

# Amostragem aleatória simples sem reposição (parte 1)

Prof. Caio Azevedo

# Estrutura geral

- Temos uma população de interesse de tamanho  $N$  e desejamos realizar inferências sobre algum parâmetro (média, total, proporção, variância) dessa população, com base em uma amostra de tamanho  $n$ .
- Com algumas adaptações, os resultados a serem vistos poderão ser utilizados mesmo se  $N$  for infinito.
- População: observações univariadas -  $y_1, \dots, y_N$  (variáveis não aleatórias), em que  $y_i$  é a observação relativa ao indivíduo  $i$  (podemos também considerar observações multivariadas). Exemplos: peso, altura, intenção de voto, conhecimento em alguma área.

# Estrutura geral

- Objetivo: estimar  $\mu = \frac{1}{N} \sum_{i=1}^N y_i$  (média, ou proporção se os  $y_i$ 's foram variáveis binárias),  $\tau = \sum_{i=1}^N y_i = N\mu$  (total), variância(s) ( $\sigma^2 = \frac{1}{N} \sum_{i=1}^N (y_i - \mu)^2$ ,  $s^2 = \frac{1}{N-1} \sum_{i=1}^N (y_i - \mu)^2$ ) (esta(s), as vezes, tem de ser estimada(s) para se poder fazer inferência para parâmetros de interesse como a média, total, proporção etc), com base na amostra de tamanho  $n$ , sem reposição.
- Amostragem aleatória simples com reposição ( $AAS_s \equiv A_2$ ).
- Amostra  $\{y_{k_1}, y_{k_2}, \dots, y_{k_n}\}$ , em que  $k_i \in \{1, 2, \dots, N\}$ . Por exemplo, Se  $N = 5$  e  $n = 3$ , podemos ter  $\{y_5, y_2, y_3\}$ .

# Mecanismo de sorteio da amostra

- 1 Dado que os elementos da população estão numerados de 1 a  $N$ , sorteia-se um elemento, segundo algum procedimento de geração de um número aleatório (função “sample”, no R).
- 2 O elemento selecionado é retirado da população.
- 3 Repete-se os procedimentos 1 e 2,  $n-1$  vezes.

# Estimação da média

- Estimador natural (sob duas formas diferentes):

$$\hat{\mu} = \bar{Y} = \frac{1}{n} \sum_{i=1}^n Y_i \quad (1)$$

$$\hat{\mu} = \bar{Y} = \frac{1}{n} \sum_{i=1}^N \Delta_i y_i, \quad (2)$$

em que  $\Delta_i$  é uma v.a. que indica se o elemento  $i$  elemento da população apareceu na amostra, e  $s$  representa a amostra sorteada, ou seja:

$$\Delta_i = \begin{cases} 1, & \text{se o indivíduo } i \text{ foi selecionado} \\ 0, & \text{caso contrário} \end{cases}$$

# Estimação da média

- Utilizar a forma (1) e considerarmos a distribuição das variáveis  $\mathbf{Y} = (Y_1, \dots, Y_n)^t$  (esses desenvolvimentos dependem da distribuição considerada para a amostra). Neste caso,  $Y_i, i = 1, \dots, n$  são variáveis aleatórias. Esta abordagem é vista nos cursos de Inferência Estatística e pode levar a inferências exatas, desde que as suposições sejam válidas. Note que, neste caso, como não há reposição não temos mais que  $Y_i \stackrel{i.i.d}{\sim} D(\theta)$ .

# Estimação da média

- Utilizar a forma (2) e considerarmos a distribuição das variáveis  $\mathbf{F} = (F_1, \dots, F_N)^t$  (mais geral, ou seja, em princípio, os resultados se aplicam, independentemente da distribuição de  $\mathbf{Y}$ ). Neste caso,  $F_i, i = 1, \dots, N$  são variáveis aleatórias ( $y_i, i = 1, 2, \dots, N$  são variáveis não aleatórias). Esta abordagem leva a inferências aproximadas (“n” e “N-n” suficientemente grandes). Uma vantagem é que ela se aplica, em princípio, independentemente da forma da distribuição de  $\mathbf{Y}$ .

# Estimação da média

## ■ Resultados:

1 Note que, nesse caso,  $\Delta_i \equiv F_i$ .

2  $F_i \stackrel{i.i.d.}{\sim} \text{Bernoulli}(n/N)$ . Ou seja,  $P(F_i = f_i) = p^{f_i}(1-p)^{1-f_i} \mathbf{1}_{\{0,1\}}(F_i)$ ,  
 $\mathcal{E}(F_i) = \frac{n}{N}$ ,  $\mathcal{V}(F_i) = \frac{n}{N} \left(1 - \frac{n}{N}\right)$

3  $\text{Cov}(F_i, F_j) = -\frac{n}{N^2} \frac{N-n}{N-1}$

4  $\pi_i = \frac{n}{N}$  (probabilidade do i-ésimo elemento aparecer na amostra).

Prova

$$\pi_i = P(F_i = 1) = \frac{n}{N}.$$

5  $\pi_{ij} = \frac{n}{N} \frac{n-1}{N-1}$  (probabilidade do i-ésimo e j-ésimo elementos aparecerem na amostra).



# Demonstrações

Sob a mesma probabilidade de seleção de cada indivíduo e usando técnicas de contagem, temos que:

$$\begin{aligned}P(F_i = 1) &= \frac{\binom{1}{1} \binom{N-1}{n-1}}{\binom{N}{n}} = \frac{(N-1)!}{(n-1)!(N-n)!} \\ &= \frac{(N-1)!}{N(N-1)!} = \frac{n}{N}\end{aligned}$$

# Demonstrações

Por outro lado, temos que

$$\text{Cov}(F_i, F_j) = \mathcal{E}(F_i F_j) - \mathcal{E}(F_i)\mathcal{E}(F_j)$$

mas

$$\begin{aligned}\mathcal{E}(F_i F_j) &= \sum_{f_i=0}^1 \sum_{f_j=0}^1 f_i f_j P(F_i = f_i, F_j = f_j) \\ &= P(F_i = 1, F_j = 1) = \frac{\binom{2}{2} \binom{N-2}{n-2}}{\binom{N}{n}} \\ &= \frac{\binom{2}{2} \binom{N-2}{n-2}}{\binom{N}{n}} = \frac{\frac{(N-2)!}{(n-2)!(N-n)!}}{\frac{N!}{n!(N-n)!}} = \frac{n(n-1)(n-2)!}{(n-2)!} \frac{(N-2)!}{N(N-1)(N-2)!} \\ &= \frac{n(n-1)}{N(N-1)}\end{aligned}$$

# Demonstrações

Assim

$$\begin{aligned} \text{Cov}(F_i, F_j) &= \frac{n(n-1)}{N(N-1)} - \frac{n}{N} \frac{n}{N} = \frac{n(n-1)}{N(N-1)} - \frac{n^2}{N^2} \\ &= \frac{Nn(n-1) - n^2(N-1)}{N^2(N-1)} = \frac{-n(N-n)}{N^2(N-1)} \end{aligned}$$

# Estimação da média : Propriedades do estimador sob $AAS_s$

## ■ Valor esperado

$$\begin{aligned}\mathcal{E}_{A_2}(\hat{\mu}) &= \frac{1}{n} \mathcal{E}_{A_2} \left( \sum_{i=1}^N F_i y_i \right) = \frac{1}{n} \sum_{i=1}^N \mathcal{E}_{A_2}(F_i) y_i = \frac{1}{n} \sum_{i=1}^N \frac{ny_i}{N} \\ &= \sum_{i=1}^N \frac{y_i}{N} = \mu\end{aligned}$$

# Estimação da média : Propriedades do estimador sob $AAS_s$

## ■ Variância do estimador

$$\begin{aligned} \mathcal{V}_{A_2}(\hat{\mu}) &= \frac{1}{n^2} \mathcal{V} \left( \sum_{i=1}^N F_i y_i \right) \\ &= \frac{1}{n^2} \left( \sum_{i=1}^N y_i^2 \mathcal{V}_{A_2}(F_i) + \sum_{\substack{i \neq j, \\ i, j=1, 2, \dots, N}} \text{Cov}_{A_2}(F_i y_i, F_j y_j) \right) \\ &= \frac{1}{n^2} \left( \sum_{i=1}^N y_i^2 \left[ \frac{n}{N} \left( 1 - \frac{n}{N} \right) \right] - \sum_{\substack{i \neq j, \\ i, j=1, 2, \dots, N}} y_i y_j \frac{n(N-n)}{N^2(N-1)} \right) \\ &= \frac{1}{n^2} \left( \frac{n(N-n)}{N^2} \right) \left( \sum_{i=1}^N y_i^2 - \frac{1}{N-1} \sum_{\substack{i \neq j, \\ i, j=1, 2, \dots, N}} y_i y_j \right) \end{aligned}$$

# Estimação da média : Propriedades do estimador sob $AAS_s$

## ■ Cont.

Lembrando que (Exercício)  $\sum_{i \neq j} y_i y_j = -\sum_{i=1}^N y_i^2 + N^2 \mu^2$  e

$\sum_{i=1}^N (y_i - \mu)^2 = \sum_{i=1}^N y_i^2 - N\mu^2$  (e denotando  $f = \frac{n}{N}$ ), vem que

$$\begin{aligned} \mathcal{V}_{A_2}(\hat{\mu}) &= \frac{1}{n^2} \left( \frac{n(N-n)}{N^2} \right) \left( \sum_{i=1}^N y_i^2 - \frac{1}{N-1} \left( N^2 \mu^2 - \sum_{i=1}^N y_i^2 \right) \right) \\ &= \frac{1}{n} \left( 1 - \frac{n}{N} \right) \frac{1}{N(N-1)} \left( N \sum_{i=1}^N y_i^2 - \sum_{i=1}^n y_i^2 - N^2 \mu^2 + \sum_{i=1}^N y_i^2 \right) \\ &= \frac{1}{n} (1-f) \frac{1}{N(N-1)} \left( N \sum_{i=1}^N y_i^2 - N^2 \mu^2 \right) \\ &= \left( \frac{1-f}{n} \right) \frac{1}{N-1} \left( \sum_{i=1}^N y_i^2 - N\mu^2 \right) = (1-f) \frac{s^2}{n} \end{aligned}$$







# Estimação da média : Propriedades do estimador sob $AAS_s$

- O estimador para a média sob  $AAS_c$  ou  $AAS_s$ , é o mesmo.
- Temos que  $\mathcal{E}_{A_i}(\hat{\mu}) = \mu$ ,  $i = 1, 2$ .
- Além disso,  $\mathcal{V}_{A_1}(\hat{\mu}) = \frac{\sigma^2}{n}$  e  $\mathcal{V}_{A_2}(\hat{\mu}) = (1 - f)\frac{\sigma^2}{n}$ , em que  $f \in (0, 1)$ .
- Portanto, o efeito do planejamento (EPA), do estimador sob o plano  $A_2$  em relação ao plano  $A_1$ , é dado por:

$$EPA = \frac{\mathcal{V}_{A_2}(\hat{\mu})}{\mathcal{V}_{A_1}(\hat{\mu})} \approx (1 - f)$$







- Ademais, quando  $N \rightarrow \infty$ ,  $\mathcal{V}_{A_2}(\hat{\mu}) \rightarrow \mathcal{V}_{A_1}(\hat{\mu})$ .
- Consequentemente, temos que o plano  $AAS_s$  é melhor do que  $AAS_c$ , tendendo ambos a serem equivalentes, à medida que o tamanho da população tende a infinito.

# Comparação dos planos amostrais

















# Comparação dos planos amostrais



# Comparação dos planos amostrais



# Comparação dos planos amostrais



# Estimação da média : Propriedades do estimador sob $AAS_s$

- Resumidamente,  $\mathcal{E}_{A_2}(\hat{\mu}) = \mu$  e  $\mathcal{V}_{A_2}(\hat{\mu}) = (1 - f)\frac{s^2}{n}$ . Podemos provar, sob  $AAS_s$ , que  $\hat{\mu}$  é consistente.
- A distribuição exata é bastante complicada de ser obtida (média de uma combinação linear de um vetor aleatório com distribuição multinomial).
- Distribuição assintótica: note que em  $\{F_i\}_{i \geq 1}$  os  $F_i$ 's são identicamente distribuídos mas não independentes. O TLC padrão não se aplica.
- Estimativa  $\tilde{\mu} = \frac{1}{n} \sum_{i \in s} y_i = \frac{1}{n} \sum_{i=1}^N f_i y_i$ .

# Estimação da média : Propriedades do estimador sob $AAS_s$

- Discutiremos, com mais detalhes (mais a frente), como se obter os resultados assintóticos mas, por enquanto, sob certas condições, entre elas,  $n$  e  $N-n$  suficientemente grandes, temos que

$$\frac{\hat{\mu} - \mu}{\sqrt{(1-f)s^2/n}} \xrightarrow[N \rightarrow \infty]{D} N(0, 1) \quad (4)$$

ou

$\hat{\mu} \approx N(\mu, (1-f)s^2/n)$ , para  $n$  e  $N-n$  suficientemente grandes.

Problema:  $\sigma^2$ , quase sempre, é desconhecido. Faz-se necessário considerar um estimador consistente (de preferência não viciado), para se poder usar o Teorema de Slutsky .

# Estimação da média : Propriedades do estimador sob $AAS_s$

- Vamos considerar o seguinte estimador

$$\hat{s}^2 = \frac{1}{n-1} \sum_{i=1}^n (Y_i - \hat{\mu})^2 = \frac{1}{n-1} \sum_{i=1}^N F_i (y_i - \hat{\mu})^2.$$

Note que (lembrando que  $\sum_{i=1}^N y_i^2 = (N-1)s^2 + N\mu^2$ )

$$\begin{aligned} \mathcal{E}_{A_2}(\hat{s}^2) &= \frac{1}{n-1} \mathcal{E}_{A_2} \left( \sum_{i=1}^n Y_i^2 - n\hat{\mu}^2 \right) \\ &= \frac{1}{n-1} \left[ \mathcal{E}_{A_2} \left( \sum_{i=1}^N y_i^2 F_i \right) - n\mathcal{E}_{A_2}(\hat{\mu}^2) \right] \end{aligned}$$

# Estimação da média : Propriedades do estimador sob $AAS_s$

$$\begin{aligned}\mathcal{E}_{A_2}(\widehat{S}^2) &= \frac{1}{n-1} \left[ \sum_{i=1}^N y_i^2 \mathcal{E}_{A_2}(F_i) - n \mathcal{E}_{A_2}(\widehat{\mu}^2) \right] \\ &= \frac{1}{n-1} \left[ ((N-1)s^2 + N\mu^2) \frac{n}{N} - n \left[ \left(1 - \frac{n}{N}\right) \frac{s^2}{n} + \mu^2 \right] \right] \\ &= \frac{1}{n-1} \left[ ns^2 \left(1 - \frac{1}{N}\right) + n\mu^2 - s^2 + s^2 \frac{n}{N} - n\mu^2 \right] \\ &= \frac{1}{n-1} \left( ns^2 - s^2 - \frac{ns^2}{N} + \frac{s^2 n}{N} \right) = s^2\end{aligned}$$

# Estimação da média : Propriedades do estimador sob $AAS_s$

- A prova de sua consistência, i.e.,

$$\widehat{s}^2 \xrightarrow[n \rightarrow \infty, N-n \rightarrow \infty]{P} s^2 \quad (5)$$

também será discutida mais à frente.

- Portanto, dos resultados (4) e (5), temos que

$$\frac{\widehat{\mu} - \mu}{\sqrt{(1-f)\widehat{s}^2/n}} = \frac{\widehat{\mu} - \mu}{\sqrt{(1-f)s^2/n}} \frac{s}{\widehat{s}} \xrightarrow[n \rightarrow \infty, N-n \rightarrow \infty]{D} N(0,1)$$

por Slutsky.



# Intervalo de Confiança

- Estimativa:  $\hat{s}^2 = \frac{1}{n-1} \sum_{i \in s} (y_i - \tilde{\mu})^2$ .
- Assim, um intervalo de confiança (assintótico) com coeficiente de confiança de aproximadamente  $\gamma$  é dado por

$$IC(\mu, \gamma) \approx \left[ \hat{\mu} - z_\gamma \sqrt{\frac{(1-f)\hat{s}^2}{n}}; \hat{\mu} + z_\gamma \sqrt{\frac{(1-f)\hat{s}^2}{n}} \right]$$

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

- Erro da estimativa:  $z_\gamma \sqrt{(1-f)\frac{\hat{s}^2}{n}}$ .

# Testes de Hipótese

- Hipóteses usuais ( $\mu_0$  conhecido)

- 1  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu < \mu_0$ .

- 2  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu > \mu_0$ .

- 3  $H_0 : \mu = \mu_0$  vs  $H_1 : \mu \neq \mu_0$ .

- Estatística do teste  $Z_t = \frac{\hat{\mu} - \mu_0}{\hat{s} \sqrt{(1-f)/\sqrt{n}}}$ , em que  $\hat{s} = \sqrt{\hat{s}^2}$ .

- Sob  $H_0$ , vimos que  $Z_t \approx N(0, 1)$ , para  $n$  e  $N-n$  suficientemente grandes.

- Defina  $z_t = \frac{\tilde{\mu} - \mu_0}{\tilde{s} \sqrt{(1-f)/\sqrt{n}}}$  o valor calculado da estatística do teste e  $z_c$  o(s) valor(es) crítico(s).

- Defina ainda  $Z \sim N(0, 1)$ .

# Testes de Hipótese

- Procedimento para testar o conjunto de hipóteses [1]
- Valor crítico
  - $P(Z \leq z_c | H_0) = \alpha$ .
  - Se  $z_t \leq z_c$  rejeita-se  $H_0$ , caso contrário, não se rejeita.
- p-valor (nível descritivo)
  - $p - \text{valor} = P(Z \leq z_t | H_0)$

# Testes de Hipótese

- Procedimento para testar o conjunto de hipóteses [2]
- Valor crítico
  - $P(Z \geq z_c | H_0) = \alpha$ .
  - Se  $z_t \geq z_c$  rejeita-se  $H_0$ , caso contrário, não se rejeita.
- p-valor (nível descritivo)
  - $p - \text{valor} = P(Z \geq z_t | H_0)$

# Testes de Hipótese

- Procedimento para testar o conjunto de hipóteses [3]
- Valor crítico
  - $P(Z \leq z_c | H_0) = \frac{1+\alpha}{2}$ .
  - Se  $|z_t| \geq z_c$  rejeita-se  $H_0$ , caso contrário, não se rejeita.
- p-valor (nível descritivo)
  - $p - \text{valor} = 2[1 - P(Z \leq |z_t| | H_0)]$ .

# Estudos de simulação

- Distribuição assintótica do estimador para a média. Tamanho da população  $N = 100000$ .
- Cinco cenários, variando em função da variável de interesse na população ( $X$ ).
  - $X \sim N(800, 10000)$
  - $X \sim \text{gama}(5; 0, 00625)$ ,  $E(X) = 800$ ,  $V(X) = 128000$ .
  - $X \sim t_{(7)}(800, 5000)$ ,  $E(X) = 800$ ,  $V(X) = 7000$ .
  - $X \sim U[400; 1200]$ .
  - $X \sim 0.5N(200, 5000) + 0.5N(600, 5000)$

# Estudos de simulação

- Quatro tamanhos amostrais (30, 50, 100, 1000), em termos percentuais, com relação ao tamanho da população (0,03%,0,05%,0,1%,1%).
- Estudar a distribuição amostral (empírica) com base em  $R = 1000$  réplicas (amostras selecionadas da população de interesse).

# Procedimento para se gerar o gráfico de envelopes (quantil-quantil)

- 1) Simule  $n$  variáveis aleatórias independentes de interesse ( $V_{ij} \stackrel{i.i.d.}{\sim} N(0, 1)$ ). Repita este processo  $m$  vezes.
- 2) Ao final teremos uma matriz com valores simulados dessas variáveis aleatórias, digamos  $V_{ij}$ ,  $i=1, \dots, n$ , (tamanho da amostra)  $j=1, \dots, m$  (réplica).

$$\mathbf{V} = \begin{bmatrix} v_{11} & v_{12} & \dots & v_{1m} \\ v_{21} & v_{22} & \dots & v_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ v_{n1} & v_{n2} & \dots & v_{nm} \end{bmatrix}$$





## Cont.

- 3) Dentro de cada amostra, ordena-se, de modo crescente, os valores simulados, obtendo-se  $v_{(i)j}^*$  (estatísticas de ordem):

$$\mathbf{V}^* = \begin{bmatrix} v_{(1)1} & v_{(1)2} & \dots & v_{(1)m} \\ v_{(2)1} & v_{(2)2} & \dots & v_{(2)m} \\ \vdots & \vdots & \ddots & \vdots \\ v_{(n)1} & v_{(n)2} & \dots & v_{(n)m} \end{bmatrix}$$

- 4) Pode-se obter os limites  $v_{(i)l} = \min_{1 \leq j \leq m} v_{(i)j}$  e  $v_{(i)s} = \max_{1 \leq j \leq m} v_{(i)j}$ ,  
 $i = 1, 2, \dots, n$ .


## Cont.

- 5) Porém, na prática considera-se  $v_{(i)l} = \frac{v_{(i)(2)} + v_{(i)(3)}}{2}$  e  $v_{(i)s} = \frac{v_{(i)(m-2)} + v_{(i)(m-1)}}{2}$  (para se gerar limites de confiança), em que  $v_{(i)(r)}$  é a  $r$ -ésima estatística de ordem dentro de cada linha,  $i = 1, 2, \dots, n$ .





- Além disso, consideramos como a linha de referência

$$v_{(i)} = \frac{1}{m} \sum_{j=1}^m v_{(i)j}, i = 1, 2, \dots, n.$$

# normal




# normal




# normal


**n = 100 , p-valor (teste-KS) = 0.8663**




**n = 100 , p-valor (teste-KS) = 0.8663**




**n = 1000 , p-valor (teste-KS) = 0.9028**



**n = 1000 , p-valor (teste-KS) = 0.9028**




# t de Student




# t de Student


$n = 30$ , p-valor (teste-KS) = 0.1174




$n = 30$ , p-valor (teste-KS) = 0.1174



$n = 50$ , p-valor (teste-KS) = 0.9001




$n = 50$ , p-valor (teste-KS) = 0.9001




# t de Student


$n = 100$ ,  $p$ -valor (teste-KS) = 0.8881




$n = 100$ ,  $p$ -valor (teste-KS) = 0.8881



$n = 1000$ ,  $p$ -valor (teste-KS) = 0.8094




$n = 1000$ ,  $p$ -valor (teste-KS) = 0.8094






# gama




# gama


$n = 30$ ,  $p$ -valor (teste-KS) = 0.89




$n = 30$ ,  $p$ -valor (teste-KS) = 0.89



$n = 50$ ,  $p$ -valor (teste-KS) = 0.1816




$n = 50$ ,  $p$ -valor (teste-KS) = 0.1816




# gama


$n = 100$ ,  $p$ -valor (teste-KS) = 0.8547




$n = 100$ ,  $p$ -valor (teste-KS) = 0.8547




$n = 1000$ ,  $p$ -valor (teste-KS) = 0.7875



$n = 1000$ ,  $p$ -valor (teste-KS) = 0.7875




# uniforme




# uniforme


$n = 30$  ,  $p$ -valor (teste-KS) = 0.5245




$n = 30$  ,  $p$ -valor (teste-KS) = 0.5245



$n = 50$  ,  $p$ -valor (teste-KS) = 0.9058




$n = 50$  ,  $p$ -valor (teste-KS) = 0.9058




# uniforme


$n = 100$ ,  $p$ -valor (teste-KS) = 0.7994




$n = 100$ ,  $p$ -valor (teste-KS) = 0.7994




$n = 1000$ ,  $p$ -valor (teste-KS) = 0.6024



$n = 1000$ ,  $p$ -valor (teste-KS) = 0.6024




# mistura de duas normais




# mistura de duas normais


$n = 30$ , p-valor (teste-KS) = 0.9281




$n = 30$ , p-valor (teste-KS) = 0.9281



$n = 50$ , p-valor (teste-KS) = 0.6123




$n = 50$ , p-valor (teste-KS) = 0.6123






# mistura de duas normais


$n = 100$ ,  $p$ -valor (teste-KS) = 0.9548




$n = 100$ ,  $p$ -valor (teste-KS) = 0.9548



$n = 1000$ ,  $p$ -valor (teste-KS) = 0.3779



$n = 1000$ ,  $p$ -valor (teste-KS) = 0.3779



# Determinação do tamanho amostral

- Estabelece-se algum critério de interesse acerca da acurácia/precisão na estimativa da média populacional.
- Sob o estimador proposto, calcula-se o tamanho da amostra, com base em sua distribuição assintótica e critério estabelecido.
- Erro de estimativa:  $z_\gamma \sqrt{\frac{(1-f)\hat{s}^2}{n}}$ . Fixa-se um erro de estimativa de interesse.
- Probabilidade do módulo da diferença  $P(|\hat{\mu} - \mu| < \delta) > \gamma$ ,  $\delta > 0$ ,  $\gamma \in (0, 1)$ .

## Determinação do tamanho amostral: erro da estimativa

$$\begin{aligned}\delta &= z_\gamma \sqrt{\frac{(1-f)s^2}{n}} \rightarrow \left(\frac{1}{n} - \frac{1}{N}\right) = \frac{\delta^2}{z_\gamma^2 s^2} \rightarrow \frac{1}{n} = \frac{\delta^2}{z_\gamma^2 s^2} + \frac{1}{N} \\ \rightarrow \frac{1}{n} &= \frac{\delta^2 N + z_\gamma^2 s^2}{N z_\gamma^2 s^2} \rightarrow n = \frac{N z_\gamma^2 s^2}{\delta^2 N + z_\gamma^2 s^2} = \frac{1}{\frac{\delta^2}{s^2 z_\gamma^2} + \frac{1}{N}}\end{aligned}$$

Em geral, o (um) valor de  $s^2$  é obtido através de pesquisas anteriores ou de uma amostra piloto, de tamanho apropriado.

## Determinação do tamanho amostral: precisão

$$\begin{aligned}P_{A_1} (|\hat{\mu} - \mu| < \delta) > \gamma &\Leftrightarrow P_{A_1} \left( \left| \frac{\hat{\mu} - \mu}{\sqrt{(1-f)\sigma^2/n}} \right| < \frac{\sqrt{n}\delta}{\sigma} \right) > \gamma \\ &\Leftrightarrow P_{A_1} \left( |Z| < \frac{\sqrt{n}\delta}{\sqrt{1-f}\sigma} \right) > \gamma \Leftrightarrow \frac{\sqrt{n}\delta}{\sqrt{1-f}\sigma} = z_\gamma\end{aligned}$$

em que  $Z \approx N(0, 1)$ . O que leva ao mesmo procedimento oriundo de se fixar o erro da estimativa.

Os tamanhos amostrais, sob os planos amostrais  $A_1$  e  $A_2$  são dados, respectivamente, por  $n_{A_1} = \frac{1}{\frac{\delta^2}{z_\gamma^2 \sigma^2}}$  e  $n_{A_2} = \frac{1}{\frac{\delta^2}{s^2 z_\gamma^2} + \frac{1}{N}}$ . Assim, nota-se que


$$n_{A_1} \geq n_{A_2}.$$

# Tamanhos amostrais


- Situações hipotéticas: cruzamento entre os níveis de diferentes fatores de interesse
  - $\delta \in \{1, 2, 5, 10\}$ .
  - $\gamma \in \{0, 9; 0, 95; 0, 99\}$ .
  - $\sigma^2 \in \{100, 500, 1000, 10000\}$ .

# Tamanhos amostrais


$\sigma^2 = 100, N = 10000$




$\sigma^2 = 500, N = 10000$



$\sigma^2 = 1000, N = 10000$




$\sigma^2 = 10000, N = 10000$




# Tamanhos amostrais


$\sigma^2 = 100$ ,  $N = 50000$




$\sigma^2 = 500$ ,  $N = 50000$



$\sigma^2 = 1000$ ,  $N = 50000$




$\sigma^2 = 10000$ ,  $N = 50000$




# Tamanhos amostrais


$\sigma^2 = 100, N = 1e+05$




$\sigma^2 = 500, N = 1e+05$



$\sigma^2 = 1000, N = 1e+05$




$\sigma^2 = 10000, N = 1e+05$






# Tamanhos amostrais


$\sigma^2 = 100, N = 1e+06$




$\sigma^2 = 500, N = 1e+06$



$\sigma^2 = 1000, N = 1e+06$




$\sigma^2 = 10000, N = 1e+06$




# Comparação dos tamanhos amostrais ( $\gamma = 0,99$ )


$\sigma^2 = 99.99$ ,  $s^2 = 100$ ,  $N = 10000$




$\sigma^2 = 499.95$ ,  $s^2 = 500$ ,  $N = 10000$







$\sigma^2 = 999.9$ ,  $s^2 = 1000$ ,  $N = 10000$



$\sigma^2 = 9999$ ,  $s^2 = 10000$ ,  $N = 10000$




# Comparação dos tamanhos amostrais ( $\gamma = 0,99$ )




# Comparação dos tamanhos amostrais ( $\gamma = 0,99$ )


$\sigma^2 = 99.999$ ,  $s^2 = 100$ ,  $N = 1e+05$




$\sigma^2 = 499.995$ ,  $s^2 = 500$ ,  $N = 1e+05$



$\sigma^2 = 999.99$ ,  $s^2 = 1000$ ,  $N = 1e+05$




$\sigma^2 = 9999.9$ ,  $s^2 = 10000$ ,  $N = 1e+05$




# Comparação dos tamanhos amostrais ( $\gamma = 0,99$ )


$\sigma^2 = 99.9999$ ,  $s^2 = 100$ ,  $N = 1e+06$




$\sigma^2 = 499.9995$ ,  $s^2 = 500$ ,  $N = 1e+06$



$\sigma^2 = 999.999$ ,  $s^2 = 1000$ ,  $N = 1e+06$



$\sigma^2 = 9999.99$ ,  $s^2 = 10000$ ,  $N = 1e+06$



# Estimação do total populacional

- $\tau = \sum_{i=1}^N y_i = N\mu.$
- Estimador “natural”:  $\hat{\tau}_u = \sum_{i=1}^n Y_i.$  Problema: se os  $y_i$ 's foram positivos,  $\hat{\tau}_u$  sempre subestimar $\hat{a}$   $\tau.$
- Alternativa  $\hat{\tau} = N\hat{\mu}.$
- Estimativa  $\tilde{\tau} = N\tilde{\mu}$

# Propriedades do estimador

- $\mathcal{E}_{A_2}(\hat{\tau}) = \mathcal{E}_{A_2}(N\hat{\mu}) = N\mathcal{E}(\hat{\mu}) = N\mu = \tau$  (não viciado).
- $\mathcal{V}_{A_2}(\hat{\tau}) = N^2\mathcal{V}_{A_2}(\hat{\mu}) = N^2(1 - f)\frac{s^2}{n}$  (a imprecisão associada à estimação do total é maior do que aquela associada à média).

# Propriedades do estimador

- Normalidade assintótica, como

$$\frac{\hat{\mu} - \mu}{\sqrt{(1-f)\hat{s}^2/n}} \xrightarrow[N-n \rightarrow \infty]{n \rightarrow \infty, D} N(0, 1),$$

lembrando que  $N$  é fixo, temos que

$$\frac{N\hat{\mu} - N\mu}{\sqrt{N^2(1-f)\hat{s}^2/n}} \xrightarrow[N-n \rightarrow \infty]{n \rightarrow \infty, D} N(0, 1) \rightarrow \frac{\hat{\tau} - \tau}{\sqrt{(1-f)N^2\hat{s}^2/n}} \xrightarrow[N-n \rightarrow \infty]{n \rightarrow \infty, D} N(0, 1)$$



# Intervalo de Confiança

- Assim, um intervalo de confiança (assintótico) com coeficiente de confiança de aproximadamente  $\gamma$  é dado por

$$IC(\mu, \gamma) \approx \left[ \hat{\mu} - z_\gamma N \sqrt{(1-f) \frac{\widehat{S}^2}{n}}; \hat{\mu} + z_\gamma N \sqrt{(1-f) \frac{\widehat{S}^2}{n}} \right]$$

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

- Erro da estimativa:  $z_\gamma N \sqrt{(1-f) \frac{\widehat{S}^2}{n}}$ .

# Testes de Hipótese

- Hipóteses usuais ( $\tau_0$  conhecido)

- 1  $H_0 : \tau = \tau_0$  vs  $H_1 : \tau < \tau_0$ .

- 2  $H_0 : \tau = \tau_0$  vs  $H_0 : \tau > \tau_0$ .

- 3  $H_0 : \tau = \tau_0$  vs  $H_0 : \tau \neq \tau_0$ .

- Estatística do teste  $Z_t = \frac{\hat{\tau} - \tau_0}{N\sqrt{(1-f)\hat{s}/\sqrt{n}}}$ , em que  $\hat{s} = \sqrt{\hat{S}^2}$ .

- Sob  $H_0$ , vimos que  $Z_t \approx N(0, 1)$ , para  $n$  e  $N-n$  suficientemente grandes.

- Defina  $z_t = \frac{\tilde{\tau} - \tau_0}{N\sqrt{(1-f)\tilde{s}/\sqrt{n}}}$  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 amostral: erro da estimativa

$$\begin{aligned}\delta &= z_\gamma \sqrt{\frac{(1-f)s^2 N^2}{n}} \rightarrow \left(\frac{1}{n} - \frac{1}{N}\right) = \frac{\delta^2}{z_\gamma^2 s^2 N^2} \rightarrow \frac{1}{n} = \frac{\delta^2}{z_\gamma^2 s^2 N^2} + \frac{1}{N} \\ \rightarrow \frac{1}{n} &= \frac{\delta^2 + z_\gamma^2 s^2 N}{z_\gamma^2 s^2 N^2} \rightarrow n = \frac{z_\gamma^2 s^2 N^2}{\delta^2 + z_\gamma^2 s^2 N} = \frac{1}{\frac{\delta^2}{N^2 s^2 z_\gamma^2} + \frac{1}{N}}\end{aligned}$$

Em geral, o (um) valor de  $s^2$  é obtido através de pesquisas anteriores ou de uma amostra piloto, de tamanho apropriado. Isto vale para qualquer um dos dois critérios: erro da estimativa e precisão.