

Viés do Estimador Razão

Teorema 5.1. Para um plano amostral com $E(\bar{x}) = \mu_X$ e $E(\bar{y}) = \mu_Y$, tem-se que para n suficientemente grande

$$E(\hat{R}) = \frac{\bar{y}}{\bar{x}} \approx R = \frac{\mu_Y}{\mu_X}$$

Demonstração (Rocha, F.M.M.)

$$\hat{R} - R = \frac{\bar{y}}{\bar{x}} - R = \frac{\bar{y} - R\bar{x}}{\bar{x}} = f(\bar{x})(\bar{y} - R\bar{x}), \quad (1)$$

com $f(\bar{x}) = \frac{1}{\bar{x}}$.

O cálculo da esperança fica mais difícil por termos uma variável aleatória \bar{x} no denominador.

Expansão em séries de Taylor de $f(x)$ em torno de a :

$$f(x) = f(a)(x-a)^0 + \frac{f'(a)(x-a)^1}{1!} + \frac{f''(a)(x-a)^2}{2!} + \frac{f'''(a)(x-a)^3}{3!} + \dots \quad (2)$$

Então, expandindo $f(\bar{x}) = \frac{1}{\bar{x}}$ em torno de $a = \mu_X$, temos:

$$f(\bar{x}) = \frac{1}{\bar{x}} \implies f(\mu_X) = \frac{1}{\mu_X}$$

$$f'(\bar{x}) = -\frac{1}{\bar{x}^2} \implies f'(\mu_X) = -\frac{1}{\mu_X^2}$$

$$f''(\bar{x}) = +2\frac{1}{\bar{x}^3} \implies f''(\mu_X) = \frac{2}{\mu_X^3}$$

$$f'''(\bar{x}) = -6\frac{1}{\bar{x}^4} \implies f'''(\mu_X) = -\frac{6}{\mu_X^4}$$

Expansão de $f(\bar{x}) = \frac{1}{\bar{x}}$ em torno de $a = \mu_X$:

$$\begin{aligned} f(\bar{x}) &= f(\mu_X) + f'(\mu_X)(\bar{x} - \mu_X) + \frac{f''(\mu_X)(\bar{x} - \mu_X)^2}{2} + \frac{f'''(\mu_X)(\bar{x} - \mu_X)^3}{3!} + \dots = \\ &= \frac{1}{\mu_X} - \frac{1}{\mu_X^2}(\bar{x} - \mu_X) + \frac{1}{\mu_X^3}(\bar{x} - \mu_X)^2 - \frac{1}{\mu_X^4}(\bar{x} - \mu_X)^3 + \dots \end{aligned}$$

$$\hat{R} - R = \frac{\bar{y}}{\bar{x}} - R = \frac{\bar{y} - R\bar{x}}{\bar{x}} = f(\bar{x})(\bar{y} - R\bar{x}) = \frac{\bar{y} - R\bar{x}}{\mu_X} - \frac{(\bar{y} - R\bar{x})(\bar{x} - \mu_X)}{\mu_X^2} + \dots$$

Calcula a esperança usando a aproximação de primeira ordem,

$$E(\hat{R} - R) \approx E\left(\frac{\bar{y} - R\bar{x}}{\mu_X}\right) = \frac{\mu_Y - R\mu_X}{\mu_X} = 0,$$

Viés

Para plano AAS (AASc ou AASSs), temos:

$$\begin{aligned}
E(\hat{R} - R) &\approx E \left(\frac{\bar{y} - R\bar{x}}{\mu_X} - \frac{(\bar{y} - R\bar{x})(\bar{x} - \mu_X)}{\mu_X^2} \right) \\
&= 0 + \frac{1}{\mu_X^2} \{R E[\bar{x}(\bar{x} - \mu_X)] - E[\bar{y}(\bar{x} - \mu_X)]\} \\
&= \frac{1}{\mu_X^2} \{R E[(\bar{x} - \mu_X)(\bar{x} - \mu_X)] - E[(\bar{y} - \mu_Y)(\bar{x} - \mu_X)]\} \\
&= \frac{1}{\mu_X^2} \{R Var(\bar{x}) - Cov(\bar{x}, \bar{y})\} \\
&= R \frac{Var(\bar{x})}{\mu_X^2} - \rho[\bar{x}, \bar{y}] \frac{DP(\bar{x})DP(\bar{y})}{\mu_X^2} \\
&= R CV^2(\bar{x}) - \rho[\bar{x}, \bar{y}] \frac{CV(\bar{x})CV(\bar{y})}{\mu_X} \mu_Y \\
&= R CV^2(\bar{x}) - \rho[\bar{x}, \bar{y}] CV(\bar{x}) CV(\bar{y}) R \\
&= R CV^2(\bar{x}) \left[1 - \rho[\bar{x}, \bar{y}] \frac{CV(\bar{y})}{CV(\bar{x})} \right]
\end{aligned}$$

Temos que:

$$CV(\bar{x}) = \frac{DP(\bar{x})}{\mu_X} = \frac{\sigma_X}{\mu_X \sqrt{n}} = \frac{CV(X)}{\sqrt{n}} \quad CV(\bar{y}) = \frac{DP(\bar{y})}{\mu_Y} = \frac{\sigma_Y}{\mu_Y \sqrt{n}}$$

Lembrando para AASc: $f_i \sim Bin(n, 1/N)$, $Var(f_i) = \frac{n}{N} \left(1 - \frac{1}{N}\right)$ e $Cov(f_i, f_j) = -\frac{n}{N^2}$.

$$\begin{aligned}
Cov(X, Y) &= \frac{\sum_{i=1}^N (X_i - \mu_X)(Y_i - \mu_Y)}{N} \\
Cov(\bar{x}, \bar{y}) &= \frac{1}{n^2} Cov\left(\sum_{i=1}^N f_i X_i, \sum_{j=1}^N f_j Y_j\right) = \frac{1}{n^2} \sum_{i=1}^N \sum_{j=1}^N X_i Y_i Cov(f_i, f_j) = \\
&= \frac{1}{n^2} \sum_{i=1}^N X_i Y_i \frac{n}{N} \left(1 - \frac{1}{N}\right) - \frac{1}{n^2} \sum_{i=1}^N \sum_{j \neq i} X_i Y_i \frac{n}{N^2} = \\
&= \frac{1}{n N^2} (N-1) \left(\sum_{i=1}^N X_i Y_i \right) - \frac{1}{n N^2} \sum_{i=1}^N \sum_{j \neq i} X_i Y_i = \\
&= \frac{1}{n N^2} N \left(\sum_{i=1}^N X_i Y_i \right) - \frac{1}{n N^2} \sum_{i=1}^N \sum_{j=1}^N X_i Y_i = \\
&= \frac{1}{n N} \left(\sum_{i=1}^N X_i Y_i \right) - \frac{1}{n} \mu_X \mu_Y = \\
&= \frac{1}{n N} \sum_{i=1}^N (X_i - \mu_X)(Y_i - \mu_Y) = \frac{1}{n} Cov(X, Y)
\end{aligned}$$

$$\rho(\bar{x}, \bar{y}) = \frac{Cov(\bar{x}, \bar{y})}{DP(\bar{x})DP(\bar{y})} = \frac{\frac{1}{n} Cov(X, Y)}{\frac{\sigma_X}{\sqrt{n}} \frac{\sigma_Y}{\sqrt{n}}} = \rho(X, Y)$$

Voltando ao viés

$$\begin{aligned}
E(\hat{R} - R) &\approx E \left(\frac{\bar{y} - R\bar{x}}{\mu_X} - \frac{(\bar{y} - R\bar{x})(\bar{x} - \mu_X)}{\mu_X^2} \right) \\
&= R CV^2(\bar{x}) \left[1 - \rho[\bar{x}, \bar{y}] \frac{CV(\bar{y})}{CV(\bar{x})} \right] \\
&= R \frac{CV^2(X)}{n} \left[1 - \rho[X, Y] \frac{CV(Y)}{CV(X)} \right]
\end{aligned}$$

Agora podemos ver que quanto maior o tamanho da amostra n, menor o viés.

Lembrando, temos a aproximação:

$$\hat{R} - R = \frac{\bar{y}}{\bar{x}} - R = \frac{\bar{y} - R\bar{x}}{\bar{x}} = f(\bar{x})(\bar{y} - R\bar{x}) = \frac{\bar{y} - R\bar{x}}{\mu_X} - \frac{(\bar{y} - R\bar{x})(\bar{x} - \mu_X)}{\mu_X^2} + \dots$$

Aproximando a variância usando o Erro Quadrático Médio e usando só o primeiro termo da nossa aproximação, temos:

$$Var(\hat{R}) = E(\hat{R} - E(\hat{R}))^2 = E(\hat{R} - R + R - E(\hat{R}))^2 \approx E(\hat{R} - R)^2 = E \left(\frac{\bar{y} - R\bar{x}}{\mu_X} \right)^2 = \frac{E(\bar{d})^2}{\mu_X^2}$$

em que $d_i = Y_i - RX_i$ e $\sum_{i=1}^N d_i = 0$.

Estimaremos a média de Y (μ_Y), usando $\hat{\mu}_R = \hat{R}\mu_X$ e estimaremos o total de T (τ_Y), usando $\hat{\tau}_R = \hat{R}\tau_X$.

Teorema 5.2. Se n é grande, tem-se para o plano AASc que

$$\begin{aligned}
Var(\hat{R}) &\approx \frac{1}{n\mu_X^2} \sum_{i=1}^N \frac{(Y_i - RX_i)^2}{N} = \frac{1}{\mu_X^2} \frac{\sigma_R^2}{n} \\
Var(\hat{\mu}_R) &\approx \frac{1}{n} \sum_{i=1}^N \frac{(Y_i - RX_i)^2}{N} = \frac{\sigma_R^2}{n} \\
Var(\hat{\tau}_R) &\approx \frac{\tau_X^2}{n\mu_X^2} \sum_{i=1}^N \frac{(Y_i - RX_i)^2}{N} = N^2 \frac{\sigma_R^2}{n} \\
\sigma_R^2 &= \sum_{i=1}^N \frac{(Y_i - RX_i)^2}{N}
\end{aligned}$$

Um estimador de σ_R^2 é dado por

$$s_R^2 = \frac{1}{n-1} \sum_{i \in s} (Y_i - \hat{R}X_i)^2.$$

Cochran (1977) comenta que os estimadores das variâncias são consistentes.

As expressões para AASc e AAsSs estão no formulário.

Para n grande, faremos intervalos de confiança utilizando a distribuição normal, sendo os intervalos para R, μ_y e τ_y respectivamente:

$$IC = [\hat{R} \mp 1.96 \sqrt{Var(\hat{R})}], \quad IC = [\hat{\mu}_R \mp 1.96 \sqrt{Var(\hat{\mu}_R)}], \quad IC = [\hat{\tau}_R \mp 1.96 \sqrt{Var(\hat{\tau}_R)}]$$

Observação: Só podemos usar o estimador razão para grandezas proporcionais, ou seja, ao fazermos o gráfico de dispersão entre y e x, teremos que ter reta a+bx ajustada passando pela origem (com a nula).