

# Amostragem por conglomerados em um único estágio (AC): parte 2

Prof. Caio Azevedo

# Normalidade assintótica dos estimadores

- Temos, para  $a$  e  $A$  suficientemente grandes,  $i = 1, 2, 3$ ,  $j = 1, 2$ , que

$$\frac{\widehat{\mu}_{C_i} - \mu}{EP_{A_j}(\widehat{\mu}_{C_i})} \xrightarrow[\substack{a \rightarrow \infty, \\ A - a \rightarrow \infty}]{D} N(0, 1)$$

$$\frac{\widehat{\mu}_{C_i} - \mu}{\widehat{EP}_{A_j}(\widehat{\mu}_{C_i})} \xrightarrow[\substack{a \rightarrow \infty, \\ A - a \rightarrow \infty}]{D} N(0, 1)$$

- As notações relativas à Amostragem por Conglomerados (AC) seguem essas ([aqui](#)) e as de teoria assintótica essas ([aqui](#) e [aqui](#)).

# Intervalos de confiança

- Conglomerados de tamanhos desiguais

$$\left[ \hat{\mu}_{C_i} - z_\gamma \sqrt{\hat{v}_{A_j}(\hat{\mu}_{C_i})}; \hat{\mu}_{C_i} + z_\gamma \sqrt{\hat{v}_{A_j}(\hat{\mu}_{C_i})} \right]$$

- Erro da estimativa:  $z_\gamma \sqrt{\hat{v}_{A_j}(\hat{\mu}_{C_i})}$ .

# Intervalos de confiança

- Conglomerados de tamanhos iguais ( $AAS_C$ )

$$\left[ \hat{\mu}_C - z_\gamma \sqrt{\frac{1}{a(a-1)} \sum_{\alpha=1}^a (\hat{\mu}_\alpha - \hat{\mu}_C)^2}; \hat{\mu}_C + z_\gamma \sqrt{\frac{1}{a(a-1)} \sum_{\alpha=1}^a (\hat{\mu}_\alpha - \hat{\mu}_C)^2} \right]$$

em que  $\hat{\mu}_C = \frac{1}{a} \sum_{\alpha=1}^a \hat{\mu}_\alpha$ .

- Erro da estimativa:  $z_\gamma \sqrt{\frac{1}{a(a-1)} \sum_{\alpha=1}^a (\hat{\mu}_\alpha - \hat{\mu}_C)^2}$ .

## Cont.

- Os testes de hipóteses seguem, essencialmente, os mesmo procedimentos descritos nos slides 10 a 14 [desses slides](#), em que a estatística do teste passa a ser

$$Z_t = \frac{\hat{\mu}_{C_i} - \mu_0}{\widehat{EP}_{A_j}(\hat{\mu}_{C_i})}$$

# Determinação do tamanho da amostra

- O “tamanho da amostra” a ser determinado, nesse caso, é o número “a” de conglomerados a serem sorteados.
- Se os conglomerados tiverem tamanhos iguais, o tamanho da amostra real ( $n = \sum_{\alpha=1}^a n_{\alpha}$ ) será constante, dado “a”. Caso contrário, será uma variável aleatória.

# Determinação do tamanho da amostra

- Supondo conglomerados de mesmo tamanho, e fixando a precisão ( $\delta$ ), temos que :

$$P(|\hat{\mu}_C - \mu| \leq \delta) \geq \gamma \rightarrow P\left(|Z| \leq \frac{\delta}{\sqrt{\sigma_{ec}^2/a}}\right) = \gamma \rightarrow$$
$$z_\gamma = \frac{\delta}{\sqrt{\sigma_{ec}^2/a}} \rightarrow a = \frac{\sigma_{ec}^2 z_\gamma^2}{\delta^2}$$

em que  $\sigma_{ec}^2 = \frac{1}{A} \sum_{\alpha=1}^A (\mu_\alpha - \mu)^2$

- Se se fixar o erro da estimativa, obter-se-á a mesma fórmula para o tamanho da amostra.
- Exercício: obter o tamanho da amostra considerando conglomerados de tamanhos diferentes.

# Determinação do tamanho da amostra

- Exercício: obter todas as expressões para as esperanças, variâncias, EQM, testes de hipótese, IC e tamanhos de amostra considerando que os conglomerados foram selecionados segundo um plano  $AAS_s$ .
- Exercício: repetir os procedimentos para a estimação do total populacional ( $\tau$ ), a partir de estimadores que você entender que são apropriados.



# Estimação de proporções

- Todas as quantidades são como definidas [aqui](#).

- Parâmetro de interesse: 
$$p = \frac{\sum_{\alpha=1}^A \tau_{\alpha}}{\sum_{\alpha=1}^A B_{\alpha}}.$$

- Como a proporção é uma média de variáveis binárias, os desenvolvimentos seguem àqueles apresentados para a estimação da média sob AC e para a proporção sob  $A_1$  (veja [aqui](#)) e sob  $A_2$  (exercício).

# Estimação de proporções

- Estimador (razão):  $\hat{p}_{C_2} = \frac{\sum_{\alpha=1}^a \hat{\tau}_{\alpha}}{\sum_{\alpha=1}^a b_{\alpha}} = \frac{\hat{\tau}}{\hat{B}}$ .
- Variância:  $\mathcal{V}(\hat{p}_{C_2}) \approx \frac{1}{aA\bar{B}^2} \sum_{\alpha=1}^A (\tau_{\alpha} - pB_{\alpha})^2$
- Estimador para a variância:  $\hat{\mathcal{V}}(\hat{p}_{C_2}) \approx \frac{1}{a(a-1)\bar{b}^2} \sum_{\alpha=1}^a (\hat{\tau}_{\alpha} - \hat{p}_{C_2} b_{\alpha})^2$
- Os dois outros estimadores são:

$$\hat{p}_{C_1} = \frac{\hat{\tau}}{\hat{B}}; \hat{p}_{C_3} = \frac{1}{a} \sum_{\alpha=1}^a \hat{p}_{\alpha}$$

## Cont.

- Suas variâncias são dadas, respectivamente, por:

$$\mathcal{V}(\hat{p}_{C_1}) = \frac{1}{aA\bar{B}^2} \sum_{\alpha=1}^A (\tau_{\alpha} - p)^2; \mathcal{V}(\hat{p}_{C_3}) = \frac{1}{aA} \sum_{\alpha=1}^A (p_{\alpha} - \bar{p})^2$$

- Estimadores são dados, respectivamente, por:

$$\hat{\mathcal{V}}(\hat{p}_{C_1}) = \frac{1}{a(a-1)\bar{B}^2} \sum_{\alpha=1}^A (\hat{\tau}_{\alpha} - \hat{p}_{C_1})^2; \hat{\mathcal{V}}(\hat{p}_{C_3}) = \frac{1}{a(a-1)} \sum_{\alpha=1}^A (\hat{p}_{\alpha} - \hat{p}_{C_3})^2$$

- Quando os conglomerados tiverem o mesmo tamanho, as expressões das variâncias (e de seus respectivos estimadores), simplificam-se. Veja o exercício 7.21 (Bolfarine & Bussab (2005)).

# Normalidade assintótica

- Temos, para  $a$  e  $A$  suficientemente grandes,  $i = 1, 2, 3$ ,  $j = 1, 2$ , que

$$\frac{\hat{p}_{C_i} - p}{EP_{A_j}(\hat{p}_{C_i})} \xrightarrow[A \rightarrow \infty]{a \rightarrow \infty} N(0, 1)$$

$$\frac{\hat{p}_{C_i} - p}{\widehat{EP}_{A_j}(\hat{p}_{C_i})} \xrightarrow[A \rightarrow \infty]{a \rightarrow \infty} N(0, 1)$$

# Intervalos de confiança

- Conglomerados de tamanhos desiguais  $j = 1, 2$ ,  $i = 1, 2, 3$

$$\left[ \hat{p}_{C_i} - z_\gamma \sqrt{\hat{v}_{A_j}(\hat{p}_{C_i})}; \hat{p}_{C_i} + z_\gamma \sqrt{\hat{v}_{A_j}(\hat{p}_{C_i})} \right]$$

- Erro da estimativa:  $z_\gamma \sqrt{\hat{v}_{A_j}(\hat{p}_{C_i})}$ .
- Exercício: repetir os procedimentos considerando que os conglomerados são sorteados segundo um plano  $AAS_s$  e/ou quando estes tiverem o mesmo tamanho.

# Intervalos de confiança

- Os testes de hipóteses seguem, essencialmente, os mesmo procedimentos descritos no slide 10 [deste material](#), em que a estatística do teste passa a ser

$$Z_t = \frac{\hat{p}_{C_i} - p_0}{\widehat{EP}_{A_j}(\hat{p}_{C_i})}$$

- Exercício: repetir os procedimentos considerando que os conglomerados são sorteados segundo um plano  $AAS_s$  e/ou quando os conglomerados tiverem o mesmo tamanho.

# Amostragem sistemática (AS)

- Trata-se de um processo de seleção quase-aleatório ([link](#)).
- Considere uma população com  $N$  elementos em que  $N = kn$ , e  $k \in \mathbb{Z}^+$  e que seus elementos estão ordenados de 1 a  $N$  (no sistema de referência).
- Uma unidade é selecionada aleatoriamente (segundo AAS) entre as  $k$  primeiras unidades do sistema de referência.
- As unidades seguintes, que farão parte da amostra, serão obtidas a partir da primeira unidade selecionada, em intervalos de comprimento  $k$ .

# Exemplo

- Suponha uma população com  $N = 1.000$  e  $n = 200$ . Portanto,  $k = 5$ .
- Ou seja a população está dividida em 200 grupos de 5 unidades populacionais.
- Suponha que uma unidade seja aleatoriamente selecionada entre as 5 primeiras e que esta tenha sido a de número 3.
- Portanto, em cada um dos 199 grupos restantes, será selecionada sempre a terceira unidade, levando, assim, a uma AS de  $n = 200$  unidades.



# Características

- Facilidade em sua execução (mecânica do sorteio).
- Bem menos sujeita a erros do entrevistador do que os outros métodos de amostragem vistos.
- Pode ou não levar à inferências mais precisas.
- Pode levar a inferências viesadas, dependendo de como a população esteja organizada no sistema de referência.

# Características

- As estimativas das variâncias dos estimadores dependem de como os elementos da população estão dispostos no sistema de referência (aleatório ou de forma tendenciosa).
- Essencialmente, a AS pode ser vista como uma caso particular da AC (embora, se a população esteja diposta de forma aleatória, algumas expressões podem ser próximas daquelas obtidas sob o plano AAS).
- Outros estimadores para as variâncias dos estimadores podem ser encontrados em [Bolfarine e Bussab \(2005\)](#) e [Cochran \(1977\)](#).

# Relação com a AC

- Considere a população ordenada da seguinte forma:

$$\mathbf{d} = (y_1, \dots, y_k, y_{k+1}, \dots, y_{2k}, \dots, y_{(n-1)k+1}, \dots, y_{nk})^t$$

que pode também ser representado através de uma matriz onde na linha  $\alpha$  tem-se a  $\alpha$ -ésima amostra sistemática, enquanto que na coluna  $i$  tem-se o  $i$ -ésimo grupo(zona).

## Relação com a AC

| Amostra  | grupo      |            |          |                | média    |
|----------|------------|------------|----------|----------------|----------|
|          | 1          | 2          | ...      | n              |          |
| 1        | $y_1$      | $y_{k+1}$  | ...      | $y_{(n-1)k+1}$ | $\mu_1$  |
| 2        | $y_2$      | $y_{k+2}$  | ...      | $y_{(n-1)k+2}$ | $\mu_2$  |
| $\vdots$ | $\vdots$   | $\vdots$   | $\ddots$ | $\vdots$       | $\vdots$ |
| $k$      | $y_k$      | $y_{2k}$   | ...      | $y_{nk}$       | $\mu_k$  |
| média    | $\mu_{.1}$ | $\mu_{.2}$ | ...      | $\mu_{.n}$     | $\mu$    |

## Relação com a AC

- Cada linha da matriz anterior corresponde a uma amostra sistemática de média  $\mu_\alpha$ ,  $\alpha = 1, 2, \dots, k$ .
- Na última coluna temos todas as médias das  $k$  amostras sistemáticas.
- Cada uma dessas amostras pode ser vista como um conglomerado (todos de tamanho  $n$ ).
- Portanto a AS pode ser vista como uma AC em que  $A = k$  conglomerados e destes,  $a = 1$  é selecionado.

# Estimador para a média ( $\mu$ )

- $\hat{\mu}_{sis} = \hat{\mu}_\alpha$ , a média da amostra sistemática (conglomerado) sorteada(o).
- Distribuição exata do estimador  $\hat{\mu}_{sis}$ ,

| $\hat{\mu}_{sis}$        | $\mu_1$       | $\mu_2$       | $\dots$ | $\mu_\alpha$  | $\dots$ | $\mu_k$       |
|--------------------------|---------------|---------------|---------|---------------|---------|---------------|
| $P(\hat{\mu}_{sis} = r)$ | $\frac{1}{k}$ | $\frac{1}{k}$ | $\dots$ | $\frac{1}{k}$ | $\dots$ | $\frac{1}{k}$ |

- Portanto  $\mathcal{E}(\hat{\mu}_{sis}) = \frac{1}{k} \sum_{\alpha=1}^k \mu_\alpha = \mu$  e  $V_k = \mathcal{V}(\hat{\mu}_{sis}) = \frac{1}{k} \sum_{\alpha=1}^k (\mu_\alpha - \mu)^2$ .
- Como selecionamos apenas um único conglomerado  $a = 1$ , não é possível obter um estimador não viciado de  $\mathcal{V}(\hat{\mu}_{sis})$ .

## Estimador para a média ( $\mu$ )

- Na maioria dos casos, essa variância é estimada por:

$$\widehat{V}_k = \widehat{V}_s = \frac{1-f}{n(n-1)} \sum_{i=1}^n (Y_i - \widehat{\mu}_{sis})^2,$$

em que  $f = \frac{n}{N}$  e  $(Y_1, \dots, Y_n)^t$  são variáveis aleatórias que representam a amostra a ser sorteada.

- Tal estimador é adequado quando a AS é aproximadamente equivalente à AAS (elementos organizados de forma “aleatória”).
- Contudo, se se tiver algum padrão na disposição dos elementos no sistema de referência, os resultados podem ser diferentes daquelas da AAS.

# Estimador para a média ( $\mu$ )

- Sob AS (lembrando que AS corresponde ao plano AC, sob certas restrições), temos que

$$V_k = \{1 + \rho_{int}(n-1)\} \frac{\sigma^2}{n}.$$

- em que  $\rho_{int} = \frac{\sigma_{ec}^2 - \sigma_{dc}^2 / (n-1)}{\sigma^2}$ .

- Como todos os conglomerados têm o mesmo tamanho e  $B = n$  (tamanho de cada conglomerado) então

$$\sigma_{ec}^2 = \frac{1}{k} \sum_{\alpha=1}^k (\mu_{\alpha} - \mu)^2, \quad \sigma_{dc}^2 = \frac{1}{k} \sum_{\alpha=1}^k \sigma_{\alpha}^2, \quad \sigma_{\alpha}^2 = \frac{1}{n} \sum_{i=1}^n (y_{\alpha i} - \mu_{\alpha})^2$$



# Exemplos

- (Exemplo 7.6, do livro Bolfarine & Bussab (2005)) Considere uma população onde  $\mathbf{d} = (2, 6, 10, 8, 10, 12)$ ,  $N = 6$  e dividida em  $n = 2$  e  $k = 3$  unidades cada, como segue:

| Grupo   |    |    |       |
|---------|----|----|-------|
| Amostra | 1  | 2  | Média |
| 1       | 2  | 8  | 5     |
| 2       | 6  | 10 | 8     |
| 3       | 10 | 12 | 11    |

# Exemplos

- Distribuição exata de  $\hat{\mu}_{sis}$

|                          |     |     |     |
|--------------------------|-----|-----|-----|
| $\hat{\mu}_{sis}$        | 5   | 8   | 11  |
| $P(\hat{\mu}_{sis} = r)$ | 1/3 | 1/3 | 1/3 |

- O que leva à  $\mathcal{E}(\hat{\mu}_{sis}) = 8$ ,  $\mathcal{V}(\hat{\mu}_{sis}) = 6$ .

# Exemplos

- Distribuição exata de  $\hat{\mu}$  (sob  $AAS_s$  para  $n = 2$ )

| $\hat{\mu}$        | 4    | 5    | 6    | 7    | 8    | 9   | 10   | 11   |
|--------------------|------|------|------|------|------|-----|------|------|
| $P(\hat{\mu} = r)$ | 1/15 | 1/15 | 2/15 | 2/15 | 2/15 | 1/5 | 2/15 | 2/15 |

- O que leva à  $\mathcal{E}(\hat{\mu}) = 8$ ,  $\mathcal{V}(\hat{\mu}) = 4,27$ . Assim, nota-se que  $\hat{\mu}_{sis}$  é pior do que  $\hat{\mu}$ . Com efeito,  $\rho_{int} = 0,125 > 0$ .

# Exemplos

- Exemplo 7.7 (livro-texto). Considere uma população com  $N = 40$  elementos distribuídos em  $k = 10$  amostras sistemáticas de tamanho  $n = 4$ .
- Análise: [aqui](#).
- Sob  $AAS_s$ ,  $n = 4$ :

$$\mathcal{V}_{A_2}(\hat{\mu}) = (1 - f) \frac{s^2}{n} = \left(1 - \frac{1}{10}\right) \frac{136,25}{4} = 30,66.$$

# Exemplos

- Além disso,  $\mathcal{V}(\widehat{\mu}_{sis}) = \frac{1}{k} \sum_{\alpha=1}^k (\mu_{\alpha} - \mu)^2 = 8,74$ .
- Com efeito, neste caso  $\rho_{int} = -0,217 < 0$
- Sob AE: cada um dos  $H = 4$  grupos é um estrato de tamanho  $N_h = 10$ . Seleciona-se um elemento de cada estrato ( $n = \sum_{h=1}^4 1 = 4$ ).

Assim:

$$\begin{aligned}\mathcal{V}(\widehat{\mu}_{es}) &= \sum_{h=1}^4 W_h^2 (1 - f_h) \frac{s_h^2}{n_h} = \frac{1}{16} \left(1 - \frac{1}{10}\right) \sum_{h=1}^4 s_h^2 \\ &= \left(1 - \frac{1}{10}\right) 53,94 \approx 3,03\end{aligned}$$