

# TEMA 3: ESTIMAÇÃO POR INTERVALOS DE CONFIANÇA

## ESTATÍSTICA APLICADA I

Catarina S. Nunes

CatarinaS.Nunes@uab.pt

Departamento de Ciências e Tecnologia

Universidade Aberta

# Conteúdos Teóricos


- Principais distribuições amostrais: proporções; média; diferenças; variância; razão de variâncias.
- Intervalos de confiança para a média populacional
- Intervalos de confiança para a variância e para o desvio padrão populacionais
- Intervalos de confiança para a diferença entre médias populacionais
- Intervalos de confiança para a razão de variâncias populacionais
- Intervalos de confiança para proporções
- Intervalos de confiança para a diferença de proporções

# Estatística Inferencial

- Estatística Inferencial (ou Indutiva): a partir de uma amostra inferir sobre as características de uma população
- Podemos inferir determinadas características de uma população se extraírmos uma amostra representativa desta:

**População:** colecção de unidades individuais (pessoas ou resultados experimentais) com uma ou mais características comuns, que se pretendem estudar.

**Amostra:** Conjunto de dados ou observações, recolhidos a partir de um subconjunto da população, que se estuda com o objectivo de tirar conclusões para a população de onde foi recolhida




# Amostragem

## Amostragem: Processo pelo qual se extraem dados de uma população

- **Amostragem aleatória simples:** cada elemento da amostra é retirado aleatoriamente de toda a população (com ou sem reposição)  $\Rightarrow$  cada amostra tem a mesma probabilidade de ser recolhida;
- **Amostragem estratificada:** subdividir a população em, pelo menos, dois subgrupos distintos que partilham alguma característica e, em seguida, recolher uma amostra de cada um dos subgrupos (estratos);
- **Amostragem por clusters:** dividir a população em clusters (grupos); selecionar aleatoriamente alguns desses clusters; escolher todos os membros dos clusters selecionados.

# Amostra Aleatória



# Parâmetro versus Estatística

- **Parâmetro:** medida utilizada para descrever a distribuição da população
  - o valor esperado (média)  $\mu$  e a variância  $\sigma^2$  (ou desvio padrão  $\sigma$ ) são parâmetros de uma distribuição Normal -  $N \sim (\mu, \sigma^2)$
  - a probabilidade de sucesso  $p$  é um parâmetro da distribuição Binomial -  $B \sim (n, p)$
- **Estatística:** função de uma amostra aleatória que não depende de parâmetros desconhecidos; é uma v.a. que estima (pontualmente) um parâmetro populacional as vezes é chamada de simplesmente de estimador
  - média amostral:  $\bar{X} = 1/n \sum_{i=1}^n X_i$
  - variância amostral:  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
- **Estimativa pontual:** valor obtido a partir da amostra (valor do estimador) que se destina a fornecer valores aproximados do parâmetro

# Estimação por intervalos

## Estimação pontual (estatísticas) versus Estimação por intervalo (intervalos de confiança)

- Uma estimativa pontual de um parâmetro não contém informação sobre a precisão do valor obtido;
- A variância e o erro quadrático médio do estimador fornecem também alguma informação;
- Uma forma mais completa de abordar a questão consiste em construir estimativas na forma de intervalos e conhecer a probabilidade de o intervalo conter o verdadeiro valor do parâmetro.

## Intervalo de Confiança

Um intervalo de confiança para um parâmetro  $\theta$ , a um grau de confiança  $1 - \alpha$ , é o um intervalo aleatório  $(L_{inf}, L_{sup})$  tal que:

$$P(L_{inf} < \theta < L_{sup}) = 1 - \alpha, \quad \alpha \in (0, 1)$$

onde  $\alpha$  deve ser um valor muito reduzido por forma a termos confianças elevadas.

- Valores usuais para o grau de confiança são 95%, 99% e 90%;
- Para cada amostra que se observa obtém-se (em geral) um intervalo de confiança diferente para o mesmo parâmetro;
- Dizer que um intervalo tem grau de confiança  $1 - \alpha$  é o mesmo que dizer que se observarmos muitas amostras distintas, os intervalos que se obtêm contêm o verdadeiro valor do parâmetro  $(1 - \alpha) \times 100\%$  das vezes.



# Intervalo de Confiança (IC)

1. IC para a média (valor esperado)  $\mu$  de uma população Normal com variância ( $\sigma^2$ ) conhecida
2. IC para a média (valor esperado)  $\mu$  de uma população Normal com variância ( $\sigma^2$ ) desconhecida
3. IC para a variância  $\sigma^2$  de uma população Normal
4. IC para a diferença de médias de duas populações Normais  $\mu_1 - \mu_2$ ; duas amostras independentes, variâncias conhecidas ( $\sigma_1^2, \sigma_2^2$ )
5. IC para a diferença de médias de duas populações Normais  $\mu_1 - \mu_2$ ; duas amostras independentes, variâncias desconhecidas mas supostamente iguais ( $\sigma_1^2 = \sigma_2^2$ )
6. IC para a razão de variâncias  $\frac{\sigma_1^2}{\sigma_2^2}$
7. IC para uma proporção  $p$
8. IC para a diferença entre duas proporções  $p_1 - p_2$

# 1. IC para a média $\mu$ de uma população Normal com variância ( $\sigma^2$ ) conhecida

Um intervalo de confiança para a média  $\mu$  de uma população Normal com variância ( $\sigma^2$ ) conhecida, a um grau de confiança  $1 - \alpha$ , é:

$$\left] \bar{X} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}; \bar{X} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}} \right[$$

onde:

- $n$  é o tamanho da amostra
- $\bar{X}$  é a média amostral:  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$
- $z_{1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição Normal Reduzida (ou Padrão);  $Z \sim N(0, 1)$  e  $P(Z < z_{1-\frac{\alpha}{2}}) = 1 - \frac{\alpha}{2}$


# 1. Interpretação do IC para a média $\mu$

$X \sim N(\mu, \sigma^2)$  com  $\mu$  desconhecido mas  $\sigma^2$  conhecida

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

Variável fulcral:

$$Z = \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} \sim N(0, 1) \text{ (Distribuição Normal Reduzida)}$$



# 1. Interpretação do IC para a média $\mu$

$$P(-z < Z < z) = 1 - \alpha \Leftrightarrow P\left(-z < \frac{\bar{X} - \mu}{\frac{\sigma}{\sqrt{n}}} < z\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(-z \frac{\sigma}{\sqrt{n}} < \bar{X} - \mu < z \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(\bar{X} - z \frac{\sigma}{\sqrt{n}} < \mu < \bar{X} + z \frac{\sigma}{\sqrt{n}}\right) = 1 - \alpha$$

↓

$$IC_{1-\alpha}(\mu) = ]\bar{X} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}; \bar{X} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}[$$

- Quanto maior o nível de confiança maior a largura do intervalo;
- Quanto maior a variância maior a largura do intervalo;
- Quanto maior a amostra (maior o  $n$ ) menor a largura do intervalo.

# 1. Interpretação do IC para a média $\mu$

Para uma amostra aleatória de tamanho 50, seguindo uma distribuição Normal de média  $\mu = 10$  e variância  $\sigma^2 = 4 \rightarrow X \sim N(10, 4)$ , determinamos o IC para  $\mu$  com 95% de grau de confiança ( $\alpha = 0.05$ ):

$$P\left(\bar{X} - 1.96 \frac{2}{\sqrt{50}} < \mu < \bar{X} + 1.96 \frac{2}{\sqrt{50}}\right) = 95\%$$

$$P(\bar{X} - 0.5544 < \mu < \bar{X} + 0.5544) = 95\%$$

↓

$$IC_{95\%}(\mu) = ]\bar{X} - 0.5544; \bar{X} + 0.5544[$$

**Interpretação:** 95% dos possíveis ICs obtidos a partir de uma amostra de tamanho 50, conterão de fato o verdadeiro valor da média  $\mu = 10$




Tabela da Distribuição normal reduzida:  $z_{1-\frac{\alpha}{2}} = z_{0.975} = 1.96$

# IC & Grau de Confiança

Como poderia obter intervalos de confiança mais estreitos, ou seja, com limites mais próximos da média verdadeira?

## Diminuindo o grau de confiança

Diminuindo o grau de confiança de 99% para 95%, aumentamos o risco de estar errados: de 1% de risco passamos a 5% de risco, ou seja temos mais possibilidades (5/100 em vez de 1/100) de que o IC não contenha a média populacional. Ao aumentar o risco, o intervalo deve ser mais preciso.

- 90% grau de confiança - existem 10 possibilidades em 100 que o IC não contenha a média populacional
- 95% grau de confiança - existem 5 possibilidades em 100 que o IC não contenha a média populacional
- 99% grau de confiança - existe 1 possibilidade em 100 que o IC não contenha a média populacional

# IC & Dimensão da Amostra

Como poderia obter intervalos de confiança mais estreitos, ou seja, com limites mais próximos da média verdadeira?

**Aumentando a dimensão da amostra**

# 1. IC para a média $\mu$ de uma população genérica com variância ( $\sigma^2$ ) conhecida

Se uma distribuição qualquer tiver média  $\mu$  (desconhecida) e variância  $\sigma^2$  (conhecida) e se forem válidas as condições do Teorema do Limite Central ( $n \gg 30$ ), podemos obter um IC aproximado para a média  $\mu$


IC para  $\mu$ , a um grau de confiança  $1 - \alpha$ , é:  $]\bar{X} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}; \bar{X} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}[$



# Teorema do Limite Central

Seja  $X_1, X_2, \dots, X_n$  uma sucessão de variáveis aleatórias iid (independentes e identicamente distribuídas) com  $E(X_i) = \mu$ ,  $VAR(X_i) = \sigma^2$ ,  $i = 1, \dots, n$ . Então,

$$\frac{\sum_{i=1}^n X_i - n\mu}{\sigma\sqrt{n}} \approx N(0, 1), n \rightarrow \infty$$



# 1. IC para $\mu$ com variância conhecida ( $\sigma^2$ ) - Resumo

$$Z = \frac{\bar{X} - \mu}{\sigma/\sqrt{n}} \begin{cases} \sim N(0,1) \text{ se } X \sim N(\mu, \sigma^2) \\ \approx N(0,1) \text{ se } X \text{ qualquer e } n \geq 30 \end{cases}$$

$$\Rightarrow IC_{1-\alpha}(\mu) = ]\bar{X} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}; \bar{X} + z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}[$$

$$\bar{X} - z_{1-\frac{\alpha}{2}} \frac{\sigma}{\sqrt{n}}$$

- quanto maior  $z_{1-\frac{\alpha}{2}} \Rightarrow$  IC menos preciso;
- quanto maior  $n \Rightarrow$  menor o erro padrão ( $\sigma/\sqrt{n}$ ), e IC mais preciso;
- se aumentarmos o grau de confiança  $\Rightarrow$  a precisão diminui por porque aumenta o valor de  $z_{1-\frac{\alpha}{2}}$ :

$1 - \alpha$	$z_{1-\frac{\alpha}{2}}$
90%	1.65
95%	1.96
99%	2.58

# 1. IC para a média $\mu$ de uma população Normal com variância ( $\sigma^2$ ) desconhecida

Um intervalo de confiança para para a média  $\mu$  de uma população Normal com variância ( $\sigma^2$ ) desconhecida, a um grau de confiança  $1 - \alpha$ , é:

$$\left[ \bar{X} - t_{n-1, 1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}; \bar{X} + t_{n-1, 1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}} \right]$$

onde:

- $n$  é o tamanho da amostra
- $\bar{X}$  é a média amostral  $\bar{X} = \frac{1}{n} \sum_{i=1}^n X_i$
- $S^2$  é a variância amostral corrigida  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
- $t_{n-1, 1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição  $t$  de Student com  $n - 1$  graus de liberdade;  
 $T \sim t_{n-1}$  e  $P(T < t_{n-1, 1-\frac{\alpha}{2}}) = 1 - \frac{\alpha}{2}$

Estes intervalos têm uma largura maior do que se o valor de  $\sigma^2$  fosse conhecido, refletindo a incerteza acrescida pelo desconhecimento deste parâmetro.

## 2. Interpretação do IC para a média $\mu$

$X \sim N(\mu, \sigma^2)$  com  $\mu$  desconhecido e  $\sigma^2$  desconhecida

Variável fulcral:

$$T = \frac{\bar{X} - \mu}{\frac{S}{\sqrt{n}}} \sim t_{n-1} \text{ (Distribuição } t\text{-Student com } n-1 \text{ graus de liberdade)}$$

$$P(-t < T < t) = 1 - \alpha \Leftrightarrow P\left(-t < \frac{\bar{X} - \mu}{\frac{S}{\sqrt{n}}} < t\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(\bar{X} - t \frac{S}{\sqrt{n}} < \mu < \bar{X} + t \frac{S}{\sqrt{n}}\right) = 1 - \alpha$$

$\Downarrow$

$$IC_{1-\alpha}(\mu) = ]\bar{X} - t_{n-1, 1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}; \bar{X} + t_{n-1, 1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}[$$

## 2. Interpretação do IC para a média $\mu$

### Exemplo:

Uma v.a.  $X$  tem uma distribuição Normal com média  $\mu$  e variância  $\sigma^2$  desconhecidas. Retira-se uma amostra de 25 valores e calcula-se a média amostral e variância amostral. Construa um IC de 95% para  $\mu$  supondo que  $\bar{X} = 12.7$  e  $S^2 = 16$


$$IC_{1-\alpha}(\mu) = ]\bar{X} - t_{n-1, 1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}; \bar{X} + t_{n-1, 1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}[$$

$$IC_{95\%}(\mu) = ]\bar{X} - t_{24, 0.975} \frac{S}{\sqrt{n}}; \bar{X} + t_{24, 0.975} \frac{S}{\sqrt{n}}[$$

$$= ]12.7 - 2.06 \frac{4}{\sqrt{25}}; 12.7 + 2.06 \frac{4}{\sqrt{25}}[$$

$$= ]12.7 - 1.648; 12.7 + 1.648[$$

$$IC_{95\%}(\mu) = ]11.052; 13.648[$$



# 1. IC para a média $\mu$ de uma população com variância ( $\sigma^2$ ) desconhecida

Uma abordagem para uma v.a.  $X$  com qualquer distribuição mas aproximada pela Normal, amostras grandes  $\Rightarrow$  usar a distribuição normal reduzida.

Um intervalo de confiança para a média  $\mu$  de uma população qualquer com variância ( $\sigma^2$ ) desconhecida, amostras grandes ( $n \gg 30$ ), a um grau de confiança  $1 - \alpha$ , é:

$$IC_{1-\alpha}(\mu) \approx ]\bar{X} - z_{1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}; \bar{X} + z_{1-\frac{\alpha}{2}} \frac{S}{\sqrt{n}}[$$

onde:

- $X$  qualquer mas  $n \gg 30$
- $Z = \frac{\bar{X} - \mu}{S/\sqrt{n}} \approx N(0, 1)$
- $z_{1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição Normal reduzida  $N(0, 1)$

### 3. IC para a variância $\sigma^2$ de uma população Normal

Um intervalo de confiança para a variância  $\sigma^2$  de uma população Normal, a um grau de confiança  $1 - \alpha$ , é:

$$\left] \frac{(n-1)S^2}{\chi^2_{n-1, 1-\frac{\alpha}{2}}}; \frac{(n-1)S^2}{\chi^2_{n-1, \frac{\alpha}{2}}} \right[$$

onde:

- $n$  é o tamanho da amostra
- $S^2$  é a variância amostral corrigida  $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
- $\chi^2_{n-1, 1-\frac{\alpha}{2}}$  é o quartil de ordem  $1 - \frac{\alpha}{2}$  da distribuição Chi-Quadrado ( $\chi^2$ ) com  $n - 1$  graus de liberdade;

### 3. Interpretação do IC para a variância $\sigma^2$

$X \sim N(\mu, \sigma^2)$  com  $\sigma^2$  desconhecida

Variável fulcral:

$$\chi^2 = \frac{(n-1)S^2}{\sigma^2} \approx \chi_{n-1}^2 \text{ (Distribuição } \chi^2 \text{ com } n-1 \text{ graus de liberdade)}$$

$$P\left(\chi_{n-1, \frac{\alpha}{2}}^2 < \chi^2 < \chi_{n-1, 1-\frac{\alpha}{2}}^2\right) = 1 - \alpha \Leftrightarrow$$

$$P\left(\chi_{n-1, \frac{\alpha}{2}}^2 < \frac{(n-1)S^2}{\sigma^2} < \chi_{n-1, 1-\frac{\alpha}{2}}^2\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(\frac{(n-1)S^2}{\chi_{n-1, 1-\frac{\alpha}{2}}^2} < \sigma^2 < \frac{(n-1)S^2}{\chi_{n-1, \frac{\alpha}{2}}^2}\right) = 1 - \alpha$$

$$\Downarrow$$

$$IC_{1-\alpha}(\sigma^2) = \left] \frac{(n-1)S^2}{\chi_{n-1, 1-\frac{\alpha}{2}}^2}; \frac{(n-1)S^2}{\chi_{n-1, \frac{\alpha}{2}}^2} \right[$$



### 3. IC para o desvio padrão $\sigma$

De um modo geral (para uma amostra de dimensão  $n$  qualquer) o intervalo de confiança para o desvio padrão populacional  $\sigma$ , a um grau de confiança  $1 - \alpha$ , pode ser calculado simplesmente a partir do IC para a variância, é:

$$\left] S \sqrt{\frac{(n-1)}{\chi_{n-1, 1-\frac{\alpha}{2}}^2}}; S \sqrt{\frac{(n-1)}{\chi_{n-1, \frac{\alpha}{2}}^2}} \right[$$

No caso de populações Normais com amostras de grandes dimensões, a distribuição amostral do desvio padrão pode ser considerada Normal.

O intervalo de confiança para o desvio padrão  $\sigma$ , com base numa amostra de dimensão grande ( $n$  muito grande), a um grau de confiança  $1 - \alpha$ , pode ser:

$$\left] S - z_{1-\frac{\alpha}{2}} \frac{S}{\sqrt{2n}}; S + z_{1-\frac{\alpha}{2}} \frac{S}{\sqrt{2n}} \right[$$

#### 4. IC para a diferença de médias de duas populações Normais $\mu_1 - \mu_2$ ; duas amostras independentes, variâncias conhecidas $(\sigma_1^2, \sigma_2^2)$

Um intervalo de confiança para diferença de médias  $\mu_1 - \mu_2$  de duas populações Normais com variâncias conhecidas  $\sigma_1^2, \sigma_2^2$  obtido a partir de duas amostras independentes, a um grau de confiança  $1 - \alpha$ , é:

$$\left[ \bar{X}_1 - \bar{X}_2 - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}; \bar{X}_1 - \bar{X}_2 + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} \right]$$

onde:

- $n_1$  é o tamanho da amostra de  $X_1$  e  $n_2$  é o tamanho da amostra de  $X_2$
- $\bar{X}_1$  e  $\bar{X}_2$  são as médias amostrais de  $X_1$  e  $X_2$ , respetivamente
- $z_{1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição Normal reduzida  $N(0, 1)$ ;

## 2. Interpretação do IC para a diferença de médias

Dadas duas v.a. independentes  $X_1$  e  $X_2$  de populações normais  $N(\mu_1, \sigma_1^2)$  e  $N(\mu_2, \sigma_2^2)$ , respetivamente, podemos considerar a estatística:

$$\bar{X}_1 - \bar{X}_2 \sim N\left(\mu_1 - \mu_2, \frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}\right)$$

$$\iff Z = \frac{\bar{X}_1 - \bar{X}_2 - (\mu_1 - \mu_2)}{\sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}} \sim N(0, 1)$$

$$\Downarrow$$

$$IC_{1-\alpha}(\mu_1 - \mu_2) = ]\bar{X}_1 - \bar{X}_2 - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}}; \bar{X}_1 - \bar{X}_2 + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\sigma_1^2}{n_1} + \frac{\sigma_2^2}{n_2}} [$$

## 5. IC para a diferença de médias de duas populações Normais $\mu_1 - \mu_2$ ; duas amostras independentes, com variâncias desconhecidas $(\sigma_1^2, \sigma_2^2)$ , mas suposto iguais

Um intervalo de confiança para diferença de médias  $\mu_1 - \mu_2$  de duas populações Normais com variâncias desconhecidas  $\sigma_1^2, \sigma_2^2$ , mas iguais, obtido a partir de duas amostras independentes, a um grau de confiança  $1 - \alpha$ , é:

$$] \bar{X}_1 - \bar{X}_2 - t_{n_1+n_2-2, 1-\frac{\alpha}{2}} S^*; \bar{X}_1 - \bar{X}_2 + t_{n_1+n_2-2, 1-\frac{\alpha}{2}} S^* [$$

onde:

- $S^* = \sqrt{\frac{(n_1)S_1^2 + (n_2-1)S_2^2}{n_1+n_2-2}} \sqrt{\frac{1}{n_1} + \frac{1}{n_2}}$
- $S_1^2$  e  $S_2^2$  são as variâncias amostrais de  $X_1$  e  $X_2$ , respetivamente
- $t_{n_1+n_2-2, 1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição  $t$ -Student com  $n_1 + n_2 - 2$  graus de liberdade

5. IC para a diferença de médias de duas populações quaisquer  $\mu_1 - \mu_2$ ; duas amostras independentes, com variâncias desconhecidas  $(\sigma_1^2, \sigma_2^2)$ , e  $n_1$  e  $n_2 \gg 30$  (amostras grandes)

Um intervalo de confiança para diferença de médias  $\mu_1 - \mu_2$  de duas populações quaisquer com variâncias desconhecidas  $\sigma_1^2, \sigma_2^2$ , e amostras muito grandes, obtido a partir de duas amostras independentes, a um grau de confiança  $1 - \alpha$ , pode ser

aproximado por:

$$] \bar{X}_1 - \bar{X}_2 - z_{1-\frac{\alpha}{2}} \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}}; \bar{X}_1 - \bar{X}_2 + z_{1-\frac{\alpha}{2}} \sqrt{\frac{S_1^2}{n_1} + \frac{S_2^2}{n_2}} [$$

onde:

- $S_1^2$  e  $S_2^2$  são as variâncias amostrais de  $X_1$  e  $X_2$ , respetivamente
- $z_{1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição Normal reduzida  $N(0, 1)$

## 5. IC para a diferença de médias de duas populações Normais $\mu_1 - \mu_2$ , com variâncias desconhecidas $(\sigma_1^2, \sigma_2^2)$ , e amostras emparelhadas de igual dimensão

Um intervalo de confiança para diferença de médias  $\mu_1 - \mu_2 = \mu_D$  de duas populações Normais com variâncias desconhecidas  $\sigma_1^2, \sigma_2^2$ , obtido a partir de duas amostras emparelhadas de tamanho  $n$ , a um grau de confiança  $1 - \alpha$ , é:

$$\left[ \bar{D} - t_{n-1, 1-\frac{\alpha}{2}} \frac{S_D}{\sqrt{n}}; \bar{D} + t_{n-1, 1-\frac{\alpha}{2}} \frac{S_D}{\sqrt{n}} \right]$$

onde:

- $D = X_1 - X_2$
- $\bar{D}$  e  $S_D^2$  são respetivamente a média e a variância amostral das diferenças
- $t_{n-1, 1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição  $t$ -Student com  $n - 1$  graus de liberdade

## 5. Interpretação do IC para $\mu_1 - \mu_2$ , com variâncias desconhecidas $(\sigma_1^2, \sigma_2^2)$ , e amostras emparelhadas de igual dimensão

Sejam  $X_1 \sim N(\mu_1, \sigma_1^2)$  e  $X_2 \sim N(\mu_2, \sigma_2^2)$ .

As amostras são dependentes na medida em que têm a mesma dimensão ( $n$ ) e cada observação  $X_{1i}$  depende da observação  $X_{2i}$ , mas os pares  $(X_{1i}, X_{2i})$  e  $(X_{1j}, X_{2j})$  são independentes ( $i \neq j$ ). Este tipo de amostras chamam-se amostras emparelhadas.

Dadas duas amostras aleatórias emparelhadas  $(X_{11}, X_{12}, \dots, X_{1n}), (X_{21}, X_{22}, \dots, X_{2n})$  provenientes de populações Normais, consideram-se as diferenças:

$$D_i = X_{1i} - X_{2i} \sim N(\mu_D, \sigma_D^2)$$

onde  $\mu_D$  é igual às diferenças das médias das populações e  $\sigma_D^2$  representa a variância das diferenças

$D_i$ .

A variável:

$$T = \frac{\bar{D} - \mu_D}{S_D / \sqrt{n}} \sim t_{n-1}$$

onde  $S_D$  representa o desvio padrão amostral das diferenças.

## 6. IC para a razão de variâncias $\frac{\sigma_1^2}{\sigma_2^2}$ de duas populações normais

Um intervalo de confiança para a razão de variâncias  $\frac{\sigma_1^2}{\sigma_2^2}$  de duas populações normais, a um grau de confiança  $1 - \alpha$ , é:

$$\left] \frac{1}{F_{n_1-1; n_2-1, 1-\frac{\alpha}{2}}} \frac{S_1^2}{S_2^2}; \frac{1}{F_{n_1-1; n_2-1, \frac{\alpha}{2}}} \frac{S_1^2}{S_2^2} \right[$$

onde:

- $n_1$  e  $n_2$  são o tamanho das amostras de  $X_1$  e  $X_2$ , respetivamente
- $S_1^2$  e  $S_2^2$  são a variância amostral de  $X_1$  e  $X_2$ , respetivamente
- $F_{n_1-1, n_2-1, 1-\frac{\alpha}{2}}$  e  $F_{n_1-1, n_2-1, \frac{\alpha}{2}}$  são valores da distribuição  $F$  de Snedecor com  $n_1 - 1$  graus de liberdade no numerador e  $n_2 - 1$  graus de liberdade do denominador



# 6. Interpretação do IC para a razão de variâncias $\frac{\sigma_1^2}{\sigma_2^2}$

$X_1 \sim N(\mu_1, \sigma_1^2)$  e  $X_2 \sim N(\mu_2, \sigma_2^2)$  com  $\sigma_1^2$  e  $\sigma_2^2$  desconhecidas

Variável fulcral:

$F = \frac{\frac{S_1^2}{\sigma_1^2}}{\frac{S_2^2}{\sigma_2^2}} = \frac{S_1^2 \sigma_2^2}{S_2^2 \sigma_1^2}$  segue uma distribuição  $F$  de Snedcor com  $n_1 - 1$  e  $n_2 - 1$  graus de liberdade.

$$P\left(F_{n_1-1, n_2-1, \frac{\alpha}{2}} < F < F_{n_1-1, n_2-1, 1-\frac{\alpha}{2}}\right) = 1 - \alpha \Leftrightarrow$$

$$P\left(F_{n_1-1, n_2-1, \frac{\alpha}{2}} < \frac{S_1^2 \sigma_2^2}{S_2^2 \sigma_1^2} < F_{n_1-1, n_2-1, 1-\frac{\alpha}{2}}\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(\frac{S_1^2}{S_2^2} \frac{1}{F_{n_1-1, n_2-1, 1-\frac{\alpha}{2}}} < \frac{\sigma_1^2}{\sigma_2^2} < \frac{S_1^2}{S_2^2} \frac{1}{F_{n_1-1, n_2-1, \frac{\alpha}{2}}}\right) = 1 - \alpha$$

↓

$$IC_{1-\alpha}\left(\frac{\sigma_1^2}{\sigma_2^2}\right) = \left] \frac{1}{F_{n_1-1, n_2-1, 1-\frac{\alpha}{2}}} \frac{S_1^2}{S_2^2}; \frac{1}{F_{n_1-1, n_2-1, \frac{\alpha}{2}}} \frac{S_1^2}{S_2^2} \right[$$

## 6. Interpretação do IC para a razão de variâncias $\frac{\sigma_1^2}{\sigma_2^2}$

Note-se que a distribuição  $F$  goza da seguinte propriedade:

$$F_{n_1-1, n_2-1, \frac{\alpha}{2}} = \frac{1}{F_{n_2-1, n_1-1, 1-\frac{\alpha}{2}}}$$

e portanto o intervalo de confiança para a razão de variâncias também pode ser escrito como:

$$IC_{1-\alpha}\left(\frac{\sigma_1^2}{\sigma_2^2}\right) = \left] \frac{1}{F_{n_1-1; n_2-1, 1-\frac{\alpha}{2}}} \frac{S_1^2}{S_2^2}; F_{n_2-1; n_1-1, 1-\frac{\alpha}{2}} \frac{S_1^2}{S_2^2} \right[$$

## 7. IC para uma proporção $p$

Um intervalo de confiança para uma proporção populacional  $p$  (e.g. proporção de indivíduos com uma certa característica na população), a um

grau de confiança  $1 - \alpha$ , é:

$$\left[ \hat{p} - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}; \hat{p} + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right]$$

onde:

- $n$  é tamanho da amostra
- $\hat{p} = \frac{X}{n}$  é a proporção de indivíduos com uma certa característica numa amostra aleatória de dimensão  $n$
- $z_{1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição Normal reduzida  $N(0, 1)$

## 7. Interpretação do IC para $p$

Seja  $X$  a frequência absoluta do número de ocorrências de sucesso (de uma certa característica) numa amostra aleatória de tamanho  $n$ , então  $X$  é uma variável aleatória Binomial  $X \sim B(np, np(1-p))$ . Um estimador para a proporção de sucessos  $p$  da população é:  $\hat{p} = \frac{X}{n}$

Variável fulcral:

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

$$P\left(-z_{1-\frac{\alpha}{2}} < Z < z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha \Leftrightarrow P\left(-z_{1-\frac{\alpha}{2}} < \frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} < z_{1-\frac{\alpha}{2}}\right) = 1 - \alpha$$

$$\Leftrightarrow P\left(\hat{p} - z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}} < p < \hat{p} + z_{1-\frac{\alpha}{2}} \sqrt{\frac{p(1-p)}{n}}\right) = 1 - \alpha$$

substituindo nos limites do intervalo,  $p$  pelo estimador amostral  $\hat{p}$ , infere-se então:

$$IC_{1-\alpha}(p) = ]\hat{p} - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}; \hat{p} + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}[$$

## 7. Interpretação do IC para $p$ - Exemplo

Em 100 acessos a páginas de internet escolhidas ao acaso, 30 são as páginas nacionais. Determine um IC a 95% para a proporção de acessos a páginas nacionais.

$X$  - número de acessos a páginas internet nacionais  $\Rightarrow X \sim B(100, p)$

$p$  - proporção de acessos a páginas nacionais (em geral)  $\Rightarrow p$  desconhecido

Utilizando esta amostra determinamos um IC aproximado para  $p$  a 95%:

$$IC_{1-\alpha}(p) = ]\hat{p} - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}; \hat{p} + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} [$$

$$\hat{p} = \frac{X}{n} = \frac{30}{100} = 0.3 \qquad \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} = \sqrt{\frac{0.3 \times 0.7}{100}} = 0.04582$$

$$z_{1-\frac{\alpha}{2}} = z_{0.9750} = 1.96$$

$$IC_{95\%}(p) = ]0.3 - 1.96 \times 0.04582; 0.3 + 1.96 \times 0.04582 [= ]0.2102; 0.3898 [$$

## 8. IC para a diferença entre duas proporções $p_1 - p_2$

Um intervalo de confiança para a diferença de proporções  $p_1 - p_2$ , a um grau de confiança  $1 - \alpha$ , é:

$$\left[ (\hat{p}_1 - \hat{p}_2) - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}; (\hat{p}_1 - \hat{p}_2) + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}} \right]$$

onde:

- $n_1$  e  $n_2$  são o tamanho das amostras independentes de  $X_1$  e  $X_2$ , respetivamente
- $\hat{p}_1 = \frac{X_1}{n_1}$  e  $\hat{p}_2 = \frac{X_2}{n_2}$ , valores observados para a proporção de sucessos nas amostras independentes das duas populações
- $z_{1-\frac{\alpha}{2}}$  é o quantil de ordem  $1 - \frac{\alpha}{2}$  da distribuição Normal reduzida  $N(0, 1)$

## 8. Interpretação do IC para $p_1 - p_2$

Seja  $X_1$  a frequência absoluta do número de ocorrências de sucesso numa amostra aleatória de tamanho  $n_1$  de uma população, então  $X_1$  é uma variável aleatória Binomial

$X_1 \sim B(n_1 p_1, n_1 p_1 (1 - p_1))$ . E seja  $X_2$  a frequência absoluta do número de ocorrências de sucesso numa amostra aleatória de tamanho  $n_2$  de uma população, então  $X_2$  é uma variável aleatória Binomial  $X_2 \sim B(n_2 p_2, n_2 p_2 (1 - p_2))$ . Sendo as duas amostras independentes.

Um estimador para a diferença entre proporções de sucessos  $p_1 - p_2$  é:

$$(\hat{p}_1 - \hat{p}_2) \approx N\left(p_1 - p_2, \frac{p_1(1-p_1)}{n_1} + \frac{p_2(1-p_2)}{n_2}\right)$$

Variável fulcral:

$$Z = \frac{(\hat{p}_1 - \hat{p}_2) - (p_1 - p_2)}{\sqrt{\frac{p_1(1-p_1)}{n_1} + \frac{p_2(1-p_2)}{n_2}}} \approx N(0, 1)$$

seguindo o mesmo raciocínio que para o IC de uma proporção, temos:

$$P\left((\hat{p}_1 - \hat{p}_2) - z_{1-\frac{\alpha}{2}} \sqrt{\frac{p_1(1-p_1)}{n_1} + \frac{p_2(1-p_2)}{n_2}} < p_1 - p_2 < (\hat{p}_1 - \hat{p}_2) + z_{1-\frac{\alpha}{2}} \sqrt{\frac{p_1(1-p_1)}{n_1} + \frac{p_2(1-p_2)}{n_2}}\right)$$

$$IC_{1-\alpha}(p_1 - p_2) = ](\hat{p}_1 - \hat{p}_2) - z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}; (\hat{p}_1 - \hat{p}_2) + z_{1-\frac{\alpha}{2}} \sqrt{\frac{\hat{p}_1(1-\hat{p}_1)}{n_1} + \frac{\hat{p}_2(1-\hat{p}_2)}{n_2}}[$$