

Métodos Estatísticos de Apoio à Decisão

Aula 8

Mônica Barros, D.Sc.

Agosto de 2007

monica@ele.puc-rio.br

1

Aula 8

- Intervalos de Confiança – Motivação
- Intervalos de Confiança para Médias
- Intervalos de Confiança para Diferenças entre Médias (Variâncias supostas iguais)
- Intervalo de Confiança para a variância de uma Normal
- Intervalos de Confiança para a razão de variâncias
- Intervalo de Confiança aproximado para a proporção uma Binomial

monica@ele.puc-rio.br

2

Intervalos de Confiança

- Até agora estivemos interessados em encontrar uma estimativa pontual para um parâmetro desconhecido θ .
- Também enumeramos algumas propriedades desejáveis de estimadores pontuais.
- **Agora tentaremos obter não apenas uma estimativa pontual, mas um intervalo** que contenha o parâmetro de interesse com uma **probabilidade especificada**. Este intervalo será chamado de “Intervalo de Confiança”.

monica@ele.puc-rio.br

3

Intervalos de Confiança

O intervalo de confiança $100(1-\alpha)\%$ para θ é dado por:

$$L(\tilde{X}) \leq \theta \leq U(\tilde{X})$$

Onde $L(\tilde{X})$ (limite inferior) e $U(\tilde{X})$ (limite superior) são tais que:

$$Prob[L(\tilde{X}) \leq \theta \leq U(\tilde{X})] = 1 - \alpha$$

Onde α é um número especificado pelo usuário.

monica@ele.puc-rio.br

4

Intervalos de Confiança



- Note que o intervalo $[L(\bar{X}), U(\bar{X})]$ é **aleatório**, e a cada amostra obtida iremos encontrar valores diferentes para os limites L e U.

- A notação \bar{X} indica todos os elementos da amostra aleatória, isto é:

$$\bar{X} = (X_1, X_2, \dots, X_n)$$

Intervalos de Confiança – Média da Normal



- Consideraremos agora o caso mais comum na prática onde os dados são supostos **NORMAIS** e θ é **média** da distribuição.
- Serão estudados **dois casos**: **variância do modelo conhecida** e **variância do modelo desconhecida**.

Intervalos de Confiança – Média da Normal



- **Argumento intuitivo....**
- Suponha que você tem uma amostra aleatória da Normal, em que a média é desconhecida.
- Se você precisasse achar um estimador pontual de θ (a média), usaria a média amostral \bar{X} .

Intervalos de Confiança – Média da Normal



- E se agora você precisar encontrar um intervalo que contenha θ com uma probabilidade especificada?
- Parece natural que este intervalo tenha a forma: $(\bar{X} - c, \bar{X} + c)$ onde c é uma constante a ser especificada.
- Veremos que os intervalos encontrados para a média da Normal têm exatamente esta forma!

Intervalo de Confiança – Média da Normal



Caso I

$X \sim \text{NORMAL}(\theta, \sigma^2)$; σ^2 conhecido

□ Seja $X = (X_1, \dots, X_n)$ uma a.a. de tamanho n da distribuição Normal acima.

□ Já vimos que $\bar{X} = \sum_{i=1}^n \frac{X_i}{n}$ é o estimador de máxima verossimilhança de θ . Além disto, é fácil provar que:

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

monica@ele.puc-rio.br

9

Intervalo de Confiança – Média da Normal



□ Logo, podemos padronizar a média amostral, transformando-a numa v.a. com densidade $N(0,1)$ da seguinte maneira:

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

□ Usando uma **tabela da Normal** podemos encontrar, por exemplo, a probabilidade desta nova variável estar **entre -2 e +2**.

monica@ele.puc-rio.br

10

Intervalo de Confiança – Média da Normal



Prob $(-2 < Z < 2) = \Phi(2) - \Phi(-2) = 0.954$

□ Substituindo Z na expressão anterior leva a:

$$-2 < \frac{\bar{X} - \theta}{\sigma / \sqrt{n}} < +2 \Leftrightarrow \bar{X} - \frac{2\sigma}{\sqrt{n}} < \theta < \bar{X} + \frac{2\sigma}{\sqrt{n}}$$

□ Daí:

$$\text{Prob}\{-2 < Z < +2\} = \text{Prob}\left\{\bar{X} - \frac{2\sigma}{\sqrt{n}} < \theta < \bar{X} + \frac{2\sigma}{\sqrt{n}}\right\} = 0.954$$

□ O intervalo que acabamos de encontrar é um **intervalo de confiança 95.4% para θ** .

monica@ele.puc-rio.br

11

Intervalo de Confiança – Média da Normal



□ Ou seja, na notação mostrada antes:

$$L(\bar{X}) = \bar{X} - \frac{2\sigma}{\sqrt{n}}$$

$$U(\bar{X}) = \bar{X} + \frac{2\sigma}{\sqrt{n}}$$

$$1 - \alpha = 0.954$$

□ A seguir exibimos uma “receita de bolo” para obter o IC da média de uma Normal com variância conhecida.

monica@ele.puc-rio.br

12

Intervalo de Confiança – Média da Normal



- ❑ **Receita de Bolo**
- ❑ Seja $\tilde{X}=(X_1, \dots, X_n)$ uma a.a. de tamanho n da distribuição Normal com **média desconhecida θ e variância conhecida σ^2** .
- ❑ Um intervalo de confiança $100(1-\alpha)\%$ para θ é dado por:
$$\left[\bar{X} - z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}}; \bar{X} + z_{1-\alpha/2} \frac{\sigma}{\sqrt{n}} \right]$$
- ❑ Onde $z_{1-\alpha/2}$ é obtido da função de distribuição **$N(0,1)$** e é tal que $\Pr(Z < z_{1-\alpha/2}) = 1-\alpha/2$.

monica@ele.puc-rio.br

13

Intervalo de Confiança – Média da Normal



- ❑ Note que, pela simetria em torno de zero da distribuição $N(0,1)$:
- ❑ **$z_{1-\alpha/2}$ é o ponto tal que, a probabilidade de estar ACIMA dele é $\alpha/2$ usando uma distribuição $N(0,1)$.**
- ❑ Também é fácil perceber que, se Z é $N(0,1)$:

$$\Pr\left\{-z_{1-\frac{\alpha}{2}} < Z < +z_{1-\frac{\alpha}{2}}\right\} = 1-\alpha$$

- ❑ E esta última expressão foi empregada para obter o IC para a média.

monica@ele.puc-rio.br

14

IC para a média da Normal com σ conhecido



- ❑ **Exemplo**
- ❑ Considere a população de alunos da PUC. Para uma amostra de 50 alunos obtivemos uma altura média de 1,68m.
- ❑ Sabe-se que o desvio-padrão da altura da população de alunos da PUC é o mesmo que o da população de jovens cariocas com menos de 25 anos: 0,11m.
- ❑ Suponha que as alturas dos alunos são Normalmente distribuídas.
- ❑ Determine, com um **nível de confiança de 95%**, o intervalo onde a real altura média da população de alunos da PUC deve estar localizada.

monica@ele.puc-rio.br

15

IC para a média da Normal com σ conhecido



- ❑ **Solução**
- ❑ Note que a amostra é Normal com variância conhecida, e assim a distribuição de \bar{X} também é Normal.
- ❑ Da tabela da Normal, ou usando a função **INV.NORMP** do Excel, procuramos um valor z_0 tal que $\Pr(Z < z_0) = 1-\alpha/2 = 97.5\%$, isto é, $\Phi(z_0) = 97.5\%$. A função INV.NORMP fornece $z_0 = 1.96$.

monica@ele.puc-rio.br

16

IC para a média da Normal com σ conhecido



❑ Solução

❑ O IC 95% (para as alturas em cm) é então:

$$\left(\bar{X} - z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \right) = \left(168 - 1.96 \cdot \frac{11}{\sqrt{50}}, 168 + 1.96 \cdot \frac{11}{\sqrt{50}} \right)$$

$$= (164.95 \text{ cm}, 171.05 \text{ cm})$$

IC para a média da Normal com σ conhecido

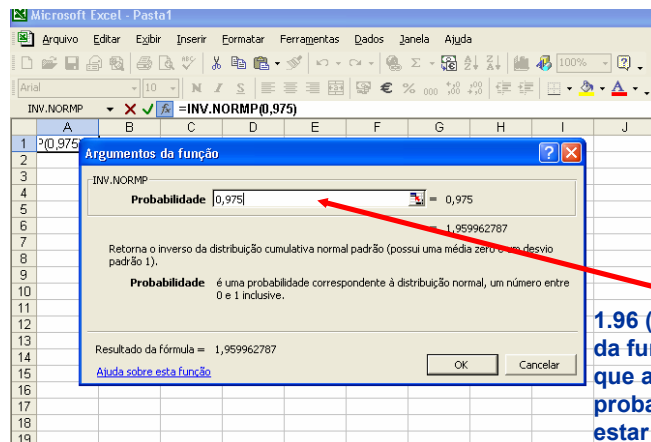


❑ **Receita de bolo – qual valor de $z_{\alpha/2}$ usar?**

| Coeficiente de Confiança | valor tabelado de z |
|--------------------------|---------------------|
| 80.0% | 1.282 |
| 90.0% | 1.645 |
| 95.0% | 1.960 |
| 97.0% | 2.170 |
| 97.5% | 2.241 |
| 99.0% | 2.576 |

Estes pontos são encontrados através da função INV.NORMP do Excel – Note que, **se o coeficiente de confiança é $1 - \alpha$** , devemos buscar um ponto na tabela da Normal tal que a probabilidade de estar **ACIMA** dele é $\alpha/2$, ou seja, a probabilidade de estar **ABAIXO** dele é $1 - \alpha/2$ (o argumento da função INV.NORMP é $1 - \alpha/2$).

IC para a média da Normal com σ conhecido



1.96 (a “resposta da função” é tal que a probabilidade de estar abaixo deste valor é 0,975)

IC para a média da Normal com σ conhecido



❑ Exemplo

- ❑ Numa amostra de 36 postos de gasolina no Rio de Janeiro, o preço médio do litro da gasolina aditivada foi de R\$ 1.78. Sabe-se, por experiências anteriores, que o desvio padrão é R\$ 0.20.
- ❑ Encontre intervalos de confiança 90%, 95% e 99% para o preço médio da gasolina aditivada no Rio de Janeiro supondo que a amostra é Normal.

❑ Solução

- ❑ Aqui estamos **supondo que o desvio padrão é conhecido**, e assim podemos usar um intervalo baseado na densidade Normal.

IC para a média da Normal com σ conhecido



- Os IC têm a forma geral: $\left(\bar{X} - z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}}, \bar{X} + z_{1-\frac{\alpha}{2}} \cdot \frac{\sigma}{\sqrt{n}} \right)$
- O IC 90% é: $\left(1.78 - 1.645 \frac{(0.20)}{6}, 1.78 + 1.645 \frac{(0.20)}{6} \right) = (\text{R\$ } 1.725, \text{R\$ } 1.835)$
- O IC 95% é: $\left(1.78 - 1.96 \frac{(0.20)}{6}, 1.78 + 1.96 \frac{(0.20)}{6} \right) = (\text{R\$ } 1.715, \text{R\$ } 1.845)$
- O IC 99% é: $\left(1.78 - 2.576 \frac{(0.20)}{6}, 1.78 + 2.576 \frac{(0.20)}{6} \right) = (\text{R\$ } 1.694, \text{R\$ } 1.866)$

Note que, à medida que o coeficiente de confiança aumenta, a largura do intervalo também aumenta!

IC para a média da Normal com σ conhecido



- Exemplo (para casa)
- O preço médio de um automóvel Palio ELX 1.0 4 portas ano 2001 é R\$ 17727 (segundo o Jornal Valor Econômico de 07/07/2003).
- Suponha que o desvio padrão REAL dos preços seja R\$ 1500 e o tamanho da amostra é $n = 25$ carros.
- Encontre intervalos de confiança 95% e 99% para os preços de Palios ELX 1.0 quatro portas ano 2001 supondo que os preços são Normalmente distribuídos.

IC para a média da Normal com σ conhecido



- Exemplo (para casa)
- Toma-se uma amostra de 25 usuário de um cartão de crédito e observa-se que o gasto médio mensal é R\$ 600.
- O desvio padrão é conhecido e igual a R\$ 250.
- Encontre intervalos de confiança 95 e 99% para o gasto médio com cartão na população de usuários.

PIVOT



- Seja $\tilde{X} = (X_1, \dots, X_n)$ uma a.a. de tamanho n de uma densidade (ou função de probabilidade) $f(x, \theta)$.
- Seja $Q = q(X_1, \dots, X_n, \theta)$ uma função dos elementos da amostra e do parâmetro desconhecido θ .
- Q é chamado de PIVOT se sua distribuição não depende de θ .**
- Um PIVOT é usado para encontrar intervalos de confiança para parâmetros desconhecidos.

PIVOT



- No exemplo do IC da média da Normal com variância conhecida, a quantidade:

$$Z = \frac{\sqrt{n}(\bar{X} - \theta)}{\sigma}$$

- é um PIVOT, pois depende de $\tilde{X} = (X_1, \dots, X_n)$ e θ , sua distribuição não depende de θ (pois é $N(0,1)$) e assim pode ser usada na construção de um IC para θ .

IC para a média da Normal com σ desconhecido



Caso II

$X \sim \text{NORMAL}(\theta, \sigma^2)$; σ^2 DESCONHECIDO

- Seja $\tilde{X} = (X_1, \dots, X_n)$ uma a.a. de tamanho n da distribuição Normal acima.

- Os estimadores **não tendenciosos** de θ e σ^2 são:

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

onde $\bar{X} \sim N\left(\theta, \frac{\sigma^2}{n}\right)$ e $\frac{(n-1)S^2}{\sigma^2} \sim \chi_{n-1}^2$

IC para a média da Normal com σ desconhecido



- Também, \bar{X} e S^2 são independentes.
- Pela definição de uma v.a. t de Student:

$$T = \frac{\frac{\sqrt{n}(\bar{X} - \theta)}{\sigma}}{\sqrt{\frac{(n-1)S^2}{\sigma^2(n-1)}}} = \sqrt{n} \cdot \frac{\bar{X} - \theta}{S} \sim t_{n-1}$$

- Onde: $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$
- Assim da tabela da distribuição t de Student com $n-1$ graus de liberdade podemos obter dois números \underline{a} e \underline{b} tais que: $\Pr(a < T < b) = 1 - \alpha$

IC para a média da Normal com σ desconhecido



- Para encontrar um intervalo simétrico fazemos $a = -b$ e assim:

$$\text{Prob}[a < T < b] = \text{Prob}\{-b < T < +b\} = \text{Prob}\left\{-b < \sqrt{n} \left(\frac{\bar{X} - \theta}{S} \right) < b\right\} = 1 - \alpha$$

$$\begin{aligned} \Leftrightarrow \text{Prob}\left(-b \frac{S}{\sqrt{n}} < \bar{X} - \theta < +b \frac{S}{\sqrt{n}}\right) &= \\ = \text{Prob}\left(-\bar{X} - b \frac{S}{\sqrt{n}} < -\theta < -\bar{X} + b \frac{S}{\sqrt{n}}\right) &= \\ = \text{Prob}\left(\bar{X} - b \frac{S}{\sqrt{n}} < \theta < \bar{X} + b \frac{S}{\sqrt{n}}\right) &= 1 - \alpha \end{aligned}$$

IC para a média da Normal com σ desconhecido



- Portanto:
- O intervalo $\left(\bar{X} - b \frac{S}{\sqrt{n}}, \bar{X} + b \frac{S}{\sqrt{n}} \right)$
- é um intervalo aleatório com probabilidade $1 - \alpha$ de incluir o parâmetro desconhecido θ .
- O ponto b que aparece na definição do IC é obtido da distribuição t com n-1 graus de liberdade, e é tal que $\Pr(T > b) = \alpha/2$.

monica@ele.puc-rio.br

29

IC para a média da Normal com σ desconhecido



- **Receita de Bolo**
- Seja X_1, X_2, \dots, X_n uma a.a. de tamanho n da distribuição Normal com **média desconhecida** θ e **variância desconhecida** σ^2 .
- Um intervalo de confiança $100(1 - \alpha)\%$ para θ é dado por: $\left(\bar{X} - b \frac{S}{\sqrt{n}}, \bar{X} + b \frac{S}{\sqrt{n}} \right)$
- Onde b é obtido da função de distribuição t de Student com n-1 graus de liberdade e é tal que $\Pr(T > b) = \alpha/2$.


monica@ele.puc-rio.br

30

IC para a média da Normal com σ desconhecido



- O IC $100(1 - \alpha)\%$ para θ é:
$$\left(\bar{X} - t_{n-1; 1-\alpha/2} \frac{S}{\sqrt{n}}, \bar{X} + t_{n-1; 1-\alpha/2} \frac{S}{\sqrt{n}} \right)$$
- Onde S é o desvio padrão amostral e $t_{n-1; 1-\alpha/2}$ é um ponto da distribuição t de Student com n-1 graus de liberdade tal que $\Pr(T > t_{n-1; 1-\alpha/2}) = \alpha/2$, como no gráfico a seguir:



31

IC para a média da Normal com σ desconhecido



- O valor $t_{n-1; 1-\alpha/2}$ é obtido de uma tabela da distribuição t com n-1 graus de liberdade. Pode-se, alternativamente, usar a função INVT do Excel.

monica@ele.puc-rio.br

32

IC para a média da Normal com σ desconhecido



- ❑ Exemplo
- ❑ Numa amostra de 16 postos de gasolina no Rio de Janeiro, o preço médio do litro da gasolina aditivada foi de R\$ 1.78.
- ❑ O desvio padrão dos preços **estimado** na amostra é R\$ 0.20. Encontre intervalos de confiança 90%, 95% e 99% para o preço médio da gasolina aditivada no Rio de Janeiro e compare-os com os encontrados no exemplo da página 18.

IC para a média da Normal com σ desconhecido



- ❑ Solução
- ❑ Aqui deve-se usar a distribuição t para encontrar o IC, pois o desvio padrão é desconhecido. A forma do intervalo é:

$$IC = \bar{X} \pm t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S}{\sqrt{n}} = \left(\bar{X} - t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S}{\sqrt{n}}, \bar{X} + t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S}{\sqrt{n}} \right)$$

- ❑ Pela função INVT do Excel com 15 graus de liberdade obtemos os pontos percentuais para os IC 90, 95 e 99%, que são, respectivamente: 1.753, 2.131 e 2.947.

IC para a média da Normal com σ desconhecido



- ❑ O IC 90% é: $\left(1.78 - 1.753 \frac{(0.20)}{\sqrt{16}}, 1.78 + 1.753 \frac{(0.20)}{\sqrt{16}} \right) = (\text{R\$ } 1.692, \text{ R\$ } 1.868)$
- ❑ O IC 95% é: $\left(1.78 - 2.131 \frac{(0.20)}{\sqrt{16}}, 1.78 + 2.131 \frac{(0.20)}{\sqrt{16}} \right) = (\text{R\$ } 1.673, \text{ R\$ } 1.887)$
- ❑ O IC 99% é: $\left(1.78 - 2.947 \frac{(0.20)}{\sqrt{16}}, 1.78 + 2.947 \frac{(0.20)}{\sqrt{16}} \right) = (\text{R\$ } 1.633, \text{ R\$ } 1.927)$

Note que os intervalos de confiança são mais largos que os correspondentes para a Normal

Nota IMPORTANTE – uso de INVT no Excel



- ❑ Suponha que você quer encontrar um intervalo de confiança $100*(1 - \alpha)\%$.
 - ❑ Então para obter o ponto $t_{1-\alpha/2}$ que entra no cálculo do IC, use a função INVT com os argumentos:
 - ❑ α e
 - ❑ $n - 1$ graus de liberdade
 - ❑ Pois a função INVT do Excel fornece a o ponto tal que a probabilidade de estar ACIMA dele é especificada.
- ❑ Isso se deve ao fato do primeiro argumento da função no Excel ser, na verdade, o valor para o intervalo bilateral.

Utilizando o Excel

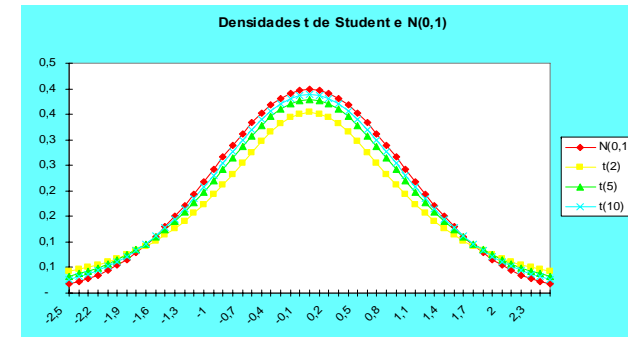
Funções do Excel para a distribuição t

| Função | Descrição |
|------------|--|
| inv(t; gl) | Para a distribuição t de Student, calcula o valor t para $p = 2\alpha$, com gl graus de liberdade |

Por exemplo, $INVT(0.05, 20) = 2.086$ calcula o valor na tabela t com 20 graus de liberdade e é tal que $\Pr(T > 2.086) = 0.05/2 = 0.025$


Distribuição t de Student

Quando n (número de graus de liberdade) cresce, a densidade t de Student se torna cada vez mais parecida com uma $N(0,1)$



A distribuição t de Student

Exemplo: para uma amostra com 15 elementos (14 graus de liberdade) e para um nível de confiança de 5% ($\alpha/2 = 0,025$), t é igual a 2,1448



| G.L | 0.100 | 0.075 | 0.050 | 0.025 | 0.020 |
|-----|--------|--------|--------|---------|---------|
| 1 | 3.0777 | 4.1653 | 6.3137 | 12.7062 | 15.8945 |
| 2 | 1.8856 | 2.2819 | 2.9200 | 4.3027 | 4.8487 |
| 3 | 1.6377 | 1.9243 | 2.3534 | 3.1824 | 3.4819 |
| 4 | 1.5332 | 1.7782 | 2.1318 | 2.7765 | 2.9985 |
| 5 | 1.4759 | 1.6994 | 2.0150 | 2.5706 | 2.7565 |
| 6 | 1.4398 | 1.6502 | 1.9432 | 2.4469 | 2.6122 |
| 7 | 1.4149 | 1.6166 | 1.8946 | 2.3646 | 2.5168 |
| 8 | 1.3968 | 1.5922 | 1.8595 | 2.3060 | 2.4490 |
| 9 | 1.3830 | 1.5737 | 1.8331 | 2.2622 | 2.3984 |
| 10 | 1.3722 | 1.5592 | 1.8125 | 2.2281 | 2.3593 |
| 11 | 1.3634 | 1.5476 | 1.7959 | 2.2010 | 2.3281 |
| 12 | 1.3562 | 1.5380 | 1.7823 | 2.1788 | 2.3027 |
| 13 | 1.3502 | 1.5299 | 1.7709 | 2.1604 | 2.2816 |
| 14 | 1.3450 | 1.5231 | 1.7613 | 2.1448 | 2.2638 |
| 15 | 1.3406 | 1.5172 | 1.7531 | 2.1315 | 2.2485 |
| 16 | 1.3368 | 1.5121 | 1.7459 | 2.1199 | 2.2354 |

Comparação: IC Normais x IC t de Student

A distribuição t nos fornece intervalos de comprimento maior que os intervalos Normais com a mesma probabilidade.

À medida que o número de graus de liberdade da densidade t cresce, a densidade se torna mais e mais parecida com uma $N(0,1)$, e conseqüentemente, os intervalos se tornam mais próximos dos encontrados através da distribuição $N(0,1)$.

Comparação: IC Normais x IC t de Student



- ❑ Também, o comprimento dos intervalos diminui à medida que aumentamos o número de observações.
- ❑ Isto é intuitivamente razoável, pois à medida que o tamanho da amostra cresce, \bar{X} “converge” para μ e temos cada vez mais “certeza” de que a média amostral está num intervalo de pequeno comprimento em torno de μ com alta probabilidade (este resultado é conhecido como “lei dos grandes números”).

monica@ele.puc-rio.br

41

Utilizando o Excel



- ❑ O Excel também pode ser utilizado para o cálculo do intervalo de confiança para σ desconhecido (para qualquer tamanho de amostra)
 - ❑ Selecione no menu **Ferramentas** a opção **Análise de Dados**;
 - ❑ Escolha a opção **Estatística Descritiva**;
 - ❑ Na caixa **Intervalo de Entrada**, selecione os dados da amostra;
 - ❑ Selecione a opção **Intervalo de Confiança para a Média** e coloque o intervalo de confiança desejado;
 - ❑ Na caixa **Intervalo de Saída**, selecione o local da planilha onde os resultados serão colocados;
 - ❑ Clique em **Ok**.

monica@ele.puc-rio.br

42

Utilizando o Excel



- ❑ A saída **Erro padrão** fornece o valor de σ/\sqrt{n} para n grande.
- ❑ Para obter o intervalo de confiança baseado na Normal, calcule $z_{1-\alpha/2}$ utilizando a função apropriada, multiplique pelo Erro padrão, e faça: média amostral + e - o resultado encontrado.
- ❑ A saída **Intervalo de Confiança** já fornece o valor de $(t_{1-\alpha/2, n-1})\sigma/\sqrt{n}$ (ou seja, já fornece o que deve ser somado e subtraído da média amostral), bastando apenas subtrair e somar à média.

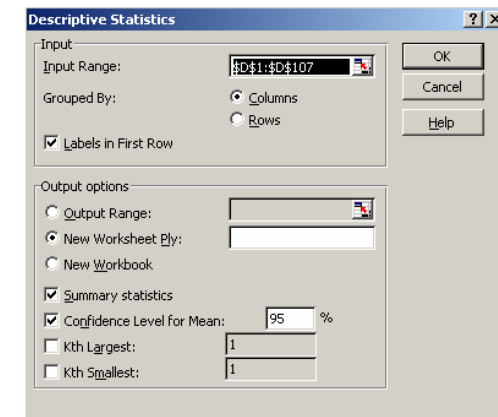
monica@ele.puc-rio.br

43

Utilizando o Excel



- ❑ A seguir aplicamos esta análise para o preço da gasolina em 106 postos do Rio de Janeiro em Agosto de 2002.



monica@ele.puc-rio.br

44

Utilizando o Excel



| Gas. Comum | |
|-----------------------|---------|
| Média | 1.725 |
| Erro Padrão | 0.007 |
| Mediana | 1.725 |
| Moda | 1.749 |
| Desvio Padrão | 0.075 |
| Variância Amostral | 0.006 |
| Curtose | 1.082 |
| Assimetria | 0.386 |
| Amplitude (Máx - Mín) | 0.410 |
| Mínimo | 1.520 |
| Máximo | 1.930 |
| Soma | 182.847 |
| n | 106 |
| IC 95% | 0.014 |

O erro padrão é apenas o desvio padrão dividido por $\sqrt{n} = \sqrt{106}$

$(t_{0.025})\sigma/\sqrt{n}$ – basta subtrair e somar este valor à média para encontrar o IC 95%

Utilizando o Excel



- **Nota:**
- Como o tamanho da amostra é grande, poderíamos ter usado um IC baseado na distribuição Normal.
- Na verdade, a diferença praticamente inexistente, pois o número de graus de liberdade da distribuição t neste caso (105) a torna, para todos os efeitos, indistingüível da Normal.

Forma Alternativa para um IC baseado na distribuição t



- Se definirmos a variância amostral como:

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

e então $\frac{(n)S^{*2}}{\sigma^2} \sim \chi_{n-1}^2$

- Daí a variável T torna-se:

$$T = \frac{\frac{\sqrt{n}(\bar{X} - \theta)}{\sigma}}{\frac{\sqrt{(n)S^{*2}}}{\sqrt{\sigma^2(n-1)}}} = \sqrt{n-1} \cdot \frac{\bar{X} - \theta}{S^*} \sim t_{n-1}$$

Forma Alternativa para um IC baseado na distribuição t



- E aí o intervalo de confiança torna-se:

$$IC = \bar{X} \pm t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S^*}{\sqrt{n-1}} = \left(\bar{X} - t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S^*}{\sqrt{n-1}}, \bar{X} + t_{n-1, 1-\frac{\alpha}{2}} \cdot \frac{S^*}{\sqrt{n-1}} \right)$$

- **Qual intervalo é “melhor”?** Nenhum – são equivalentes, o importante é saber se você está calculando a variância amostral com denominador n ou (n-1), para ser coerente na sua escolha.

IC para a média de uma distribuição qualquer – GRANDES AMOSTRAS

- Intervalo de confiança aproximado para as médias de distribuição não-normais (**baseado no Teorema Central do Limite**).
- Considere a v.a. X com densidade ou função de probabilidade $f(x)$, não necessariamente Normal.
- Tome uma a.a. de tamanho n desta densidade.

IC para a média de uma distribuição qualquer – GRANDES AMOSTRAS

- Se n (o tamanho da amostra) é grande o Teorema Central do Limite estabelece que:

$$S^2 \xrightarrow{P} \sigma^2 \quad \sqrt{n} \frac{(\bar{X} - \theta)}{\sigma} \xrightarrow{d} N(0,1)$$

$$\frac{\sqrt{n}(\bar{X} - \theta) / \sigma}{\sqrt{(n-1)S^2 / (n-1)\sigma^2}} = \sqrt{n} \frac{(\bar{X} - \theta)}{S} \xrightarrow{d} N(0,1)$$

IC para a média de uma distribuição qualquer – GRANDES AMOSTRAS

- Daí, um intervalo de confiança aproximado para θ quando a variância é desconhecida e X_i é não- Normal é:

$$\left(\bar{X} - z_{1-\alpha/2} \cdot \frac{S}{\sqrt{n}}; \bar{X} + z_{1-\alpha/2} \cdot \frac{S}{\sqrt{n}} \right)$$

onde $z_{1-\alpha/2}$ é obtido de uma $N(0,1)$ tal que:

Prob $[-z_{1-\alpha/2} < Z < z_{1-\alpha/2}] = 1 - \alpha$ sendo $Z \sim N(0,1)$

IC para diferenças entre médias

- **Objetivo**
- Comparação das médias de duas amostras aleatórias Normais.
- Exemplos: Agricultura, Medicina, Energia, Veterinária, Marketing, Produção, Finanças, etc...

IC para diferenças entre médias



- ❑ Aplicações - Medicina
- ❑ Deseja-se medir o efeito da dieta sobre a pressão sanguínea e a taxa de colesterol de uma pessoa. Toma-se duas amostras “parecidas” de pessoas (mesmas idades, pesos, nível de atividade, etc...).
- ❑ Uma das amostras é submetida a uma dieta com alto teor de gordura e carnes vermelhas.
- ❑ O outro grupo ingere uma dieta consistindo principalmente em vegetais, carnes brancas e grãos.

IC para diferenças entre médias



- ❑ Os pacientes são acompanhados por um período de 3 meses, no qual são feitas medições quinzenais da pressão sanguínea e da taxa de colesterol.
- ❑ Como a dieta afeta estas 2 quantidades? A pressão sanguínea no grupo que ingere mais gordura é significativamente maior que no outro grupo?
- ❑ E a taxa de colesterol?

IC para diferenças entre médias



- ❑ Aplicações - Veterinária
- ❑ A empresa produtora da ração “Baby Dog” decide lançar no mercado uma nova marca de ração, “Super Baby Dog”, que supostamente tem maior teor nutritivo.
- ❑ Toma-se uma amostra de 200 cachorrinhos com 2 meses de idade, 100 deles alimentados com “Baby Dog” e 100 alimentados com “Super Baby Dog”.

IC para diferenças entre médias



- ❑ Ao completarem 6 meses de idade, os cães são novamente examinados e registra-se o aumento de peso no período de 2 a 6 meses de idade.
- ❑ Pergunta-se: a ração “Super Baby Dog” fez os cachorrinhos crescerem mais que a “Baby Dog”? Qual a diferença no aumento de peso médio dos cães submetidos às duas rações?

IC para diferenças entre médias



- Aplicações – Marketing
- A empresa ABC concentra seus anúncios de TV no horário nobre, gastando uma imensa fortuna em publicidade. Como forma de conter as despesas, a companhia decide direcionar seus anúncios para um horário mais tardio, e para programas vistos por um público principalmente das classes A e B. A questão de interesse para a empresa é: esta mudança foi eficaz? Ou seja, será que a empresa economizou dinheiro e ainda manteve o mesmo nível de vendas após a mudança do horário de seus anúncios?

IC para diferenças entre médias



- **Formulação Matemática**
- Considere duas populações Normais com médias (μ_1 e μ_2) possivelmente distintas e com a **mesma variância (esta hipótese é essencial para resolver o problema!)**. Isto é:

$$X_i \sim N(\mu_1, \sigma^2) \text{ e } Y_j \sim N(\mu_2, \sigma^2)$$

$$\text{Onde } i = 1, 2, \dots, m \text{ e } j = 1, 2, \dots, n$$

IC para diferenças entre médias



- Considere as duas amostras aleatórias de X e Y com tamanhos m e n respectivamente, isto é:

$$\tilde{X} = (X_1, \dots, X_m); \quad \tilde{Y} = (Y_1, \dots, Y_n)$$

- Suponha que todos os parâmetros (μ_1 , μ_2 e σ^2) são **desconhecidos**. Então o nosso objetivo é:

Achar um intervalo de confiança 100(1- α)% para ($\mu_1 - \mu_2$).

IC para diferenças entre médias



- Intuitivamente, este intervalo deverá ser baseado nas respectivas médias amostrais e terá a forma:

$$(\bar{X} - \bar{Y} - c, \bar{X} - \bar{Y} + c)$$

- A questão que devemos responder é: como achar esta constante c?

IC para diferenças entre médias



Solução:

Sabemos que:

$$\bar{X} \sim N(\mu_1; \sigma^2 / m); \quad \bar{Y} \sim N(\mu_2; \sigma^2 / n)$$

e estas médias amostrais são independentes. Então qualquer combinação linear de \bar{X} e \bar{Y} é Normal e, em particular:

$$\bar{X} - \bar{Y} \sim N\left(\mu_1 - \mu_2, \sigma^2 \left(\frac{1}{n} + \frac{1}{m}\right)\right)$$

IC para diferenças entre médias



Além disso, temos que:

$$\frac{(m-1)S_1^2}{\sigma^2} \sim \chi_{m-1}^2 \quad \frac{(n-1)S_2^2}{\sigma^2} \sim \chi_{n-1}^2$$

Onde S_1^2 é a variância amostral da 1a. amostra (X's) e S_2^2 a variância amostral dos Y's, ambas independentes.

Daí:

$$\frac{1}{\sigma^2} ((m-1)S_1^2 + (n-1)S_2^2) \sim \chi_{n+m-2}^2$$

IC para diferenças entre médias



Revisão:

□ Seja $Z \sim N(0,1)$ e $V \sim \chi_p^2$, ambas independentes.

□ Então:

$$T = Z / \sqrt{V/p} \sim t_p,$$

Tem uma distribuição t de Student com p graus de liberdade

IC para diferenças entre médias



Combinando os resultados temos:

$$Z = \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\sigma^2 \left(\frac{1}{m} + \frac{1}{n}\right)}} \sim N(0,1)$$

$$V = \frac{1}{\sigma^2} ((m-1)S_1^2 + (n-1)S_2^2) \sim \chi_{n+m-2}^2$$

IC para diferenças entre médias



Além disso, Z e V são independentes, então a variável T dada por:

$$T = \frac{Z}{\sqrt{\frac{V}{n+m-2}}} = \frac{\bar{X} - \bar{Y} - (\mu_1 - \mu_2)}{\sqrt{\left(\frac{1}{n} + \frac{1}{m}\right) \left(\frac{(m-1)S_1^2 + (n-1)S_2^2}{n+m-2}\right)}} \sim t_{n+m-2}$$

Tem distribuição t de Student com (m+n-2) graus de liberdade.

IC para diferenças entre médias



Dado um nível de significância $100*(1-\alpha)\%$ podemos achar um número “b” tal que:

$$\text{Prob}\{-b < T < b\} = (1-\alpha)$$

b é obtido a partir da distribuição t com n+m-2 graus de liberdade, onde T é a variável mostrada no “slide” anterior, calculada a partir da diferença entre as médias das duas amostras.

IC para diferenças entre médias



□ Para simplificar a notação, seja:

$$R = \sqrt{\left(\frac{1}{n} + \frac{1}{m}\right) \left(\frac{(m-1)S_1^2 + (n-1)S_2^2}{n+m-2}\right)}$$

□ O IC $100*(1-\alpha)\%$ para a diferença das médias é:

$$(\bar{X} - \bar{Y}) - bR; (\bar{X} - \bar{Y}) + bR$$

IC para diferenças entre médias



□ Exemplo

□ Estuda-se um certo processo químico com o objetivo de tentar aumentar a produção de um certo composto. Atualmente usa-se na produção um certo tipo de catalisador A, mas um outro tipo de catalisador B é aceitável.

□ Faz-se uma experiência com n = 8 tentativas para o catalisador A e o mesmo nº de repetições para o catalisador B.

IC para diferenças entre médias



- As médias e variâncias amostrais são:

$$\bar{X} = 91.73, \bar{Y} = 93.75 \text{ e } S_1^2 = 3.89, S_2^2 = 4.02.$$

- Construa um intervalo de confiança 95% para $\mu_1 - \mu_2$.

- Solução

- $n = m = 8$

$$R = \sqrt{\left(\frac{1}{n} + \frac{1}{m}\right) \frac{(m-1)S_1^2 + (n-1)S_2^2}{(n+m-2)}} = \sqrt{\left(\frac{1}{4}\right) \frac{7(3.89) + 7(4.02)}{14}} = 0.989$$

monica@ele.puc-rio.br

69

IC para diferenças entre médias



- $b = 2.145$ da tabela t_{14} . O intervalo de confiança é:

$$(\bar{X} - \bar{Y}) \pm bR = -2.02 \pm 2.121 = (-4.141, 0.101)$$

- Note que este *intervalo inclui zero*. Isso indica que pode não existir diferença real na produção média usando os catalisadores A e B. Assim, baseado apenas neste teste, parece não haver razão para mudar do catalisador A para o B com o objetivo de aumentar a produção.

monica@ele.puc-rio.br

70

IC para a variância da Normal



- Sejam X_1, X_2, \dots, X_n iid $N(\mu, \sigma^2)$ onde ambos μ e σ^2 são desconhecidos. Este é o caso usual na prática, onde desejamos inferir sobre um dos parâmetros quando ambos são desconhecidos.

- A variância amostral é $S^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$

- Também sabemos que nS^2/σ^2 tem distribuição Qui-quadrado com $n-1$ graus de liberdade.

monica@ele.puc-rio.br

71

IC para a variância da Normal



- Dado $\alpha \in (0,1)$ ache a e b da tabela Qui-quadrado com $(n-1)$ graus de liberdade tais que:

- $\Pr(a < (n-1)S^2/\sigma^2 < b) = 1 - \alpha$ e

- $\Pr((n-1)S^2/\sigma^2 < a) = \alpha/2 = \Pr((n-1)S^2/\sigma^2 > b)$

- Logo: $\Pr[(n-1)S^2/b < \sigma^2 < (n-1)S^2/a] = 1 - \alpha$.

monica@ele.puc-rio.br

72

IC para a variância da Normal



- O intervalo $((n-1)S^2/b, (n-1)S^2/a)$ é um intervalo aleatório com probabilidade $1-\alpha$ de incluir o parâmetro desconhecido σ^2 .
- Exemplo
- Sejam X_1, X_2, \dots, X_9 iid Normais com média μ e variância σ^2 .
- Observa-se $s^2 = 7.63$. Encontre um intervalo de confiança 95% para σ^2 .

IC para a variância da Normal



- Solução
- Neste caso precisamos encontrar a e b de uma tabela Qui-quadrado com 8 graus de liberdade.
- O ponto \underline{a} tal que a probabilidade de estar abaixo dele é 2.5% é: 2.180
- O ponto \underline{b} tal que a probabilidade de estar abaixo dele é 97.5% (ou seja, a probabilidade de estar acima dele é 2.5%) é: 17.535.

IC para a variância da Normal



- O intervalo de confiança 95% para a variância da distribuição é:

$$\left(\frac{(n-1)S^2}{b}, \frac{(n-1)S^2}{a} \right) = \left(\frac{8(7.63)}{17.535}, \frac{8(7.63)}{2.180} \right) = (3.481, 28.004)$$

IC aproximado para a proporção de uma Binomial



- Seja $Y \sim \text{Bin}(n,p)$ onde n é conhecido e $0 < p < 1$ é desconhecido.
- Assim, $E(Y) = np$, $\text{VAR}(Y) = np(1-p)$, e $\hat{p} = \frac{Y}{n}$ é o estimador de máxima verossimilhança para p .
- Pelo Teorema Central do Limite:

$$\frac{Y - np}{\sqrt{np(1-p)}} \underset{\text{aprox}}{\sim} N(0,1) \quad \text{se } n \text{ é grande.}$$

IC aproximado para a proporção de uma Binomial



- Mas, precisamos de uma estimativa do desvio padrão de Y para calcular o intervalo de confiança para $\mu = E(Y) = np$, e então substituímos p no denominador pelo seu estimador de máxima verossimilhança.

- Ou seja, um *intervalo de confiança 1- α aproximado* para p é:

$$\left(\hat{p} - z_{1-\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}}, \hat{p} + z_{1-\alpha/2} \sqrt{\frac{\hat{p}(1-\hat{p})}{n}} \right)$$

monica@ele.puc-rio.br

77

IC aproximado para a proporção de uma Binomial



Este intervalo foi obtido da seguinte maneira:

$$\frac{Y - np}{\sqrt{np(1-p)}} \underset{\text{aprox}}{\sim} N(0,1)$$

- Dividindo o numerador e o denominador acima por n leva a:

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

monica@ele.puc-rio.br

78

IC aproximado para a proporção de uma Binomial



- E como Z definido acima é aproximadamente N(0,1) então:

$$\Pr[-z_{1-\alpha/2} < Z < z_{1-\alpha/2}] = 1-\alpha$$

e obtemos o intervalo indicado.

monica@ele.puc-rio.br

79

IC aproximado para a proporção de uma Binomial



- Exemplo
- Uma pesquisa do governo afirma que 10% dos homens com idade inferior a 25 anos estão desempregados.
- Encontre a probabilidade de que, ao tomarmos uma amostra de 400 homens com menos de 25 anos, a proporção estimada de desempregados seja superior a 12%.

monica@ele.puc-rio.br

80

IC aproximado para a proporção de uma Binomial



- ❑ Solução
- ❑ A probabilidade real (segundo o governo) de um homem desta faixa etária estar desempregado é $p = 10\%$.
- ❑ Toma-se uma amostra de tamanho 400 e estima-se p a partir desta amostra. Podemos utilizar o Teorema Central do Limite e encontramos:

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

monica@ele.puc-rio.br

81

IC aproximado para a proporção de uma Binomial



- ❑ A probabilidade desejada é:

$$\begin{aligned} \Pr(\hat{p} > 0.12) &= \Pr\left(\sqrt{\frac{400}{(1/10)(9/10)}}(\hat{p} - 0.10) > \sqrt{\frac{400}{(1/10)(9/10)}}(0.12 - 0.10)\right) = \\ &= \Pr\left(\left(\frac{200}{3}\right)(\hat{p} - 0.10) > \left(\frac{200}{3}\right)(0.02)\right) = \Pr\left(Z > \frac{4}{3}\right) = \Pr(Z > 1.33) = 0.0918 \end{aligned}$$

- ❑ Logo, existe uma probabilidade de cerca de 9% de que a estimativa amostral ultrapasse 12%, mesmo que o valor real seja 10%.

monica@ele.puc-rio.br

82

IC aproximado para a proporção de uma Binomial



- ❑ Exemplo
- ❑ Considere novamente a situação do exemplo anterior.
- ❑ Suponha que a probabilidade de um homem com menos de 25 estar desempregado é desconhecida, e será estimada a partir de uma amostra de 400 homens.
- ❑ Suponha que observamos $\hat{p} = 0.12$. Encontre um intervalo de confiança 90% aproximado para p .

monica@ele.puc-rio.br

83

IC aproximado para a proporção de uma Binomial



- ❑ Solução
- ❑ Pelo exemplo anterior:

$$\frac{\hat{p} - p}{\sqrt{\frac{p(1-p)}{n}}} = \sqrt{n} \frac{\hat{p} - p}{\sqrt{p(1-p)}} \approx \sqrt{n} \frac{\hat{p} - p}{\sqrt{\hat{p}(1-\hat{p})}} = \frac{\sqrt{400}}{\sqrt{(0.12)(0.88)}}(\hat{p} - p) = 61.546(\hat{p} - p)$$

- ❑ É aproximadamente $N(0,1)$. Usando a tabela da Normal leva a:

$$\Pr(-1.645 < Z < +1.645) = 0.90 \Rightarrow \Pr(-1.645 < 61.546(\hat{p} - p) < +1.645) = 0.90$$

monica@ele.puc-rio.br

84

IC aproximado para a proporção de uma Binomial



□ Logo:

$$\begin{aligned} \Rightarrow \Pr\left(\hat{p} - \frac{1.645}{61.546} < p < \hat{p} + \frac{1.645}{61.546}\right) &= \Pr\left(0.12 - \frac{1.645}{61.546} < p < 0.12 + \frac{1.645}{61.546}\right) = \\ &= \Pr(9.33\% < p < 14.67\%) \end{aligned}$$

- Ou seja, nestas condições há 90% de probabilidade da taxa de desemprego real estar entre 9.33% e 14.67%.