sqrt{\frac{p(1-p)}{n}}} \right) = \gamma$$

$$P\left( \frac{-\epsilon\sqrt{n}}{\sqrt{p(1-p)}} < Z < \frac{\epsilon\sqrt{n}}{\sqrt{p(1-p)}} \right) = \gamma$$

$$P(-z_{\alpha} < Z < z_{\alpha}) = \alpha$$

Figura 7.16:  $P(0 \leq Z \leq z_c)$  fornecido pela Tabela III.



$\uparrow$   
 $z_{\alpha}$

"Tabela"  $\Rightarrow$

$$z_{\alpha} = \frac{\epsilon \sqrt{n}}{\sqrt{p(1-p)}}$$

$\Downarrow$

$$\epsilon = z_{\alpha} \sqrt{\frac{p(1-p)}{n}}$$

"Entao" o intervalo de confianca para p (desconhecido) e'

$$\left[ \hat{p} - z_{\alpha} \sqrt{\frac{p(1-p)}{n}} ; \hat{p} + z_{\alpha} \sqrt{\frac{p(1-p)}{n}} \right]$$

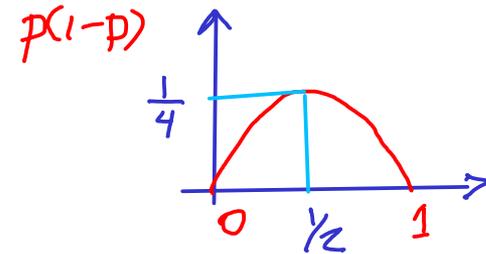
??????

## Duas solucoes: "Conservadora" e "Otimista"

Conservadora: tomo um intervalo que garante

"Probabilidade do intervalo conter  $p$  é pelo menos  $\gamma$ "

$$P(p - \epsilon < \hat{p} < p + \epsilon) \geq \gamma$$



Considero a maior variancia possivel:

$$\sigma_{\bar{x}} = \sigma_{\hat{p}} = \sqrt{\frac{p(1-p)}{n}} \leq \sqrt{\frac{\gamma/4}{n}} = \frac{1}{2\sqrt{n}}$$

$$\epsilon = \frac{\partial}{\partial \gamma} \sqrt{\frac{p(1-p)}{n}} \leq \frac{\partial}{\partial \gamma} \frac{1}{2\sqrt{n}}$$

$$IC [p; \alpha] = \left[ \hat{p} - \frac{\hat{\sigma}_p}{2\sqrt{n}} ; \hat{p} + \frac{\hat{\sigma}_p}{2\sqrt{n}} \right]$$

"Solucao Otimista": uso a estimativa de  $\sigma_{\hat{p}} = \sigma_p = \sqrt{\hat{p}(1-\hat{p})}$

$$IC [p; \alpha] = \left[ \hat{p} - \hat{\sigma}_p \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} ; \hat{p} + \hat{\sigma}_p \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right]$$

**Exemplo 11.15.** Numa pesquisa de mercado,  $n = 400$  pessoas foram entrevistadas sobre determinado produto, e 60% delas preferiram a marca A. Aqui,  $\hat{p} = 0,6$  e um intervalo de confiança para  $p$  com coeficiente de confiança  $\gamma = 0,95$  será

$$0,6 \pm (1,96) 1/\sqrt{1600} = 0,6 \pm 0,049,$$

ou seja

$$IC(p; 0,95) = ]0,551; 0,649[.$$



**intervalo "conservador" ou "cauteloso"**

pois pode ser bem maior que o necessario se  $p$  for "pequeno" ou "grande"

Na pratica, o mais frequente e' usar o resultado matematico

$$\frac{\hat{p} - p}{\sqrt{\frac{\hat{p}(1-\hat{p})}{n}}} \sim N(0,1)$$

↑  
aprox.

e considerar o "intervalo otimista"

$$IC[p; \gamma] = \left[ \hat{p} - z_{\gamma} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}; \hat{p} + z_{\gamma} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right]$$

**Exemplo 11.16.** Suponha que em  $n = 400$  provas obtemos  $k = 80$  sucessos. Vamos obter um intervalo de confiança para  $p$  com  $\gamma = 0,90$ . Como  $\hat{p} = 80/400 = 0,2$  e  $\hat{q} = 1 - \hat{p} = 0,8$ , então

$$0,2 \pm (1,645)\sqrt{(0,2)(0,8)/400} = 0,2 \pm 0,033,$$

ou seja,

$$IC(p; 0,90) = ]0,167; 0,233[.$$

Usando (11.40) o intervalo conservador é

$$IC(p; 0,90) = ]0,159; 0,241[.$$

("otimista")

compare!