

# Amostragem Estratificada (AE): parte 3

Prof. Caio Azevedo

# Estimação da proporção

- Mesma estrutura relativa à estimação da média sob AE ([link 1](#), [link 2](#)), com algumas adaptações.
- Vetor de dados populacionais  $\mathbf{d} = (y_{11}, \dots, y_{1N_1}, \dots, y_{hi}, \dots, y_{HN_H})^T$ .
- $N_h$  : tamanho do estrato  $h$ .
- $y_{hi}$  : valor da variável de interesse da unidade amostral  $i$  no estrato  $h$ ,  $i = 1, \dots, N_h$ , em que  $y_{hi} = 1$ , se sucesso e 0, caso contrário.
- $Y_{hi}$  : variável aleatória que representa o  $i$ -ésimo elemento sorteado no estrato  $h$ ,  $i = 1, \dots, n_h$ .
- $p_h = \frac{1}{N_h} \sum_{i=1}^{N_h} y_{hi}$  : proporção do estrato  $h$ .

## Notações e relações úteis (cont.)

- $\sigma_h^2 = \frac{1}{N_h} \sum_{i=1}^{N_h} (y_{hi} - p_h)^2 = p_h q_h$  : variância do estrato h,  
 $q_h = 1 - p_h$ .
- $s_h^2 = \frac{1}{N_h - 1} \sum_{i=1}^{N_h} (y_{hi} - p_h)^2 = \frac{N_h}{N_h - 1} \sigma_h^2 = \frac{N_h}{N_h - 1} p_h q_h$  : variância do estrato h.
- $W_h = \frac{N_h}{N}$  : peso (proporção) do estrato h,  $\sum_{h=1}^H W_h = 1$ .

## Notações e relações úteis (cont.)

- $p = \frac{1}{N} \sum_{h=1}^H \sum_{i=1}^{N_h} y_{hi} = \frac{1}{N} \sum_{h=1}^H N_h p_h = \sum_{h=1}^H W_h p_h$ : proporção populacional.
- $\sigma^2 = \frac{1}{N} \sum_{h=1}^H \sum_{i=1}^{N_h} (y_{hi} - p)^2 = \sum_{h=1}^H W_h \sigma_h^2 + \sum_{h=1}^H W_h (p_h - p)^2$   
 $= \sum_{h=1}^H W_h p_h q_h + \sum_{h=1}^H W_h (p_h - p)^2$ .
- Podemos escrever  $\sigma^2 = \sigma_d^2 + \sigma_e^2$ , em que  $\sigma_d^2 = \sum_{h=1}^H W_h p_h q_h$  e  $\sigma_e^2 = \sum_{h=1}^H W_h (p_h - p)^2$ .

## Notações e relações úteis (cont.)

$$\begin{aligned} \blacksquare s^2 &= \frac{1}{N-1} \sum_{h=1}^H \sum_{i=1}^{N_h} (y_{hi} - p)^2 = \\ &\sum_{h=1}^H \frac{N_h - 1}{N-1} s_h^2 + \sum_{h=1}^H \frac{N_h}{N-1} (p_h - p)^2 = s_{d'}^2 + s_{e'}^2, \end{aligned}$$

$$s_{d'}^2 = \sum_{h=1}^H \frac{N_h - 1}{N-1} s_h^2 = \sum_{h=1}^H \frac{N_h - 1}{N-1} \frac{N_h}{N_h - 1} \sigma_h^2 = \sum_{h=1}^H \frac{N_h}{N-1} \sigma_h^2 = \sum_{h=1}^H \frac{N_h}{N-1} p_h q_h,$$

$$s_{e'}^2 = \sum_{h=1}^H \frac{N_h}{N-1} (p_h - p)^2$$

# Estimador proposto

- Basicamente, o estimador considerado, é aquele utilizado para a média, em que a variável resposta (observada) é binária.
- Ademais, os resultados obtidos para a estimação da proporção, sob  $AAS_c$  e  $AAS_s$ , serão utilizados.
- Estimador proposto:  $\hat{p}_{es} = \sum_{h=1}^H W_h \hat{p}_h$ , em que  $\hat{p}_h = \frac{1}{n_h} \sum_{i=1}^{n_h} Y_{hi}$ .
- Segue-se, então, que

$$\mathcal{E}_{AE_i}(\hat{p}_{es}) = \mathcal{E}\left(\sum_{h=1}^H W_h \hat{p}_h\right) = \sum_{h=1}^H W_h \mathcal{E}(\hat{p}_h) = \sum_{h=1}^H W_h p_h = p.$$

# Estimador proposto

- De forma análoga,

$$\mathcal{V}_{AE_1}(\hat{p}_{es}) = \sum_{h=1}^H W_h^2 \frac{\sigma_h^2}{n_h} = \sum_{h=1}^H W_h^2 \frac{p_h q_h}{n_h} \quad (1)$$

$$\begin{aligned} \mathcal{V}_{AE_2}(\hat{p}_{es}) &= \sum_{h=1}^H W_h^2 (1 - f_h) \frac{s_h^2}{n_h} = \sum_{h=1}^H W_h^2 (1 - f_h) \frac{N_h}{N_h - 1} \frac{\sigma_h^2}{n_h} \\ &= \sum_{h=1}^H W_h^2 (1 - f_h) \frac{N_h}{N_h - 1} \frac{p_h q_h}{n_h} \\ &= \sum_{h=1}^H W_h^2 \frac{N_h - n_h}{N_h - 1} \frac{p_h q_h}{n_h} \end{aligned} \quad (2)$$

# Propriedades do estimador

- Estimadores apropriados, para as respectivas variâncias do estimador, são dados por:

$$\widehat{V}_{AE_1}(\widehat{p}_{es}) = \sum_{h=1}^H W_h^2 \frac{\widehat{\sigma}_h^2}{n_h} = \sum_{h=1}^H W_h^2 \frac{\widehat{p}_h \widehat{q}_h}{n_h - 1}$$

$$\widehat{V}_{AE_2}(\widehat{p}_{es}) = \sum_{h=1}^H W_h^2 (1 - f_h) \frac{\widehat{s}_h^2}{n_h} = \sum_{h=1}^H W_h^2 (1 - f_h) \frac{\widehat{p}_h \widehat{q}_h}{n_h - 1}$$

- em que  $\widehat{q}_h = 1 - \widehat{p}_h$ ,  $\widehat{\sigma}_h^2 = \widehat{s}_h^2 = \frac{1}{n_h - 1} \sum_{i=1}^{n_h} (Y_{hi} - \widehat{p}_h)^2$



# Propriedades do estimador

- No caso das alocações proporcional e uniforme, e  $AAS_c$  em cada estrato, temos, respectivamente que:

$$\mathcal{V}_{AE_1(pr)}(\hat{p}_{es}) = \sum_{h=1}^H W_h^2 \frac{p_h q_h}{n W_h} = \frac{1}{n} \sum_{h=1}^H W_h p_h q_h$$

$$\mathcal{V}_{AE_1(un)}(\hat{p}_{es}) = \sum_{h=1}^H W_h^2 \frac{p_h q_h}{n/H} = \frac{H}{n} \sum_{h=1}^H W_h^2 p_h q_h$$

# Propriedades do estimador

- No caso das alocações proporcional e uniforme, e  $AAS_5$  em cada estrato, temos, respectivamente, que:

$$\begin{aligned} \mathcal{V}_{AE_2(pr)}(\hat{p}_{es}) &= \sum_{h=1}^H W_h^2 (1 - f_h) \frac{N_h}{N_h - 1} \frac{p_h q_h}{n W_h} \\ &= \frac{1}{n} \sum_{h=1}^H W_h (1 - f_h) \frac{N_h}{N_h - 1} p_h q_h, f_h = \frac{n}{N} \end{aligned}$$

$$\begin{aligned} \mathcal{V}_{AE_2(un)}(\hat{p}_{es}) &= \sum_{h=1}^H W_h^2 (1 - f_h) \frac{N_h}{N_h - 1} \frac{p_h q_h}{n/H} \\ &= \frac{H}{n} \sum_{h=1}^H W_h^2 (1 - f_h) \frac{N_h}{N_h - 1} p_h q_h, f_h = \frac{n}{HN_h} \end{aligned}$$

# Propriedades do estimador

- Estimadores apropriados, sob diferentes formas de alocação e  $AAS_c$ , são dadas por:

$$\hat{V}_{AE_1(pr)}(\hat{p}_{es}) = \sum_{h=1}^H W_h^2 \frac{\hat{p}_h \hat{q}_h}{n W_h - 1} = \sum_{h=1}^H W_h \frac{\hat{p}_h \hat{q}_h}{n - W_H^{-1}} \quad (3)$$

$$\hat{V}_{AE_1(un)}(\hat{p}_{es}) = \sum_{h=1}^H W_h^2 \frac{\hat{p}_h \hat{q}_h}{n/H - 1} = H \sum_{h=1}^H W_h^2 \frac{\hat{p}_h \hat{q}_h}{n - H} \quad (4)$$

# Propriedades do estimador

- Estimadores apropriados, sob diferentes formas de alocação e  $AAS_s$ , são dadas por:

$$\widehat{V}_{AE_2(pr)}(\widehat{p}_{es}) = \sum_{h=1}^H W_h \left(1 - \frac{n}{N}\right) \frac{\widehat{p}_h \widehat{q}_h}{n - W_h^{-1}} \quad (5)$$

$$\widehat{V}_{AE_2}(\widehat{p}_{es}) = H \sum_{h=1}^H W_h^2 \left(1 - \frac{n}{HN_h}\right) \frac{\widehat{p}_h \widehat{q}_h}{n - H} \quad (6)$$

# Estimativas

- $\tilde{p} = \sum_{h=1}^H W_h \tilde{p}_h$ , em que  $\tilde{p}_h = \frac{1}{n_h} \sum_{i \in \mathbf{s}_h} y_{hi}$ ,  $\mathbf{s}_h = \{k_{h1}, k_{h2}, \dots, k_{hn_h}\}$ .
- $\tilde{V}_{AE_1}(\hat{p}_{es}) = \sum_{h=1}^H W_h^2 \frac{\tilde{p}_h \tilde{q}_h}{n_h - 1}$ .
- $\tilde{V}_{AE_2}(\hat{p}_{es}) = \sum_{h=1}^H (1 - f_h) W_h^2 \frac{\tilde{p}_h \tilde{q}_h}{n_h - 1}$ .

# Resultados assintóticos

- Novamente, temos que ter  $n_h$  e  $N_h$ ,  $h = 1, 2, \dots, H$  suficientemente grandes.
- Os estimadores  $\hat{p}_{es}$ ,  $(\hat{p}_h, \hat{q}_h)$  são consistentes, respectivamente, para  $p$  e  $p_h, q_h$ .
- Usando resultados anteriores, vem que ( $AAS_c$  e  $AAS_s$ , respectivamente):

$$\frac{\hat{p}_{es} - p}{\sqrt{\sum_{h=1}^H W_h^2 p_h q_h / n_h}} \xrightarrow[\substack{n_h \rightarrow \infty, \\ N_h - n_h \rightarrow \infty, \\ h=1,2,\dots,H}]{D} N(0, 1)$$
$$\frac{\hat{p} - p}{\sqrt{\sum_{h=1}^H (1 - f_h) W_h^2 \frac{N_h}{N_h - 1} p_h q_h / n_h}} \xrightarrow[\substack{n_h \rightarrow \infty, \\ N_h - n_h \rightarrow \infty, \\ h=1,2,\dots,H}]{D} N(0, 1)$$

# Resultados assintóticos

- Além disso, sob  $AAS_c$  e  $AAS_s$ , respectivamente, temos que:

$$\frac{\widehat{p}_{es} - p}{\sqrt{\sum_{h=1}^H W_h^2 \widehat{p}_h \widehat{q}_h / (n_h - 1)}} \xrightarrow[D]{\substack{n_h \rightarrow \infty, \\ N_h - n_h \rightarrow \infty, \\ h=1,2,\dots,H}} N(0, 1)$$

$$\frac{\widehat{p} - p}{\sqrt{\sum_{h=1}^H (1 - f_h) W_h^2 \widehat{p}_h \widehat{q}_h / (n_h - 1)}} \xrightarrow[D]{\substack{n_h \rightarrow \infty, \\ N_h - n_h \rightarrow \infty, \\ h=1,2,\dots,H}} N(0, 1)$$

## Intervalo de Confiança ( $AAS_c$ )

- Assim, dois intervalos de confiança (assintóticos) com coeficiente de confiança de aproximadamente  $\gamma$ , são dados por

$$IC(p, \gamma) \approx \left[ \hat{p}_{es} - z_\gamma \sqrt{\sum_{h=1}^H W_h^2 \frac{\hat{p}_h \hat{q}_h}{n_h - 1}}; \hat{p}_{es} + z_\gamma \sqrt{\sum_{h=1}^H W_h^2 \frac{\hat{p}_h \hat{q}_h}{n_h - 1}} \right] \quad (7)$$

$$IC(p, \gamma) \approx \left[ \hat{p}_{es} - z_\gamma \sqrt{\sum_{h=1}^H W_h^2 \frac{1}{4(n_h - 1)}}; \hat{p}_{es} + z_\gamma \sqrt{\sum_{h=1}^H W_h^2 \frac{1}{4(n_h - 1)}} \right] \quad (8)$$

em que  $P(Z \leq z_\gamma) = \frac{1+\gamma}{2}$  e  $Z \sim N(0, 1)$ .



## Intervalo de Confiança ( $AAS_c$ )

- Erro da estimativa:  $z_\gamma \sqrt{\sum_{h=1}^H W_h^2 \frac{\widehat{p}_h \widehat{q}_h}{n_h - 1}}$  ou  $z_\gamma \sqrt{\sum_{h=1}^H W_h^2 \frac{1}{4(n_h - 1)}}$ .
- O comprimento do intervalo (8) sempre será maior (ou igual) ao comprimento do intervalo (7).

## Intervalo de Confiança ( $AAS_s$ )

- Assim, dois intervalos de confiança (assintóticos) com coeficiente de confiança de aproximadamente  $\gamma$ , são dados por

$$IC(p, \gamma) \approx \left[ \hat{p}_{es} - z_\gamma \sqrt{\sum_{h=1}^H W_h^2 (1 - f_h) \frac{\hat{p}_h \hat{q}_h}{n_h - 1}}; \right. \\ \left. \hat{p}_{es} + z_\gamma \sqrt{\sum_{h=1}^H W_h^2 (1 - f_h) \frac{\hat{p}_h \hat{q}_h}{n_h - 1}} \right] \quad (9)$$

## Intervalo de Confiança ( $AAS_s$ )

$$IC(\mu, \gamma) \approx \left[ \hat{p}_{es} - z_\gamma \sqrt{\sum_{h=1}^H W_h^2 (1 - f_h) \frac{1}{4(n_h - 1)}}; \right. \\ \left. \hat{p}_{es} + z_\gamma \sqrt{\sum_{h=1}^H W_h^2 (1 - f_h) \frac{1}{4(n_h - 1)}} \right] \quad (10)$$

em que  $P(Z \leq z_\gamma) = \frac{1+\gamma}{2}$  e  $Z \sim N(0, 1)$ .

# Intervalo de Confiança ( $AAS_s$ )

- Erro da estimativa:  $z_\gamma \sqrt{\sum_{h=1}^H W_h^2 (1 - f_h) \frac{\hat{p}_h \hat{q}_h}{n_h - 1}}$  ou  $z_\gamma \sqrt{\sum_{h=1}^H W_h^2 (1 - f_h) \frac{1}{4(n_h - 1)}}$ .
- O comprimento do intervalo (10) sempre será maior (ou igual) ao comprimento do intervalo (9).

# Testes de Hipótese ( $AAS_c$ )

- Hipóteses usuais ( $p_0$  conhecido,  $q_0 = 1 - p_0$ )

1  $H_0 : p = p_0$  vs  $H_1 : p < p_0$ .

2  $H_0 : p = p_0$  vs  $H_0 : p > p_0$ .

3  $H_0 : p = p_0$  vs  $H_0 : p \neq p_0$ .

- Estatística do teste  $Z_t = \frac{\hat{p}_{es} - p_0}{\sqrt{\sum_{h=1}^H W_h^2 \frac{\hat{p}_h \hat{q}_h}{n_h - 1}}}$ .

- Sob  $H_0$ , vimos que  $Z_t \approx N(0, 1)$ , para  $n_h$  e  $N_h - n_h$ ,  $h = 1, 2, \dots, H$ , suficientemente grandes.

# Testes de Hipótese ( $AAS_c$ )

- Defina  $z_t = \frac{\tilde{p} - p_0}{\sqrt{\sum_{h=1}^H W_h^2 \frac{\tilde{p}_h \tilde{q}_h}{n_h - 1}}}$  o valor calculado da estatística do teste e  $z_c$  o(s) valor(es) crítico(s).
- Defina ainda  $Z \sim N(0, 1)$ . Os procedimentos são análogos ao caso da média, com as devidas adaptações.

# Testes de Hipótese ( $AAS_s$ )

- Hipóteses usuais ( $p_0$  conhecido,  $q_0 = 1 - p_0$ )

1  $H_0 : p = p_0$  vs  $H_1 : p < p_0$ .

2  $H_0 : p = p_0$  vs  $H_0 : p > p_0$ .

3  $H_0 : p = p_0$  vs  $H_0 : p \neq p_0$ .

- Estatística do teste  $Z_t = \frac{\hat{p}_{es} - p_0}{\sqrt{\sum_{h=1}^H (1 - f_h) W_h^2 \frac{\hat{p}_h \hat{q}_h}{n_h - 1}}}$ .

- Sob  $H_0$ , vimos que  $Z_t \approx N(0, 1)$ , para  $N_h - n_h$ ,  $h = 1, 2, \dots, H$ , suficientemente grandes.

# Testes de Hipótese ( $AAS_s$ )

- Defina  $z_t = \frac{\tilde{p} - p_0}{\sqrt{\sum_{h=1}^H (1-f_h) W_h^2 \frac{\tilde{p}_h \tilde{q}_h}{n_h - 1}}}$  o valor calculado da estatística do teste e  $z_c$  o(s) valor(es) crítico(s).
- Defina ainda  $Z \sim N(0, 1)$ . Os procedimentos são análogos ao caso da média, com as devidas adaptações.



# Determinação do tamanho da amostra

- Devido ao fato de que expressões dos estimadores das variâncias Equações (3), (4), (5) e (6), a obtenção analítica do tamanho da amostra, sob as alocações proporcional e uniforme são bastante complicadas.
- Podemos utilizar as expressões da alocação ótima, dadas em [link](#).

# Determinação do tamanho da amostra

- Uma outra opção é utilizar as expressões das variâncias (1) e (2) e, posteriormente, considerar estimadores para  $p_h$ , ( $q_h$ ), por exemplo, valores relativos ao pior cenário ( $p_h = q_h = \frac{1}{2}$ ,  $h = 1, 2, \dots, H$ ).
- Nesse caso, basta substituir  $p_h$  e  $q_h$ , por  $\hat{p}_h$  e  $\hat{q}_h$ , respectivamente.