

## Estimação de uma razão

Até aqui tem-se considerado a estimação de uma **única característica da população** --- usando uma **amostragem aleatória simples sem reposição**.

Mas, muitas vezes pretende-se obter informação sobre várias características --- recolhem-se dados multivariados.

Considere-se o **caso bivariado**, que permite nalgumas circunstâncias aproveitar a estrutura de correlação para melhorar os estimadores.

Consideremos a amostra aleatória constituída por **n pares** de valores  $(X_i, Y_i)$  obtida por amostragem aleatória simples.

Suponhamos que, para a população de N indivíduos pretendemos estimar a razão

$$R = X_T / Y_T = \mu_X / \mu_Y.$$

Para isso dispomos então de uma amostra com os valores  $(x_1, y_1) \dots (x_n, y_n)$

sendo o **estimador de  $R$**  mais usado

$$R^* = \bar{X} / \bar{Y}$$

Prova-se que, no caso de grandes amostras,  $R^*$  é assintoticamente normal com valor médio e variância assintóticos assim definidos:

$$E[R^*] \cong R = \mu_X / \mu_Y;$$

$$Var[R^*] \cong \frac{1-f}{n\bar{y}^2} \sum_1^N \frac{(X_i - RY_i)^2}{N-1} = \frac{1-f}{n\bar{y}^2} [\sigma_X^2 - 2R\sigma_{XY} + R^2\sigma_Y^2]$$

Uma estimativa de  $\text{Var}[R^*]$  é

$$s'^2[R^*] = \frac{1-f}{n\bar{y}^2} \sum_1^n \frac{(x_i - r^* y_i)^2}{n-1}$$

$$r^* = \bar{x}/\bar{y}$$

Para grandes amostras um intervalo a  $(1-\alpha)100\%$  de confiança para  $R$  é

$$r^* - z_{\alpha/2} s'(R^*) < R < r^* + z_{\alpha/2} s'(R^*)$$

Acontece por vezes que ao estudarmos duas características para cada unidade de amostragem, para uma delas é **conhecido o total dos valores** dessa característica.

Seja então  $R = X_T/Y_T = \mu_X/\mu_Y$  e suponhamos que  $Y_T$  é conhecido.

Neste caso é possível estimar o valor médio,  $\mu_X$

$\mu_X = R\mu_Y$ , usando o **estimador de razão**, assim definido

$$\bar{X}_R = \frac{\bar{X}}{\bar{Y}} \mu_Y = R^* \mu_Y$$

O estimador  $\bar{X}_R$  é assintoticamente centrado e para grandes amostras tem-se

$$\text{Var}[\bar{X}_R] \cong \frac{1-f}{n} \sum_1^N \frac{(X_i - RY_i)^2}{N-1} = \frac{1-f}{n} [\sigma_X^2 - 2R\sigma_{XY} + R^2\sigma_Y^2]$$

**Uma pergunta natural:**

**--Em que circunstâncias será o estimador da razão preferível ao estimador habitual da média?**

**Isto é**

**Será  $\bar{X}_R$  mais ou menos eficiente do que  $\bar{X}$  ?**

Em que condições  $\text{Var}[\bar{X}_R] < \text{Var}[\bar{X}]$ ?

Ora tem-se

$$\frac{1-f}{n} [\sigma'_X{}^2 - 2R\sigma'_{XY} + R^2\sigma'_Y{}^2] < \frac{1-f}{n} \sigma'_X{}^2$$

⇓

$$2R\rho\sigma'_X\sigma'_Y > R^2\sigma'_Y{}^2$$

⇓

$$\rho > \frac{R\sigma'_Y}{2\sigma'_X} \Rightarrow \rho > \frac{1}{2} \frac{CV_Y}{CV_X},$$

onde  $CV$  designa coeficiente de variação .

Notas finais:

- O estimador da razão  $\bar{X}_R$  resulta num estimador mais eficiente se  $\rho_{XY}$  for suficientemente elevado, mas...
- ... se  $CV_Y > 2CV_X$ , então o ganho na eficiência só se verificava se  $\rho_{XY} > 1$  (isto não pode ser pois não ???!!!!).

Portanto, nestas condições mesmo existindo uma relação linear perfeita entre X e Y,  $\bar{X}_R$  não pode ser mais eficiente do que  $\bar{X}$

### Dois factores importantes para o aumento da eficiência dos estimadores da razão

- a variabilidade da variável Y não pode ser muito maior que a de X
- o coeficiente de correlação  $\rho_{XY}$  tem que ser positivo e elevado

## Amostragem Estratificada

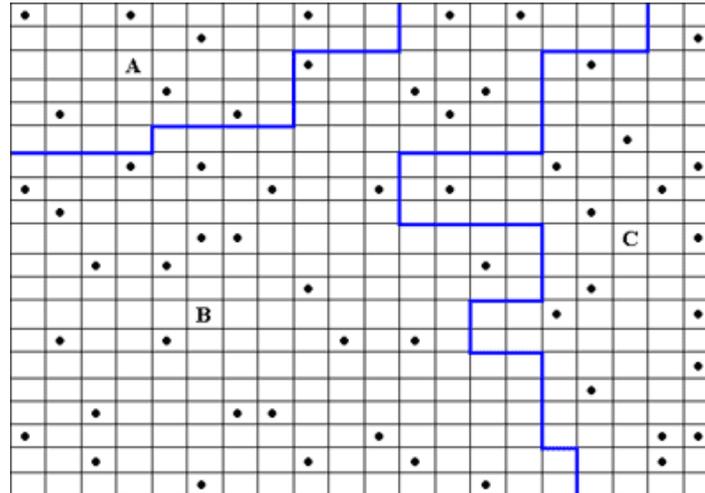
### Exemplo

Suponhamos que se divide uma região em tipos (ou classes) de arbustos para se estudar uma dada característica desses arbustos.

### Qual a vantagem?

Veremos que desta forma se pode ter estimativas mais precisas do valor médio da população do que ao usar a amostragem aleatória simples. Há também vantagem em dirigir o estudo para cada subpopulação ou estrato – modos diferentes de lidar com cada tipo de arbusto....

-- também pode haver questões de custos envolvidos...



## Amostragem Estratificada – conceitos

População dividida em subpopulações ou **estratos**.

São várias as **razões** que levam a estratificar a população:

- oferece maior garantia de representatividade;
- permite obter estimativas com uma dada precisão para a variável de interesse em cada estrato;
- permite resolver os problemas inerentes a cada estrato e que podem diferir de estrato para estrato;
- a estratificação permite um aumento de precisão nas estimativas; essa precisão é tanto maior quanto mais homogêneos forem os estratos;
- conveniências administrativas de organização do trabalho de recolha da informação.

População finita com  $N$  indivíduos

$a_1, \dots, a_N$  os valores de uma dada característica para aqueles indivíduos.

População é dividida em  $k$  grupos ou **estratos** de dimensões conhecidas:  
 $N_1, \dots, N_k$  ( $\sum N_i = N$ )

Estrato	dimensão	elementos	valor médio	variância
$S_1$	$N_1$	$a_{11}a_{12} \cdots a_{1N_1}$	$\mu_1$	$\sigma_1^2$
$S_2$	$N_2$	$a_{21}a_{22} \cdots a_{2N_2}$	$\mu_2$	$\sigma_2^2$
$\vdots$	$\vdots$	$\vdots$	$\vdots$	$\vdots$
$S_k$	$N_k$	$a_{k1}a_{k2} \cdots a_{kN_k}$	$\mu_k$	$\sigma_k^2$

$$N = \sum_{i=1}^k N_i$$

**Valor médio**

$$\mu = \frac{1}{N} \sum_{i=1}^k N_i \mu_i = \sum_{i=1}^k W_i \mu_i$$

**Variância da população**

$$\sigma'^2 = \frac{1}{N-1} \left\{ \sum_1^k (N_i - 1) \sigma_i'^2 + \sum_1^k N_i (\mu_i - \mu)^2 \right\}$$

onde  $W_i = N_i/N$  é o “peso” em cada estrato.

De facto tem-se

$$\begin{aligned} \sigma'^2 &= \frac{1}{N-1} \sum_{i,j} (a_{ij} - \mu)^2 = \frac{1}{N-1} \sum_{i=1}^k \sum_{j=1}^{N_i} (a_{ij} - \mu)^2 = \frac{1}{N-1} \sum_i \left[ \sum_{j=1}^{N_i} (a_{ij} - \mu_i + \mu_i - \mu)^2 \right] \\ &= \frac{1}{N-1} \sum_i \left[ \sum_{j=1}^{N_i} (a_{ij} - \mu_i)^2 + N_i (\mu_i - \mu)^2 + 2(\mu_i - \mu) \underbrace{\sum_{j=1}^{N_i} (a_{ij} - \mu_i)}_{=0} \right] \end{aligned}$$

$$\sigma'^2 = \frac{1}{N-1} \left[ \sum_{i=1}^k (N_i - 1) \sigma_i'^2 + \sum_{i=1}^k N_i (\mu_i - \mu)^2 \right].$$

Para cada estrato  $i$  tem-se

$$\mu_i = \frac{1}{N_i} \sum_{j=1}^{N_i} a_{ij} \quad \text{e} \quad \sigma_i^2 = \frac{1}{N_i - 1} \sum_{j=1}^{N_i} (a_{ij} - \mu_i)^2$$

A **amostragem aleatória estratificada** consiste em **tirar de cada estrato** uma amostra aleatória de tamanho pré-fixado:

$$n_1, n_2, \dots, n_k \quad \left( \sum_i^k n_i = n \right)$$

tendo como elementos em cada estrato  $i$

$$x_{i1}, x_{i2}, \dots, x_{in_i}$$

A média e a variância do i-ésimo estrato são:

$$\bar{x}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} x_{ij} \quad \text{e} \quad s_i'^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_i)^2$$

A  $f_i = \frac{n_i}{N_i}$  chama-se fracção de amostragem em cada estrato.

Há dois problemas que se colocam neste tipo de amostragem:

- 1- Como se divide a população em estratos.
- 2- Qual o número de elementos a escolher em cada estrato? Afectação.

Destes dois problemas o mais simples é o segundo e é esse que começaremos a tratar.

Fixada a **dimensão da amostra a recolher**, seja  $n$ , um dos modos que à primeira vista parece mais razoável consiste em seleccionar em cada estrato um número de elementos proporcional à dimensão do estrato, i.e.,

$$\frac{n_i}{n} = \frac{N_i}{N} \quad \text{donde} \quad n_i = n \frac{N_i}{N}$$

Verifica-se portanto que

$$f_i = \frac{n_i}{N_i} = \frac{n}{N}$$

É habitual designar esta afectação por **afecção proporcional**.

## Estimação do valor médio

O estimador do valor médio é a média empírica estratificada assim definida

$$\bar{X}_{st} = \sum_{i=1}^k W_i \bar{X}_i = \sum_{i=1}^k \frac{N_i \bar{X}_i}{N}$$

A média empírica estratificada  $\neq$  média aritmética,

$$\bar{X}_{st} = \sum_{i=1}^k W_i \bar{X}_i = \sum_{i=1}^k \frac{N_i \bar{X}_i}{N} \neq \bar{X}' = \sum_{i=1}^k \frac{n_i \bar{X}_i}{n}$$

O primeiro é um **estimador centrado**, enquanto o segundo não é.

$$E[\bar{X}_{st}] = \sum_{i=1}^k W_i \mu_i = \mu \quad \text{enquanto} \quad E[\bar{X}'] = \frac{1}{n} \sum_{i=1}^k n_i \mu_i \neq \mu$$

$\bar{X}'$  só será **estimador centrado** se  $\frac{n_i}{n} = \frac{N_i}{N}$ , ou seja, no caso da **afecção ser proporcional**.

Vejam agora

$$Var[\bar{X}_{st}] = \sum_1^k W_i^2 (1 - f_i) \sigma_i^2 / n_i$$

Visto

$$Var[\bar{X}_{st}] = \sum_1^k W_i^2 Var(\bar{X}_i), \text{ pois } Cov(\bar{X}_i, \bar{X}_j) = 0.$$

**Observação:**

Vimos que no **caso da afecção proporcional**  $\bar{X}_{st}$  e  $\bar{X}'$  coincidem, no entanto estes dois estimadores **não apresentam a mesma variância**. Efectivamente

$$\text{Var}[\bar{X}'] = \frac{1}{n^2} \sum_1^k n_i (1 - f_i) \sigma_i'^2.$$

Vejam **várias expressões** para a variância, em certos **casos particulares**:

1. Se  $f_i = \frac{n_i}{N_i}$  for desprezável  $\text{Var}[\bar{X}_{st}] = \sum_1^k W_i^2 \sigma_i'^2 / n_i$  ;

2. Se  $w_i = \frac{n_i}{n} = \frac{N_i}{N}$  -- afectação proporcional  $\text{Var}[\bar{X}_{st}] = \frac{1-f}{n} \sum_1^k W_i \sigma_i'^2$  ;

3. Se a amostragem é proporcional e a variância é constante , i.e.,  $\sigma_i'^2 = \sigma^2$ , então

$$\text{Var}[\bar{X}_{st}] = \frac{1-f}{n} \sigma^2.$$

## Estimação do Total da População

Um estimador centrado para o total  $x_T$  da população é

$$X_T^* = N \bar{X}_{st} = \sum_1^k N_i \bar{X}_i$$

Facilmente se verifica que se trata de um **estimador centrado**, sendo a sua variância dada por

$$Var[X_T^*] = \sum_1^k N_i^2 (1 - f_i) \sigma_i^2 / n_i$$

## Intervalos de Confiança

Um intervalo de confiança para  $\mu$  a  $(1-\alpha)100\%$  é

$$\bar{x}_{st} - z_{\alpha/2} s'(\bar{x}_{st}) < \mu < \bar{x}_{st} + z_{\alpha/2} s'(\bar{x}_{st})$$

e um intervalo de confiança para  $X_T$  a  $(1-\alpha)100\%$  é

$$N\bar{x}_{st} - z_{\alpha/2} Ns'(\bar{x}_{st}) < X_T < N\bar{x}_{st} + z_{\alpha/2} Ns'(\bar{x}_{st})$$

Se em cada estrato são recolhidas poucas observações o procedimento usual consiste em considerar  $t_{\alpha/2}$  em vez de  $z_{\alpha/2}$ , sendo o número de graus de liberdade dado por

$$n = \frac{\left( \sum_{i=1}^k g_i s_i'^2 \right)^2}{\sum_{i=1}^k g_i^2 s_i'^4 / (n_i - 1)} \quad \text{com} \quad g_i = \frac{N_i (N_i - n_i)}{n_i}$$

**Observação: Vejamos em que condições a amostragem estratificada é preferível à amostragem aleatória simples, i.e, em que condições**

$$\text{Var}[\bar{X}_{st}] < \text{Var}[\bar{X}]$$

Temos:

$$\text{Var}[\bar{X}] = (1 - f) \frac{\sigma^2}{n} \quad \text{e}$$

$$\text{Var}[\bar{X}_{st}] = \sum_{i=1}^k W_i^2 (1 - f_i) \frac{\sigma_i^2}{n_i} .$$

Numa primeira fase consideremos que estamos no caso de afecção proporcional,

$$f_i = f$$

$$\text{Var}[\bar{X}_{st}] = \frac{(1-f)}{n} \sum_{i=1}^k \frac{N_i}{N} \sigma_i'^2 \qquad \text{Var}[\bar{X}] - \text{Var}[\bar{X}_{st}] = \frac{1-f}{n} \left( \sigma'^2 - \frac{1}{N} \sum_{i=1}^k N_i \sigma_i'^2 \right)$$

vimos porém que

$$\sigma'^2 = \frac{1}{N-1} \left( \sum_{i=1}^k (N_i - 1) \sigma_i'^2 + \sum_{i=1}^k N_i (\mu_i - \mu)^2 \right)$$

Se o tamanho dos estratos é grande

$$\boxed{\frac{N_i - 1}{N - 1} = \frac{N_i}{N} = \frac{N_i}{N - 1}} \quad (*)$$

donde  $\sigma'^2 = \frac{1}{N} \left( \sum_{i=1}^k N_i \sigma_i'^2 + \sum_{i=1}^k N_i (\mu_i - \mu)^2 \right)$

$$\Rightarrow \text{Var}[\bar{X}] - \text{Var}[\bar{X}_{st}] = \frac{1-f}{Nn} \sum_{i=1}^k N_i (\mu_i - \mu)^2 = \frac{1-f}{n} \sum_{i=1}^k W_i (\mu_i - \mu)^2 > 0$$

excepto se  $\mu_i$  todos iguais.

**Conclusão:** o **estimador da média na amostragem estratificada** será sempre **mais eficiente** do que o **estimador da média na amostragem aleatória simples**, ou melhor, é tanto mais eficiente quanto maior for a variação nas médias dos estratos.

Porém, se acontece que os estratos não são suficientemente grandes que permitam que se verifique (\*), deve considerar-se

$$\sigma'^2 = \frac{1}{N-1} \left( \sum_{i=1}^k (N_i - 1) \sigma_i'^2 + \sum_{i=1}^k N_i (\mu_i - \mu)^2 \right)$$
$$\Rightarrow \text{Var}[\bar{X}] - \text{Var}[\bar{X}_{st}] = \frac{1-f}{n(N-1)} \left[ \sum_{i=1}^k N_i (\mu_i - \mu)^2 - \frac{1}{N} \sum_{i=1}^k (N - N_i) \sigma_i'^2 \right]$$

Sendo assim, podemos dizer que

$\bar{X}_{st}$  é mais eficiente do que  $\bar{X}$  se

$$\sum_{i=1}^k N_i (\mu_i - \mu)^2 > \frac{1}{N} \sum_{i=1}^k (N - N_i) \sigma_i'^2$$

Informalmente pode dizer-se que **quanto maior for a variabilidade entre os estratos e menor for a variabilidade dentro de cada estrato**, maior será o ganho potencial ao considerar a amostra estratificada para estimar a média populacional.

## **Escolha óptima do tamanho da amostra a recolher em cada estrato**

### **Objectivo:**

Saber como escolher a dimensão da amostra de modo a **satisfazer uma certa precisão ou um certo custo** .

Suponhamos que no processo de amostragem há:

$C_0$  --- custo base da amostragem;

$C_i$  --- custo de cada observação individual no estrato  $i$ .

**Custo total**  $C_T$  é dado por  $C_T = C_0 + \sum_1^k n_i c_i$ .

Que valores escolher para  $n_1, n_2, \dots, n_k$  de modo a:

**a)** minimizar  $Var(\bar{X}_{st})$ , para um custo total  $C_T$ ;

**b)** minimizar o custo total, para um dado valor de  $Var(\bar{X}_{st})$ .

**a) Variância mínima para custo fixo.**

Pretendemos determinar  $n_1, n_2, \dots, n_k$  que minimize

$$\text{Var}[\bar{X}_{st}] = \sum_{i=1}^k W_i^2 \frac{\sigma_i'^2}{n_i} - \frac{1}{N} \sum_{i=1}^k W_i \sigma_i'^2 \quad \text{sujeito a} \quad \sum_{i=1}^k c_i n_i = C_T - c_0$$

Usando o método dos multiplicadores de Lagrange, temos a *Lagrangeana* assim definida

$$L = \sum_{i=1}^k W_i^2 \frac{\sigma_i'^2}{n_i} - \frac{1}{N} \sum_{i=1}^k W_i \sigma_i'^2 + \lambda \left( \sum_{i=1}^k c_i n_i - C_T + c_0 \right)$$

Para se minimizar esta função teremos

$$\frac{\partial \mathcal{L}}{\partial n_i} = -\sum_{i=1}^k W_i^2 \frac{\sigma_i'^2}{n_i^2} - \lambda \sum_{i=1}^k c_i = 0$$

$$\frac{\partial \mathcal{L}}{\partial \lambda} = \sum_{i=1}^k c_i n_i - C_T + c_0 = 0$$

Da primeira equação tem-se

$$-\sum_{i=1}^k \left( W_i^2 \frac{\sigma_i'^2}{n_i^2} - \lambda c_i \right) = 0$$

onde para cada parcela se tem

$$n_i \sqrt{\lambda} = \frac{W_i \sigma_i'}{\sqrt{c_i}},$$

que multiplicando por  $C_i$ , dá  $c_i n_i \sqrt{\lambda} = \sqrt{c_i} W_i \sigma'_i$   
 e efectuando a soma ao longo de todas os estratos:

$$(C_T - c_0) \sqrt{\lambda} = \sum_{i=1}^k \sqrt{c_i} W_i \sigma'_i \Rightarrow \sqrt{\lambda} = \frac{\sum_{i=1}^k \sqrt{c_i} W_i \sigma'_i}{C_T - c_0}$$

e dado que  $n_i = \frac{W_i \sigma'_i}{\sqrt{c_i \lambda}}$  tem-se

$$n_i = \frac{(C_T - c_0) W_i \sigma'_i / \sqrt{c_i}}{\sum_{i=1}^k W_i \sigma'_i \sqrt{c_i}},$$

**Esta é a dimensão óptima da amostra a recolher em cada estrato para um custo total fixo.**

## Observações:

- As dimensões das amostras em cada estrato devem ser:
- proporcionais ao tamanho do estrato e ao desvio padrão do estrato e
- inversamente proporcionais à raiz quadrado do preço unitário de amostragem em cada estrato.

A **dimensão total** da amostra a recolher é

$$n = \frac{(C_T - c_0) \sum_{i=1}^k W_i \sigma_i' / \sqrt{c_i}}{\sum_{i=1}^k W_i \sigma_i' \sqrt{c_i}}$$

## Caso particular

Se os custos  $c_i$  são os mesmos para todos os estratos tem-se

$C_T = c_0 + nc$  onde  $c$  é o custo unitário de amostragem (constante), donde

$$n_i = n \frac{W_i \sigma'_i}{\sum_{i=1}^k W_i \sigma'_i} \quad \text{com} \quad n = \frac{C_T - c_0}{c}$$

esta é a **dimensão óptima**, para  $n$  fixo.

Chama-se a esta afectação, **afectação de Neymann** ou **afectação óptima**, tendo então como variância mínima

$$Var_{\min} [\bar{X}_{st}] = \frac{1}{n} \left( \sum_i^k W_i \sigma'_i \right)^2 - \frac{1}{N} \sum_{i=1}^k W_i \sigma_i'^2.$$

## **b) Custo mínimo para variância fixa**

Consideremos  $Var[\bar{X}_{st}] = V$

**--- qual a dimensão da amostra a recolher em cada estrato de modo a termos um custo mínimo?**

Do que vimos atrás sabemos que  $Var[\bar{X}_{st}]$  é minimizada quando os  $n_i$  são escolhidos proporcionalmente a  $W_i \sigma'_i / \sqrt{c_i}$ .

Para um dado  $V$  deverá haver um custo mínimo para o qual a afectação permitirá obter  $V$  como a variância mínima. Sendo assim a escolha dos  $n_i$  será aquela que satisfazendo a proporcionalidade acima referida, minimize o custo total, para um dado valor de  $Var[\bar{X}_{st}]$ , isto é,

$$n_i = k \frac{W_i \sigma'_i}{\sqrt{c_i}}$$

onde  $k$  deve ser escolhido de modo a assegurar que

$$\text{Var}[\bar{X}_{st}] = \sum_{i=1}^k W_i^2 \frac{\sigma_i'^2}{n_i} - \frac{1}{N} \sum_{i=1}^k W_i \sigma_i'^2 = V$$

Sendo assim deve tomar-se

$$n_i = \left\{ \frac{\sum_{i=1}^k W_i \sigma'_i \sqrt{c_i}}{V + \frac{1}{N} \sum_{i=1}^k W_i \sigma_i'^2} \right\} W_i \sigma'_i / \sqrt{c_i}$$

## Mais uma Nota

No caso de **pretendermos uma afectação proporcional**, isto é, se  $n_i = n \frac{N_i}{N}$ , que **valor de  $n$**  se deve considerar?

Nalguns casos é pre-fixado;

caso contrário, sendo  **$d$ , o erro absoluto**, considera-se

$$n_0 \cong \frac{4 \sum W_i \sigma_i'^2}{d^2} \quad \text{se } \alpha = 0.05$$

caso a população seja finita, deve considerar-se a correcção

$$n = \frac{n_0}{1 + n_0 / N} \quad .$$

## Estimação de Proporções

Seja  $P$  a proporção dos indivíduos na população, verificando uma dada característica,  $A$

Definindo, como fizemos na amostragem aleatória simples, as variáveis aleatórias  $Y_i$  como

$$Y_i = \begin{cases} 1 & \text{se o elemento } i \text{ verifica } A \\ 0 & \text{se o elemento } i \text{ não verifica } A \end{cases}$$

Seja

$$Y_T = \sum_{i=1}^N Y_i \quad \text{donde} \quad P = \frac{\sum_{i=1}^N Y_i}{N}$$

Como **estimador de  $P$**  tem sentido considerar

$$\bar{Y}_{st} = \sum_{i=1}^k \frac{N_i}{N} \bar{Y}_i = \sum_{i=1}^k W_i \hat{P}_i = \hat{P}_{st}$$

onde  $\bar{Y}_i = \hat{P}_i$  designa a proporção de indivíduos no estrato  $i$ , incluídos na amostra e verificando A. O estimador de  $P$  é tal que

$$E[\hat{P}_{st}] = P$$

$$Var[\hat{P}_{st}] = \sum_{i=1}^k \frac{W_i^2}{n_i} \left( \frac{N_i - n_i}{N_i - 1} \right) P_i (1 - P_i) \quad (\text{comparar com slide 42})$$

Um **estimador desta variância** é :

$$Var\hat{P}_{st} = S'^2[\hat{P}_{st}] = \sum_{i=1}^k \frac{W_i^2}{n_i - 1} \left( \frac{N_i - n_i}{N_i - 1} \right) \hat{P}_i (1 - \hat{P}_i)$$

Se  $N_i$  grande tem-se

$$\text{Var}[\hat{P}_{st}] = \sum \frac{W_i^2}{n_i} (1 - f_i) P_i (1 - P_i)$$

Se estamos numa situação de afectação proporcional, isto é, se  $\frac{n_i}{N_i} = \frac{n}{N}$  tem-se

$$\text{Var}[\hat{P}_{st}] = \frac{N-n}{n} \sum \frac{W_i^2}{N_i - 1} P_i (1 - P_i) \cong \frac{1-f}{n} \sum W_i P_i (1 - P_i).$$

### **Dimensão da amostra em cada estrato de modo a minimizar a variância com custo fixo**

No caso de  $C_T = c_0 + \sum c_i n_i$ , tem-se a dimensão da amostra a recolher em cada estrato

$$n_i = \frac{(C_T - c_0)W_i\sqrt{P_iQ_i/c_i}}{\sum W_i\sqrt{P_iQ_i}c_i}$$

**Dimensão total da amostra**

$$n = \sum n_i = \frac{(C_T - c_0)\sum_{i=1}^k W_i\sqrt{P_iQ_i/c_i}}{\sum W_i\sqrt{P_iQ_i}c_i}$$

Se considerarmos a **afecção de Neyman**, com  $n$  fixo ignorando custos tem-se

$$n_i = \frac{nW_i\sqrt{P_iQ_i}}{\sum W_i\sqrt{P_iQ_i}}$$