

Bioestatística

Aula 5

Teoria da Amostragem e Teoria da Estimação


Prof. Tiago A. E. Ferreira




Teoria da Amostragem



- Com já visto, desejamos uma amostra que seja representativa de uma dada população.




- Observe que pode haver diferenças entre os valores reais (população) e os valores estimados (amostra)



Teoria da Amostragem



- Na prática, quase sempre ocorrerá alguma discrepância entre os resultados estimados (amostra) e os resultados reais (população)
 - Se esta discrepância, ou erro, for no entanto tratável estatisticamente, ainda há possibilidade de inferirmos conclusões verídicas da população a partir da amostra.
 - O estudo das relações entre amostras e população é o objetivo da **Teoria da Amostragem**.




Técnicas de Extração de Amostras



- Basicamente, as técnicas de amostragem podem ser:
 - Amostragem com Reposição (ACR)
 - Todo elemento selecionado para a amostra é devolvido ao repositório antes da seleção do próximo elemento da amostra
 - Dada uma população de tamanho **N** e amostras de tamanho **n**, é possível construir **N^n amostras**.
 - Amostragem sem Reposição (ASR)
 - Um elemento selecionado para a amostra não volta para o repositório antes do término da construção da amostra.
 - Dada uma população de tamanho **N** e amostras de tamanho **n**, é possível construir **$\pi_n(N)$ amostras**, onde $\pi_n(N)$ é a função fatorial incompleta, dada por:


$$\pi_n(N) = N(N-1)(N-2)\cdots(N-n)$$



Amostragem




- Dada uma população
 - Desta população são extraídas **n** amostras
 - Os elementos destas **n** amostras podem variar, não sendo necessariamente os mesmo de uma amostra para a outra.
 - Assim, os **parâmetros amostrais** devem ser diferentes entre as **n** amostras e aos parâmetros populacionais.
 - A grande questão é:
 - “Estas diferenças seguem ou não um comportamento regular e previsível?”



Distribuição Amostral das Médias



- A partir da DAM (Distribuição Amostral das Médias) é possível calcular parâmetros característicos para a distribuição
 - Como a média e a variância da DAM
 - Para uma amostragem com reposição (ou população infinita):
$$\mu_{DAM} = \mu \quad \sigma_{DAM}^2 = \frac{\sigma^2}{n}$$
 - Ou seja, a média da DAM é igual a média populacional e a variância da DAM é a variância populacional dividida pelo tamanho da amostra



Exemplo



- Dado um população hipotética formada por 3 indivíduos


– Cujas taxas de glicose sejam 80, 100, 120 (mg/100ml)

– Assim, a média das taxas de glicose para a população é:

$$\bar{x} = \frac{80 + 100 + 120}{3} = 100(\text{mg} / 100\text{ml})$$

– E a variância populacional é:

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} = \frac{(80 - 100)^2 + (100 - 100)^2 + (120 - 100)^2}{3} = 266,67(\text{mg} / 100\text{ml})$$



Exemplo



- Calculando todas as possíveis amostras de 2 elementos com reposição

Amostra	Indivíduos	Médias Amostrais
1	(80,80)	80
2	(80,100)	90
3	(80,120)	100
4	(100,80)	90
5	(100,100)	100
6	(100, 120)	110
7	(120,80)	100
8	(120,100)	110
9	(120,120)	120

Calculando obtemos,

$$\mu_{DAM} = \frac{80 + 90 + \dots + 120}{9} = 100(\text{mg} / 100\text{ml})$$

$$\sigma_{DAM}^2 = \frac{(80-100)^2 + \dots + (120-100)^2}{9} = 133,33(\text{mg} / 100\text{ml})$$

$$\frac{\sigma^2}{2} = \frac{266,67}{2} \cong 133,33(\text{mg} / 100\text{ml})$$

$$N[\mu, \sigma] \therefore DAM \rightarrow N\left[\mu, \frac{\sigma}{\sqrt{n}}\right]$$




Distribuição Amostral das Médias



- Assim,
 - Se a população tem distribuição normal, caracterizada por uma média μ e um desvio padrão σ
 - Então, as médias amostrais terão também uma distribuição normal com média μ e um desvio padrão σ/\sqrt{n}
 - Gerando uma v.a. padronizada da média das médias amostrais, gera-se uma distribuição t-student:

$$z = \frac{\bar{x} - \mu}{\frac{\sigma}{\sqrt{n}}}$$




Distribuição Amostral das Médias



- Para o caso de amostragem sem reposição:


$$\mu_{DAM} = \mu \quad \sigma_{DAM}^2 = \frac{\sigma^2}{n} \left(\frac{N - n}{N - 1} \right)$$



Distribuição Amostral das Proporções



- Também é possível trabalhar com variáveis não numéricas
 - Como, por exemplo, “percentual de fumantes” e “não fumantes”, ou, sexo “Feminino” e “Masculino”, ou ...
 - A distribuição estatística das proporções de uma v.a. extraídas de todas as amostras de tamanho n de uma população de tamanho N é denominada de **Distribuição Amostral das Proporções (DAP)**.



Distribuição Amostral das Proporções



- Para uma população infinita (com reposição) com distribuição binomial,


$$P \xrightarrow{N \rightarrow \infty} B[p, q = 1 - p]$$

- Os parâmetros da DAP são:

$$\mu_{DAP} = p \quad \sigma_{DAP}^2 = \frac{pq}{n}$$

- Para população finita (sem reposição)

$$\mu_{DAP} = p \quad \sigma_{DAP}^2 = \frac{pq}{n} \left(\frac{N - n}{N - 1} \right)$$




Distribuição Amostral das Diferenças ou das Somas



- Dadas duas populações A e B
 - Suponha que sejam calculadas as diferenças entre as médias de todas as combinações possíveis de amostras de tamanho n_A e n_B das por. A e B
 - Então tem-se uma **Distribuição Amostral das Diferenças (DAD)** entre as médias, ou analogamente, uma **Distribuição Amostral das Somas (DAS)** entre as médias, com médias:

$$\mu_{DAD} = \mu_A - \mu_B \qquad \mu_{DAS} = \mu_A + \mu_B$$



Distribuição Amostral das Diferenças ou das Somas



- A variância tanto para a DAD quanto para a DAS é:

$$\sigma_{DADS}^2 = \frac{\sigma_A^2}{n_A} + \frac{\sigma_B^2}{n_B}$$

- A ideia da Distribuição Amostral das Diferenças ou das Somas pode ser aplicada a qualquer parâmetro ou estatística




Teoria da Estimação



- Estimativa


- De modo geral, uma estimativa é uma tentativa de avaliar algum dado desconhecido
- Desta forma, uma estimativa sempre terá duas características:
 - A estimativa é uma aproximação do dado verdadeiro
 - A estimativa sempre contém um componente de incerteza.



Estimativa Pontual




- Um estimativa é dita ser pontual se esta se baseia em apenas um único ponto.
 - Exemplo:
 - “A média da taxa de glicose de diabéticos foi estimada em 200 mg/100ml”
 - Este é uma estimativa pontual pois considera possível apenas um valor único para a média de todos os diabéticos.
 - Embora esta estimativa seja muito precisa, suas chances de serem verdadeiras são quase nulas!



Estimativa por Intervalo





- Uma estimativa mais factível de ocorrer pode ser descrita por um intervalo.
 - Este procedimento acarreta em um **Intervalo de confiança**.
 - Por exemplo:
 - A taxa média de glicose em diabéticos está entre 180 e 220 mg/100ml, em um nível de confiança de 90%.



Intervalo de Confiança para Média Populacional



- A ideia do intervalo de confiança é que ele englobe uma certa quantidade de observações com uma dada confiança ou certeza.




Intervalo de Confiança para Média Populacional



- O Intervalo de Confiança associado a um grau de certeza (GC) para a média populacional, quando o desvio padrão populacional σ é conhecido, é dado por:

$$IC_{GC}(\mu) \rightarrow \bar{x} \mp z_{GC} \cdot \frac{\sigma}{\sqrt{n}}$$


- Esta expressão depende:
 - Do grau de Confiança z_{GC}
 - Do Desvio Padrão Populacional σ
 - Do tamanho da Amostra n



Intervalo de Confiança para Média Populacional




- Observe que:
 - O termo σ/\sqrt{n} é **erro padrão** da média
 - Grau de confiança muito elevado implica em uma grande amplitude do intervalo de confiança
 - Deseja-se que a estimativa precisa, ou seja, alto grau de confiança (confiabilidade) e pequeno intervalo de confiança
 - Entretanto estas características são concorrentes



Tamanho da Amostra



- É possível determinar o tamanho de uma amostra para que esta satisfaça um certo intervalo de confiança.
 - Foi visto que a média populacional pode ser estimada a partir das médias amostrais com um erro de $z_{GC} \sigma / \sqrt{n}$
 - Assim é possível fixar uma margem máxima de erro, ou uma proporção ε



Tamanho da Amostra




- Assim,

$$\frac{z_{GC} \cdot \sigma}{\sqrt{n}} \leq \varepsilon \cdot \bar{x}$$

ou

$$n \geq \left(\frac{z_{GC} \cdot \sigma}{\varepsilon \cdot \bar{x}} \right)^2$$



Exemplo



- Deseja-se estimar o diâmetro pupilar de coelhos adultos normais, a partir de uma amostra de 12 animais, cuja média foi 5,2 mm e considerando que o desvio padrão é 1,2 mm. Empregando o grau de confiança de 95% ($Z_{GC} = 1,96$)
 - IC95% $\rightarrow 5,2 \text{ (mm)} \pm 12(\text{mm})/\sqrt{12}$
 - IC95% $\rightarrow 5,2 \text{ (mm)} \pm 0,68 \text{ (mm)}$
 - Ou seja, pode-se ter uma confiança de 95% de que a média pupilar esteja entre 4,52 mm e 5,88 mm



Desvio Padrão Populacional Estimado




- Na realidade, na grande maioria dos casos, também não conhecemos o desvio padrão populacional
 - Mais podemos estimá-lo através do desvio padrão amostral

$$s = \sqrt{\frac{\sum (x - \bar{x})^2}{n - 1}}$$

– Assim

$$IC_{GC}(\mu) \rightarrow \bar{x} \mp t_{GC,gl} \cdot \frac{s}{\sqrt{n}}$$

- Onde agora é utilizada a distribuição t-student com *gl graus de liberdade*




Exemplo



- Para o exemplo anterior da medida do diâmetro pupilar do coelhos,
 - $\bar{x}=5,2$ mm
 - $s=0,69$ mm
 - Assim, $t_{95\%,11}=2,20$, logo:

$$IC_{95\%}(\mu) \rightarrow 5,2 \mp 2,10 \cdot \frac{0,69}{\sqrt{12}} = 5,2 \mp 0,44$$

$$IC_{95\%}(\mu) \rightarrow 4,76(mm) \leq \mu \leq 5,64(mm)$$




Intervalo de Confiança para a Diferença de Médias Populacionais



- Dada duas populações A e B
 - O Intervalo de Confiança para a diferença das médias, para um certo GC, é dado por

$$IC_{GC}(\mu_A - \mu_B) \rightarrow (\bar{x}_A - \bar{x}_B) \mp t_{GC, gl} \cdot \sqrt{\frac{s_A^2}{n_A} + \frac{s_B^2}{n_B}}$$

sendo $gl = n_A + n_B - 2$



Exemplo



- Suponha que medimos o diâmetro pupilar de dois grupos de coelhos, um grupo normal e o outro após estímulo doloroso.
 - Grupo 1: Normal

Coelho	1	2	3	4	5	6	7	8	9	10	11	12
DP(mm)	5,0	5,5	5,0	4,5	4,5	6,0	6,5	5,5	5,5	5,0	5,5	4,0

- Grupo 2: tratamento doloroso


Coelho	1	2	3	4	5	6	7	8	9	10
DP(mm)	9,0	10,0	8,0	8,0	8,0	9,0	8,5	10,0	8,0	10,5



Exemplo



- Para o grupo 1:
 - Média = 5,2 mm
 - S = 0,69 mm
- Para o grupo 2:
 - Média = 8,9 mm
 - S = 0,97 mm
- Pergunta-se:
 - Qual a alteração pupilar de um coelho ao receber um estímulo doloroso?



Exemplo



- Com confiabilidade de 95%:


– Onde $gl=10+12-2=20$ e $t_{95\%,20} = 2,09$

$$IC_{95\%}(\mu_A - \mu_B) \rightarrow (8,9 - 5,2) \mp 2,09 \cdot \sqrt{\frac{0,97^2}{10} + \frac{0,69^2}{12}}$$

$$IC_{95\%}(\mu_A - \mu_B) \rightarrow 3,7(mm) \mp 0,76(mm)$$

$$IC_{95\%}(\mu_A - \mu_B) \rightarrow 2,94(mm) \leq (\mu_A - \mu_B) \leq 4,46(mm)$$


- Assim, é possível afirmar, com um nível de confiança de 95%, que o estímulo doloroso aumenta o diâmetro pupilar de 2,94 a 4,46 mm



Amostras Pareadas



- Amostras pareadas ou pares de amostras são dados referentes a um mesmo conjunto de indivíduos, tomados em situações distintas
 - Geralmente, estas duas situações são denominadas *antes e depois*.
 - De forma geral, deseja-se saber se estas duas amostras são iguais ou diferentes!



Amostras Pareadas



- Dada uma situação onde foram medidas as variáveis:

ANTES	DEPOIS
$X_{A,1}$	$X_{B,1}$
...	...
$X_{A,n}$	$X_{B,n}$

– Assim, o intervalo de confiança é:

$$IC_{GC}(\Delta_{A-B}) \rightarrow \bar{d}_{A-B} \mp t_{GC,gl} \frac{s_d}{\sqrt{n}}$$

onde,

$$d_i = x_{A,i} - x_{B,i} \quad \bar{d}_{A-B} = \frac{1}{n} \sum_{i=1}^n d_i \quad s_d = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2}$$

Exemplo




- Considere 10 pacientes febris que foram tratados com um antitérmico.

Paciente	1	2	3	4	5	6	7	8	9	10
Temp. (°C) Antes	38,0	39,5	38,0	38,7	37,5	39,0	38,0	37,8	36,7	39,0
Temp. (°C) Depois	36,5	37,8	37,0	37,5	36,0	38,5	37,0	36,5	36,0	37,5

– Quais as diferenças?

- $d_1 = x_{A,1} - x_{B,1} = 38,0 - 36,5 = 1,5 \text{ } ^\circ\text{C}$
- E assim por diante...
 - $1,7^\circ\text{C}; 1,0 \text{ } ^\circ\text{C}; 1,2^\circ\text{C}; 1,5^\circ\text{C}; 0,5^\circ\text{C}; 1,0^\circ\text{C}; 1,3^\circ\text{C}; 0,7^\circ\text{C}; 1,5^\circ\text{C}$



Exemplo



- As médias das diferenças “antes-depois”:


$$\bar{d}_{A-B} = \frac{1}{n} \sum_{i=1}^n d_i = \frac{1,5 + 1,7 + \dots + 1,5}{10} = 1,19^{\circ} C$$

- O Desvio Padrão para as diferenças

$$s_i = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (d_i - \bar{d})^2} = \sqrt{\frac{(1,5 - 1,19)^2 + \dots + (1,5 - 1,19)^2}{10 - 1}} = 0,39^{\circ} C$$

- O IC com GC=95%

$$IC_{95\%}(\Delta_{A-B}) \rightarrow 1,19 \mp 2,26 \cdot \frac{0,39}{\sqrt{10}} = 1,19^{\circ} C \mp 0,28^{\circ} C$$




Intervalo de Confiança para Proporções Populacionais



- Quanto temos alguma proporção binária em uma população, caímos em uma distribuição binomial, com probabilidade p e q .
 - Assim, dada um proporção π , o intervalo de confiança será:

$$IC_{GC}(\pi) \rightarrow p \mp t_{GC.gl} \cdot \sqrt{\frac{p \cdot q}{n}}$$



Exemplo




- Dado um certo levantamento sobre alcoolismo mostrou que, de 30 entrevistados, 18 afirmaram ingerir bebidas alcoólicas com frequência. Qual a estimativa, com GC=95%, da proporção de indivíduos que bebem habitualmente?

$$- p=18/30=0,6; q=1-p=0,4; gl=30-1=29; t_{95\%,29} = 2,05$$

$$IC_{95\%}(\pi) \rightarrow 0,6 \mp 2,05 \cdot \sqrt{\frac{0,6 \cdot 0,4}{30}} = 0,6 \mp 0,1833$$

$$IC_{95\%}(\pi) \rightarrow 41,65\% \leq \pi \leq 78,33\%$$



Intervalo de Confiança para Diferenças de Proporções Populacionais



- Da mesma forma que temos diferenças para médias, é possível termos diferenças para proporções populacionais para as populações A e B ($\pi_A - \pi_B$).
 - Assim,


$$IC_{GC}(\pi_A - \pi_B) \rightarrow (p_A - p_B) \mp t_{GC,gl} \cdot \sqrt{\frac{p_A q_A}{n_A} + \frac{p_B q_B}{n_B}}$$



Comparando duas Grandezas



- Ao montarmos os IC para Diferenças, **com um GC**, é possível responder se duas grandezas são estatisticamente iguais ou diferente!
 - Se o IC contiver o valor “Zero”, então não é possível distinguir diferença entre as grandezas
 - Caso contrário, as duas grandezas são distintas!



Referências



- Livro Texto: Bioestatística. Teoriaia e Computacional (Héctor G. Arango). Guanaba
 - Capítulo 7
- Leituras Complementares:
 - Livro: Bioestatística. Princípios e Aplicações (Sidia M. Callegari-Jaqcques)
 - Capítulo 5, 8 e 9.
 - Livro: Estatística Básica (Wilton de O. Bussab e Pedro A. Morettin). Saraiva
 - Capítulo: 11
 - Livro: Probabilidade. Aplicações à Estatística (Paul L. Meyer). LTC
 - Capítulos 14

