

$$L(\beta, \sigma^2 | y, x) = \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \exp \left[-\frac{1}{2\sigma^2} (y - x\beta)' (y - x\beta) \right]$$

$$\mathbb{H} = \{ (\beta, \sigma^2), -\infty < \beta_j < +\infty, j=0,1,2 \dots k, \sigma^2 > 0 \}$$

$$\mathbb{H}_0 = \{ (\beta, \sigma^2) \in \mathbb{H} \mid \beta_0 = m \}$$

$$\lambda = \frac{\sup_{(\beta, \sigma^2) \in \mathbb{H}_0} L(\beta, \sigma^2 | y, x)}{\sup_{(\beta, \sigma^2) \in \mathbb{H}} L(\beta, \sigma^2 | y, x)}$$

$$\sup_{(\beta, \sigma^2) \in \mathbb{H}} L(\beta, \sigma^2 | y, x) = L(\hat{\beta}, \hat{\sigma}_{mv}^2 | y, x) =$$

$$\hat{\beta} = (x'x)^{-1}x'y$$

$$\hat{\sigma}_{mv}^2 = \frac{(x - x\hat{\beta})' (x - x\hat{\beta})}{n}$$

$$= (2\pi)^{-n/2} (\hat{\sigma}_{mv}^2)^{-n/2} e^{-n/2}$$

Cálculo de $\sup_{(\beta, \sigma^2) \in \mathbb{H}_0} L(\beta, \sigma^2 | y, x)$

Maximizar $L(\beta, \sigma^2 | y, x)$ sujeito à condição

$$\beta = m$$

$$((\beta - m)') \lambda$$

$$L = L(\beta, \sigma^2 | y, x) - \lambda' ((\beta - m)) \quad \text{obter } \hat{\beta}_0, \hat{\sigma}^2$$

λ vetor $p \times 1$ de multiplicadores de Lagrange

$$L(\beta, \sigma^2 | y, x) = \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \exp \left[-\frac{1}{2\sigma^2} (y - X\beta)' (y - X\beta) \right] \\ y'y - 2y'X\beta + \beta'X'X\beta$$

$$\frac{\partial L}{\partial \beta} = -\frac{1}{\sigma^2} (2X'X\beta - 2X'y) \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \exp \left[-\frac{1}{2\sigma^2} (y - X\beta)' (y - X\beta) \right] - \lambda' \lambda$$

$$= -\frac{1}{2\sigma^2} (2X'X\beta - 2X'y) L(\beta, \sigma^2 | y, x) - \lambda' \lambda$$

derivada de exp

$$\frac{\partial L}{\partial \sigma^2} = \left(\frac{1}{2\pi\sigma^2} \right)^{n/2} \left(\frac{1}{2\sigma^4} (y - X\beta)' (y - X\beta) \right) \exp \left[-\frac{1}{2\sigma^2} (y - X\beta)' (y - X\beta) \right]$$

$$+ \left(\frac{1}{2\pi} \right)^{n/2} \left[-\frac{n}{2} (\sigma^2)^{n/2 - 1} \right] \exp \left[-\frac{1}{2\sigma^2} (y - X\beta)' (y - X\beta) \right]$$

$$= -\frac{n}{2\sigma^2} L(\beta, \sigma^2 | y, x) + \frac{1}{2\sigma^4} (y - X\beta)' (y - X\beta) L(\beta, \sigma^2 | y, x)$$

$$\frac{\partial L}{\partial \lambda} = -(\beta - m)$$

$$\frac{\partial L}{\partial \theta^2} = 0$$

$$\therefore L(\beta_2, \delta^2 | y, x)$$

$$-n\beta^2 + (\bar{y} - x\hat{\beta}_0)'(\bar{y} - x\hat{\beta}_0) = 0$$

$$\hat{\sigma}_0^2 = \frac{(y - x\hat{\beta}_0)^T(y - x\hat{\beta}_0)}{n}$$

$$\frac{\partial L}{\partial \beta_0} = \frac{x^T (\hat{\beta}_0 - x^T y)}{n} + \frac{C \lambda}{L(\hat{\beta}_0, \hat{\beta}_1 | y, x)} = 0$$

$$\Rightarrow x^T x (\hat{\beta}_0 - x^T \hat{\beta}) + C \hat{\beta}^* = 0 \quad \hat{\beta}^* = - \frac{\hat{\beta}_0^T \hat{\beta}}{L(\hat{\beta}_0, \hat{\beta}_0^T | y, x)}$$

$$X' X \hat{\beta}_0 + C' \hat{\lambda}^* = X' Y$$

$$x' x \hat{\beta}_0 = x' y - c' \lambda^*$$

$$\hat{\beta}_0 = (x'x)^{-1} x' y - (x'x)^{-1} C' \hat{z}^* = \hat{\beta} - (x'x)^{-1} C' \hat{z}^*$$

$$\frac{\partial L}{\partial \tilde{x}} = 0 \Rightarrow C \hat{\beta}_0 + \tilde{m} \downarrow \Rightarrow C \hat{\beta}_0 - C (x^T x)^{-1} C^T \tilde{x}^* = \tilde{m}$$

$$\Rightarrow \lambda^* = \left[C (X'X)^{-1} C' \right]^{-1} (C \hat{\beta} - \tilde{y})$$

C é de posto completo
e $X^T X$ é simétrica

$$r[n] = r(c) = q$$

$$\therefore \hat{\beta}_0 = \hat{\beta} - (X'X)^{-1} C^T [C(X'X)^{-1} C^T]^{-1} (C\hat{\beta} - \tilde{y})$$

Ibs:

$\hat{\beta}_0$ e $\hat{\sigma}^2$ são os estimadores de máxima verossimilhança de β_0 e σ^2 sob H_0 : $C(\hat{\beta}_0) = \mathbf{m}$

Coincidem com os est. max. veross no modelo reduzido sob H_0 .

$$\sup_{\theta \in \Theta_0} L(\beta, \sigma^2 | y, x) = L(\hat{\beta}_0, \hat{\sigma}^2 | y, x) = (2\pi)^{-n/2} (\hat{\sigma}^2)^{-n/2} e^{-n/2}$$

$$\lambda = \left(\frac{\hat{\sigma}_{mv}^2}{\hat{\sigma}_0^2} \right)^{n/2}$$

$$\text{Re: } \lambda = \left(\frac{\hat{\sigma}^2}{\hat{\sigma}_0^2} \right)^{n/2} \leq \lambda_0$$

Usar a estatística $W = (\lambda^{-2/n} - 1) \frac{m-k-1}{p}$ facilidade
de obter a
distribuição

- W é uma função monótona de λ

$$-\lambda \leq \lambda_0 \Leftrightarrow \lambda^{-1} \geq \lambda_0^{-1} \quad (\Rightarrow \lambda^{-2/n} \geq \lambda_0^{-2/n}) \quad (\Rightarrow \text{pular})$$

$$(\lambda^{-2/n} - 1) \frac{m-k-1}{p} \geq (\lambda_0^{-2/n} - 1) \frac{m-k-1}{p} \Leftrightarrow$$

$$\Leftrightarrow W \geq w \quad \text{forma da regiões críticas}$$

$$W = \left(\frac{\hat{\sigma}_o^2}{\hat{\sigma}_{mv}^2} - 1 \right) \frac{n-k-1}{p} = \frac{\hat{\sigma}_o^2 - \hat{\sigma}_{mv}^2}{\hat{\sigma}_{mv}^2} \frac{n-k-1}{p}$$

lembrando que

$$\hat{\sigma}_o^2 = \frac{(y - x\hat{\beta}_0)'(y - x\hat{\beta}_0)}{n}$$

$$\begin{aligned}\hat{\beta}_0 &= \hat{\beta} - \underbrace{(x'x)^{-1} C' [C(x'x)^{-1} C']^{-1} (C\hat{\beta} - w)}_{H \sim (k+1) \times 1} \\ &= \hat{\beta} - H\end{aligned}$$

$$\hat{\sigma}_o^2 = \frac{1}{n} (y - x\hat{\beta}_0)'(y - x\hat{\beta}_0) = \frac{1}{n} \left\{ (y - x\hat{\beta} + xH)'(y - x\hat{\beta} + xH) \right.$$

$$= \frac{1}{n} \left\{ (y - x\hat{\beta})'(y - x\hat{\beta}) + (y - x\hat{\beta})'xH + H'x'(y - x\hat{\beta}) + H'x'xH \right\}$$

$$H'x'(y - x\hat{\beta}) = H' (x'y - x'x\hat{\beta}) = H' [x'y - x'y] = 0$$

$$(y - x\hat{\beta})'xH = [H'x'(y - x\hat{\beta})]' = 0$$

$$= \hat{\sigma}_o^2 + \frac{H'x'xH}{n} = \hat{\sigma}_o^2 + \frac{1}{n} (C\hat{\beta} - w)' [C(x'x)^{-1} C']^{-1} C(x'x)^{-1} (x'x)$$

$$(x'x)^{-1} C' [C(x'x)^{-1} C']^{-1} (C\hat{\beta} - w) =$$

$$= \hat{\sigma}_{mv}^2 + \frac{1}{n} (C\hat{\beta} - w)' [C(x'x)^{-1} C']^{-1} (C\hat{\beta} - w)$$

Substituindo na expressão de W (íncio pag 93)

$$\begin{aligned}
 W &= \frac{(C\hat{\beta} - m)' [C(x'x)^{-1}C']^{-1} (C\hat{\beta} - m)}{n\hat{\sigma}_{m\hat{\beta}}^2} \frac{n-k-1}{p} \\
 &= \frac{(C\hat{\beta} - m)' [C(x'x)^{-1}C']^{-1} (C\hat{\beta} - m)}{p \frac{(y - x\hat{\beta})'(y - x\hat{\beta})}{n-k-1}} = \\
 &= \frac{(C\hat{\beta} - m)' [C(x'x)^{-1}C']^{-1} (C\hat{\beta} - m)}{p \text{MSE}} \quad \begin{matrix} \rightarrow \text{estatística} \\ \text{de teste} \end{matrix} \\
 &\downarrow \\
 &\text{Modelo Completo } Y = X\beta + \varepsilon
 \end{aligned}$$

Distribuições de W

$$\frac{(C\hat{\beta} - m)' [C(x'x)^{-1}C']^{-1} (C\hat{\beta} - m)}{\hat{\sigma}^2}$$

$$\hat{\beta} \sim N_{k+1}(\beta, (x'x)^{-1}\hat{\sigma}^2)$$

$$C\hat{\beta} \sim N_p(C\beta, C(x'x)^{-1}C'\hat{\sigma}^2)$$

$$A\Sigma = \frac{[C(x'x)^{-1}C']^{-1}}{\hat{\sigma}^2} C(x'x)^{-1}C'\hat{\sigma}^2 = I \quad (A\Sigma \text{ é idempotente})$$

$$\lambda = \frac{1}{2} (C\hat{\beta} - m)' \frac{[C(x'x)^{-1}C']^{-1}}{\hat{\sigma}^2} (C\hat{\beta} - m)$$

$$\therefore \frac{(C\hat{\beta} - \tilde{w})' [C(X'X)^{-1} C']^{-1} (C\hat{\beta} - \tilde{w})}{\hat{\sigma}^2} \sim \chi^2_{p, n}$$

$$\frac{(Y - X\hat{\beta})' (Y - X\hat{\beta})}{\hat{\sigma}^2} \sim \chi^2_{n-k-1}$$

$\hat{\beta}$ e SSE não independentes

$$\therefore W \sim F_{p, n-k-1, \lambda}$$

sob H_0 , $C\hat{\beta} = \tilde{w}$, $\lambda=0$, $W \sim F_{p, n-k-1}$ central

O teste da razão de Veross. Generalizada rejeita H_0 p/

$$W > w$$

$$\text{Tomar } w \mid P(F_{p, n-k-1} > w) = \alpha$$

Obs:

$$j) W = \frac{\hat{\sigma}_0^2 - \hat{\sigma}_{mv}^2}{\hat{\sigma}_{mv}^2} \frac{n-k-1}{p}$$

$\hat{\sigma}_{mv}^2$ - est. max. veross. de $\hat{\sigma}^2$ no modelo original

$\hat{\sigma}_0^2$ - est. max. veross. de $\hat{\sigma}^2$ no modelo reduzido

sob H_0 . (ambos têm denominador n)

Portanto, W pode ser escrita como

$$W = \frac{SSE_n - SSE_c}{SSE_c} \cdot \frac{n-k-1}{p}$$

$$SST = SSE + SSR$$

$$SSE = SST - SSR_n$$

$$SSE_c = SST - SSR_c$$

H_0 : modelo reduzido

H_a : modelo completo

SSE_c - soma de quadrados do resíduo do modelo completo
(modelo original) = $(\hat{Y} - X\hat{\beta})'(\hat{Y} - X\hat{\beta})$

SSE_n - soma de quadrados do resíduo do modelo reduzido

$$\text{Sob } H_0 = (\hat{Y} - X(\hat{\beta}_0))'(\hat{Y} - X(\hat{\beta}_0)) = (\hat{Y} - X\hat{\beta})'(\hat{Y} - X\hat{\beta}) + (C(\hat{\beta} - \beta_0)'(C(\hat{\beta} - \beta_0)))$$

$$SSE_n - SSE_c = (C(\hat{\beta} - \beta_0)'[C(X'X)^{-1}C])^{-1}(C(\hat{\beta} - \beta_0)) \geq 0 \text{ pois } C(X'X)^{-1}C \text{ é p.d.}$$

(Não escrever $SSE_n - SSE_c = SSR_c - SSR_n$ aqui, pois isto pode não valer. Em alguns casos (raros), a redução sob

H_0 altera a variável resposta e as somas de quadrados totais não são as mesmas)

Resultados

i) se A é positiva definida entao

$$r[CAC'] = r(C) \Rightarrow [C(X'X)^{-1}C] \text{ é inv.}$$

ii) se A é p.d. $n \times n$ e C é $p \times n$, $r(C) = p$ entao CAC' é positiva definida

$$i) \quad n \times p \quad r(X) = p \Rightarrow X'X \text{ é p.d.}$$

$$\text{Ex: } y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

$$\beta_1 = \beta_2 + 4$$

$$\text{Sob } H_0 \quad y = \beta_0 + ((\beta_2 + 4)x_1 + \beta_2 x_2) + \epsilon \quad \text{Ver pag 386}$$

$$y - 4x_1 = \beta_0 + \beta_2(x_1 + x_2) + \epsilon$$

$$2) \quad \text{Var}(C(\hat{\beta} - \beta)) = \text{Var}(C\hat{\beta}) = C(X'X)^{-1}C' \sigma^2$$

$$\text{Var}(C\hat{\beta}) = C(X'X)^{-1}C' \text{MSE}$$

3) Para cada λ , o poder do teste é

$$\Pi(\lambda) = \int_{w_\alpha}^{\infty} F(p, n-k-1, \lambda) dw$$

onde $F(p, n-k-1, \lambda)$ - densidade da estatística $F_{p, n-k-1, \lambda}$

$$\text{e } w_\alpha \text{ tal que } P(F_{p, n-k-1} \geq w_\alpha) = \alpha$$

4) $\hat{\beta}_0 = \hat{\beta} - (x'x)^{-1}C' [C(x'x)^{-1}C']^{-1}(C\hat{\beta} - m)$, est. maz. veross. de β sob $H_0: C\beta = m$ e também o estimador de mínimos quadrados de β sob H_0 . [minimiza $(y - x\hat{\beta}_0)'(y - x\hat{\beta}_0)$ sujeito à condição $C\hat{\beta}_0 = m$]

5) A estatística W para testar $H_0: C\beta = m$ contra $H_a: C\beta \neq m$ fica inalterada se testarmos $H_0: QC\beta = Qm$ contra $H_a: QC\beta \neq Qm$, onde Q é uma matriz $p \times p$ não singular

$$C = p \times (k+1)$$

$$C\beta = m \Leftrightarrow$$

$$QC = p \times (k+1)$$

$$QC\beta = Qm$$

$$W_1 = \frac{(QC\hat{\beta} - Qm)' [QC(x'x)^{-1}C'Q']^{-1}(QC\hat{\beta} - Qm)}{p \text{ MSE}} =$$

$$= \frac{(C\hat{\beta} - m)' Q' Q^{-1} [C(x'x)^{-1}C']^{-1} Q^{-1} Q (C\hat{\beta} - m)}{p \text{ MSE}} =$$

$$= \frac{(C\hat{\beta} - m)' [C(x'x)^{-1}C']^{-1} (C\hat{\beta} - m)}{p \text{ MSE}}$$

No exemplo 4, $y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \beta_4 x_4 + \epsilon$

$$H_0: \beta_1 = \beta_2 = \beta_3 = \beta_4 \Leftrightarrow C\beta = \tilde{m}$$

$$C = \begin{bmatrix} 0 & 1 & -1 & 0 & 0 \\ 0 & 1 & 0 & -1 & 0 \\ 0 & 1 & 0 & 0 & -1 \end{bmatrix}_{3 \times 5} \quad \tilde{m} = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad \begin{array}{l} \beta_1 - \beta_2 = 0 \\ \beta_1 - \beta_3 = 0 \\ \beta_1 - \beta_4 = 0 \end{array}$$

H_0 pode ser escrita alternativamente como

$$H_0: C_1 \beta = \tilde{m}_1$$

$$C_1 = \begin{bmatrix} 0 & 1 & -1 & 0 & 0 \\ 0 & 0 & 1 & -1 & 0 \\ 0 & 0 & 0 & 1 & -1 \end{bmatrix} \quad \tilde{m}_1 = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad \begin{array}{l} \beta_1 - \beta_2 = 0 \\ \beta_2 - \beta_3 = 0 \\ \beta_3 - \beta_4 = 0 \end{array}$$

Temos que $C_1 = QC$ para a $\begin{bmatrix} \cdot & \cdot & \cdot \end{bmatrix}$

$$C_1 = \begin{bmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \end{bmatrix}_{3 \times 3} \quad Q = \begin{bmatrix} 1 & 0 & 0 \\ -1 & 1 & 0 \\ 0 & -1 & 1 \end{bmatrix} \quad |Q| = 1$$

$Q_{3 \times 3}$ não singular, portanto

W_1 para testar $H_0: \tilde{C}_1 \beta = \tilde{m}_1$ coincide com W que testa $H_0: C\beta = \tilde{m}$.

Os graus de liberdade são os mesmos (3 e $n-5$) e assim, as conclusões são as mesmas.

Exemplos

$$H_0: \underline{\beta} = \underline{\beta}_0 \quad \underline{\beta} = [\beta_0, \beta_1, \beta_2, \dots, \beta_k]$$

$$H_a: \underline{\beta} \neq \underline{\beta}_0 \quad p=1$$

$$W = \frac{(\underline{\beta} - \underline{\beta}_0)' \left[\underline{\beta}' (\mathbf{X}' \mathbf{X})^{-1} \underline{\beta} \right]^{-1} (\underline{\beta} - \underline{\beta}_0)}{\text{MSE}}$$

$$= \frac{(\underline{\beta} - \underline{\beta}_0)^2}{[\underline{\beta}' (\mathbf{X}' \mathbf{X})^{-1} \underline{\beta}] \hat{\sigma}^2} = \frac{(\underline{\beta} - \underline{\beta}_0)^2}{\text{Var}(\underline{\beta})}$$

$$\text{Rejetamos } H_0 \text{ se } W > F_{\alpha/2, n-k-1} = t_{\alpha/2, n-k-1}^2$$

$$\Leftrightarrow \frac{\underline{\beta} - \underline{\beta}_0}{\sqrt{\text{Var}(\underline{\beta})}} > t_{\alpha/2, n-k-1} \text{ ou } \frac{\underline{\beta} - \underline{\beta}_0}{\sqrt{\text{Var}(\underline{\beta})}} < -t_{\alpha/2, n-k-1}$$

IC em termos da estatística t. Permite fazer teste univariado.

Equivalentemente, rejetamos H_0 se e só se

$$\underline{\beta}_0 \in \left\{ \underline{\beta} - t_{\alpha/2, n-k-1} \sqrt{\hat{\sigma}^2 \underline{\beta}' (\mathbf{X}' \mathbf{X})^{-1} \underline{\beta}}, \underline{\beta} + t_{\alpha/2, n-k-1} \sqrt{\hat{\sigma}^2 \underline{\beta}' (\mathbf{X}' \mathbf{X})^{-1} \underline{\beta}} \right\}$$



IC com coeficiente $1-\alpha$ para $\underline{\beta}$.

$$\text{de } \underline{\beta} = [0, 0, \dots, 1, \dots, 0]_{(n \times (k+1))} \text{ e } \underline{\beta}_0 = 0, \text{ o teste fija}$$

$$H_0: \beta_j = 0$$

$$H_a: \beta_j \neq 0$$

$$W = \frac{\hat{\beta}_j^2}{a_{jj} \hat{\sigma}^2}$$

a_{jj} - j-ésimo elemento da diagonal de

$$(X'X)^{-1} = \begin{bmatrix} a_{00} & a_{01} & \dots & a_{0k} \\ a_{10} & a_{11} & & \\ \vdots & & \ddots & \\ & & & a_{kk} \end{bmatrix}$$

Rejetamos H_0 se $W \geq F_{\alpha, 1, n-k-1}$

Além disso,

$$W = \frac{SSE_n - SSE_c}{SSE_c} \cdot \frac{n-k-1}{p} = \frac{SSE_n - SSE_c}{MSE_c}$$

Modelo Completo: $y = \beta_0 + \beta_1 x_1 + \dots + \beta_j x_j + \beta_{j+1} x_{j+1} + \dots + \beta_k x_k + \epsilon$

Modelo Reduzido: $y = \beta_0 + \beta_1 x_1 + \dots + \beta_{j-1} x_{j-1} + \beta_{j+1} x_{j+1} + \dots + \beta_k x_k + \epsilon$

Como aqui a redução sob H_0 não altera a variável dependente,

$$W = \frac{SSR_c - SSR_n}{MSE_c}$$

↳ Estatística do Teste F-parcial

Intervalo de Confiança para β_j :

$$\hat{\beta}_j \pm t_{\alpha/2, n-k-1} \sqrt{a_{jj} MSE}$$

Para $F_{1, n-k-1}$, pode fazer o teste t

$$2) \hat{\beta} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_q \\ \beta_{q+1} \end{bmatrix} \quad \begin{array}{l} \beta_1 \quad (k+1-q) \times 1 \\ \beta_2 \quad q \times 1 \\ \vdots \\ \beta_{q+1} \quad 0 < q \leq k+1 \end{array}$$

$$H_0: \hat{\beta}_2 = \underline{\beta}_2 \rightarrow \text{vetor de constantes}$$

$$H_a: \hat{\beta}_2 \neq \underline{\beta}_2$$

$$X = \begin{bmatrix} X_1 & X_2 \end{bmatrix}_{m \times (k+1-q)} \quad m \times q$$

$$\tilde{Y} = X\hat{\beta} + \tilde{\epsilon} = \begin{bmatrix} X_1 & X_2 \end{bmatrix} \begin{bmatrix} \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_q \\ \hat{\beta}_{q+1} \end{bmatrix} + \tilde{\epsilon} = X_1\hat{\beta}_1 + X_2\hat{\beta}_2 + \tilde{\epsilon}$$

$$C = \begin{bmatrix} O & I_q \\ q \times (k+1-q) & q \times q \end{bmatrix}$$

$$(X'X)^{-1} = \begin{bmatrix} T_{11} & T_{12} \\ T_{21} & T_{22} \end{bmatrix}_{q \times (k+1-q) \quad q \times q}$$

$$(\hat{\beta} - \underline{\beta}) = \hat{\beta}_2 - \underline{\beta}_2$$

$$XX = \begin{bmatrix} X_1' \\ X_2' \end{bmatrix} \begin{bmatrix} X_1 & X_2 \end{bmatrix} = \begin{bmatrix} X_1' X_1 & X_1' X_2 \\ X_2' X_1 & X_2' X_2 \end{bmatrix}$$

$$\begin{bmatrix} k+1-q & \times q \\ k+1-q & \times q \end{bmatrix}$$

$$\tilde{m} = \underline{\beta}_2 \rightarrow C\hat{\beta} = \hat{\beta}_2$$

$$\hat{\beta} = \begin{bmatrix} \hat{\beta}_1 \\ \vdots \\ \hat{\beta}_q \end{bmatrix}$$

$$C(X'X)^{-1}C' = [O \quad I_q] \begin{bmatrix} T_{11} & T_{12} \\ T_{21} & T_{22} \end{bmatrix} [O \quad I_q]$$

$$= T_{22}$$

$$W = \frac{(\hat{\beta}_2 - \tilde{\beta}_2)^T T_{22}^{-1} (\hat{\beta}_2 - \tilde{\beta}_2)}{q \text{MSE}}$$

$$X^T X = \begin{bmatrix} X_1^T \\ X_2^T \end{bmatrix} \begin{bmatrix} X_1 & X_2 \end{bmatrix} = \begin{bmatrix} X_1^T X_1 & X_1^T X_2 \\ X_2^T X_1 & X_2^T X_2 \end{bmatrix}$$

$$(X^T X)^{-1} = \begin{bmatrix} - & - \\ - & \underbrace{[X_2^T X_2 - X_2^T X_1 (X_1^T X_1)^{-1} X_1^T X_2]}_{\approx T_{22}}^{-1} \end{bmatrix} \begin{bmatrix} B_{22} - B_{21} B_{11}^{-1} B_{12} \\ B_{11}^{-1} \end{bmatrix}$$

$$T_{22}^{-1} = X_2^T X_2 - X_2^T X_1 (X_1^T X_1)^{-1} X_1^T X_2$$

$H_0: \beta_2 = 0$ (verifica a importância das q últimas variáveis independentes)

$$W = \frac{\hat{\beta}_2^T T_{22}^{-1} \hat{\beta}_2}{q \text{MSE}}$$

Rejeitamos H_0 para $W > w$

$P(F_{q, n-k-1} > w) = \alpha$

Como

$$W = \frac{SSE_n - SSE_c}{q \text{MSE}}$$

$$SSE_c = \tilde{y}' \tilde{y} - \hat{\beta}_2^T X_1^T \tilde{y}$$

$$SSE_n = \tilde{y}' \tilde{y} - \hat{\beta}_2^T X_1^T \tilde{y}$$

$$\hat{\beta}_2 = (X_1^T X_1)^{-1} X_1^T \tilde{y}, \text{ temos que}$$

$$W = \frac{\hat{\beta}_2^T X_1^T \tilde{y} - \hat{\beta}_2^T X_1^T \tilde{y}}{q \text{MSE}}$$

$$3) H_0: \beta^* = 0$$

$$\hat{\beta}^* = \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_K \end{bmatrix}$$

Caso particulares do anterior

$$q = K$$

$$\hat{\beta}_1 = \beta_0$$

Verificar que, neste caso, $W = \frac{MSR}{MSE}$

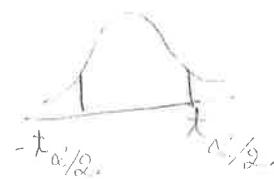
b) Intervalos de Confiança e de Previsão

Intervalo de Confiança para $E(Y_i | X_i) = \hat{x}_i \hat{\beta}$

$$\hat{x}_i \hat{\beta} = \hat{l}' \hat{\beta} \quad \text{para } \hat{l}' = \hat{x}_i$$

Portanto, o IC com coeficiente $1 - \alpha$ é

$$\hat{x}_i \hat{\beta} \pm t_{n-K-1, \alpha/2} \sqrt{\hat{x}_i (X'X)^{-1} \hat{x}_i' \hat{\sigma}^2}$$



Intervalo de Previsão para $Y_i | \hat{x}_h$, onde a observação h não pertence à amostra

Definição

Seja T uma variável aleatória com valor desconhecido. O var. aleat. \hat{T} é ^{um previsor} não viésado para T se

$$E(\hat{T} - T) = 0$$

O erro quadrático médio de \hat{T} é dado por

$$EQM(\hat{T}) = \text{Var}(\hat{T} - T) = E(\hat{T} - T)^2 = \text{Var}(\hat{T} - T) + E^2(\hat{T} - T)$$

\downarrow
se \hat{T} é não viésado

$$\hat{Y}_h = \tilde{x}_h \hat{\beta} \quad \text{previsor de } Y_h$$

$$E(\hat{Y}_h - Y_h) = \tilde{x}_h E(\hat{\beta}) - E(Y_h) = \tilde{x}_h \hat{\beta} - \tilde{x}_h \beta$$

∴ \hat{Y}_h é um previsor não viésado de Y_h

Intervalo de Previsão para $Y | \tilde{x}_h$

$$\hat{Y}_h \pm t_{n-k-1, \alpha/2} \sqrt{\text{Var}(\hat{Y}_h - Y_h)} \quad \rightarrow EQM(\hat{Y}_h)$$

$$\text{Var}(\hat{Y}_h) = \text{Var}(\tilde{x}_h \hat{\beta}) = \tilde{x}_h (x'x)^{-1} \tilde{x}_h' \hat{\sigma}^2$$

$$\text{Var}(Y_h) = \sigma^2$$

\hat{Y}_h e Y_h são independentes

h não pertence à amostra \Rightarrow

porque o elemento

$$\text{Var}(\hat{Y}_h - Y_h) = \text{Var}(\hat{Y}_h) + \text{Var}(Y_h) = \tilde{x}_h (x'x)^{-1} \tilde{x}_h' \hat{\sigma}^2 + \sigma^2$$

I. Previsão $\hat{Y}_h \pm t_{n-k-1, \alpha/2} \sqrt{(1 + \tilde{x}_h (x'x)^{-1} \tilde{x}_h) \hat{\sigma}^2}$

Intervalo de Confiança para σ^2

$$\frac{SSE}{\sigma^2} = \frac{(n-k-1) MSE}{\sigma^2} \sim \chi^2_{n-k-1}$$

$$P\left(a \leq \frac{(n-k-1) MSE}{\sigma^2} \leq b\right) =$$

$$P\left(\frac{(n-k-1) \hat{\sigma}^2}{b} \leq \sigma^2 \leq \frac{(n-k-1) \hat{\sigma}^2}{a}\right) = \gamma$$

IC p/ σ^2 : $\left[\frac{(n-k-1) MSE}{b}, \frac{(n-k-1) \hat{\sigma}^2}{a}\right]$

a, b tais que $P(a \leq Z \leq b) = \gamma$

$$\text{Z} \sim \chi^2_{n-k-1}$$

3.3 - Inferência $\xi \sim N_n(0, \sigma^2 V)$, V conhecida

Modelo

$$\tilde{Y} = X\beta + \tilde{\xi}$$

$$\tilde{\xi} \sim N_n(0, \sigma^2 V)$$

V matriz positiva definida ($V \neq I$) conhecida.

V positiva definida \Rightarrow Existe P não singular tal que $V = P P'$

$$\tilde{z} = P^{-1} \tilde{y} \sim N_n(P^{-1} \beta, \sigma^2 I)$$

$$\text{Var}(\tilde{z}) = \text{Var}(P^{-1} \tilde{y}) = P^{-1} V P^{-1} \sigma^2 = P^{-1} P P' P^{-1} \sigma^2 \\ = \sigma^2 I$$

$$\begin{aligned} A^{-1}A &= I \\ (A^{-1}A)^{-1} &= I \\ ((A^{-1}A)^{-1})^{-1} &= I \\ A^{-1} &= A'^{-1} \end{aligned}$$

Transformamos o modelo

$$y = X\beta + \varepsilon \quad \varepsilon \sim N(0, \sigma^2 V)$$

em

$$P^{-1} y = P^{-1} X \beta + P^{-1} \varepsilon$$

$$\tilde{z} = Q \beta + \tilde{\eta} \quad \tilde{z} = P^{-1} y \quad Q = P^{-1} X \quad \tilde{\eta} = P^{-1} \varepsilon$$

$$\tilde{\eta} \sim N_n(0, \sigma^2 I)$$

① modelo transformado satisfaz as condições do modelo linear geral, caso 1. ($\tilde{\eta} \sim N_n(0, \sigma^2 I)$)

Os parâmetros de interesse β e σ^2 do modelo original são os parâmetros do modelo transformado.

$\hat{\beta} \rightarrow$ est. m.q. e m.v. de β no modelo transformado

$$\begin{aligned}\hat{\beta} &= (\mathbf{Q}'\mathbf{Q})^{-1} \mathbf{Q}' \tilde{z} \\ &= (\underbrace{\mathbf{x}' \mathbf{P}^{-1} \mathbf{P}' \mathbf{x}}_{V^{-1}})^{-1} \mathbf{x}' \underbrace{\mathbf{P}^{-1} \mathbf{P}' \mathbf{y}}_{V^{-1}} \\ &= (\mathbf{x}' V^{-1} \mathbf{x})^{-1} \mathbf{x}' V^{-1} \mathbf{y}\end{aligned}$$

$$\begin{aligned}V &= \mathbf{P} \mathbf{P}' \\ V^{-1} &= \mathbf{P}'^{-1} \mathbf{P}^{-1} \\ &= \mathbf{P}^{-1} \mathbf{P}'^{-1}\end{aligned}$$

$$\begin{aligned}\text{Var}(\hat{\beta}) &= \text{Var} \left[(\mathbf{x}' V^{-1} \mathbf{x})^{-1} \mathbf{x}' V^{-1} \mathbf{y} \right] = \\ &= (\mathbf{x}' V^{-1} \mathbf{x})^{-1} \mathbf{x}' V^{-1} V V^{-1} \mathbf{x} (\mathbf{x}' V^{-1} \mathbf{x})^{-1} \sigma^2 \\ &= (\mathbf{x}' V^{-1} \mathbf{x})^{-1} \sigma^2\end{aligned}$$

$\hat{\beta}_G = (\mathbf{x}' V^{-1} \mathbf{x})^{-1} \mathbf{x}' V^{-1} \mathbf{y} \rightarrow$ estimador de mínimos quadrados generalizados de β no modelo $\tilde{y} = \mathbf{x}\beta + \tilde{\epsilon}$

Coincide com o estimador de min. quad. usual $(\mathbf{Q}'\mathbf{Q})^{-1} \mathbf{Q}' \tilde{z}$, do modelo transformado

$$\hat{\sigma}_{\tilde{\epsilon}}^2 = \frac{1}{n-k-1} (\tilde{z} - \mathbf{Q}\hat{\beta})' (\tilde{z} - \mathbf{Q}\hat{\beta}) = \frac{1}{n-k-1} (\tilde{z}' \tilde{z} - \hat{\beta}' \mathbf{Q}' \tilde{z})$$

em função das variáveis transformadas

$$\begin{aligned}
 &= \frac{1}{n-k-1} \left[\tilde{y}' P^{-1} P^{-1} \tilde{y} - \underbrace{\tilde{y}' V^{-1} X}_{\hat{\beta}'} \underbrace{(X' V^{-1} X)^{-1}}_{Q'} \underbrace{X' P^{-1} P^{-1} \tilde{y}}_{\tilde{z}} \right] \\
 &= \frac{1}{n-k-1} \left[\tilde{y}' V^{-1} \tilde{y} - \tilde{y}' V^{-1} X (X' V^{-1} X)^{-1} X' V^{-1} \tilde{y} \right] \\
 &= \frac{1}{n-k-1} \tilde{y}' \left[V^{-1} - V^{-1} X (X' V^{-1} X)^{-1} X' V^{-1} \right] \tilde{y}
 \end{aligned}$$

$\hat{\beta}_G$, $\text{Var}(\hat{\beta}_G)$ e $\hat{\sigma}_G^2$ são as únicas quantidades necessárias para estimação pontual e por intervalo e testes de hipóteses.

$$W = \frac{((\hat{\beta}_G - m)') \left[C (Q' Q)^{-1} C' \right]^{-1} ((\hat{\beta}_G - m))}{p \hat{\sigma}_G^2}$$

Também aqui, não trabalhar com $SSR_C - SSR_R$ pois a transformação $P^{-1} \tilde{y} = P^{-1} X \beta + P^{-1} \varepsilon$ pode levar a um modelo sem intercepto.

Muitas vezes, a transformação $P^{-1} \tilde{y} = P^{-1} X \beta + P^{-1} \varepsilon$ pode resultar em um modelo sem intercepto, mesmo que o modelo de partida possua intercepto.

Exemplo 1

$$Y_i = \beta x_i + \epsilon_i$$

$\epsilon_i \sim N(0, \sigma^2)$ ϵ_i, ϵ_j v.a. independentes, $i \neq j$

$$\sigma^2 = x_i \sigma^2$$

$$\text{Var}(\xi) = \begin{bmatrix} x_1 & 0 & 0 \\ 0 & x_2 & 0 \\ & & \ddots \\ & & x_n \end{bmatrix} \sigma^2 = V \sigma^2$$

$$\epsilon_i \sim N_n(0, \sigma^2 V) \quad V \text{ conhecida}$$

$$V^{-1} = \text{diag}\left(\frac{1}{x_1}, \frac{1}{x_2}, \dots, \frac{1}{x_n}\right)$$

$$X = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$$

$$X' V^{-1} X = \sum_{i=1}^n x_i \quad X' V^{-1} Y = \sum_{i=1}^n y_i \Rightarrow \hat{\beta} = \frac{\sum y_i}{\sum x_i} = \frac{\bar{y}}{\bar{x}}$$

Exemplo 2

$$Y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

$$\epsilon \sim N(0, \sigma^2 V)$$

$V = \text{diag}(w_1, w_2, \dots, w_n) \Rightarrow \text{Var}(\epsilon_i) = w_i \sigma^2 \quad w_i > 0$
 $\epsilon_i, \epsilon_j \text{ v.a. indep. } i \neq j$
 Conhecidas

$$V = P P' \Rightarrow P = \begin{bmatrix} \sqrt{w_1} & & & \\ & \sqrt{w_2} & & \\ & & \ddots & \\ & & & \sqrt{w_n} \end{bmatrix}$$

$$\boxed{\begin{array}{l} V = P^2 \\ P = V^{1/2} \end{array}}$$

$$P^{-1} = \text{diag} \left[\frac{1}{\sqrt{w_1}}, \frac{1}{\sqrt{w_2}}, \dots, \frac{1}{\sqrt{w_n}} \right]$$

$$P^{-1} Y = \begin{bmatrix} \frac{y_1}{\sqrt{w_1}} \\ \frac{y_2}{\sqrt{w_2}} \\ \vdots \\ \frac{y_n}{\sqrt{w_n}} \end{bmatrix} \quad P^{-1} X = \begin{bmatrix} \frac{1}{\sqrt{w_1}} & \frac{x_1}{\sqrt{w_1}} \\ \frac{1}{\sqrt{w_2}} & \frac{x_2}{\sqrt{w_2}} \\ \vdots & \vdots \\ \frac{1}{\sqrt{w_n}} & \frac{x_n}{\sqrt{w_n}} \end{bmatrix}$$

Modelo Transformado : $\frac{y_i}{\sqrt{w_i}} = \frac{\beta_0}{\sqrt{w_i}} + \beta_1 \frac{x_i}{\sqrt{w_i}} + \frac{\epsilon_i}{\sqrt{w_i}}$

sem intercepto

$$SST = \sum_{i=1}^n \frac{y_i^2}{w_i}$$

Usar a estatística W normalmente.

Se usar ANOVA, trabalhar com SST_{nc} e SSR_{nc}
(ver ANOVA para modelo sem intercepto)

Exemplo 3

$$y_i = \beta_0 + \beta_1 x_i + \epsilon_i$$

$$\left\{ \begin{array}{l} \epsilon_i = \rho \epsilon_{i-1} + v_i \\ \text{com } E(v_i) = 0 \quad \text{Var}(v_i) = \sigma^2 \quad \forall i \\ E(v_i v_j) = 0 \quad i \neq j \end{array} \right.$$

* é um modelo de séries temporais, denominado auto-regressivo de ordem 1 [AR(1)].

Verifica-se neste caso que

$$r(\epsilon_i, \epsilon_{i-1}) = \rho \quad \text{e, admitindo } |\rho| \neq 1,$$

$$E(\epsilon_i) = 0$$

$$\text{Var}(\epsilon_i) = \frac{\sigma^2}{1-\rho^2} = \sigma^2 \quad \text{e} \quad E(\epsilon_i \epsilon_{i-h}) = \rho^h \frac{\sigma^2}{1-\rho^2} = \rho^h \sigma^2$$

Portanto

$$\text{Var}(\xi) = \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ 1 & \rho & \dots & \rho^{n-2} \\ \vdots & & & \rho^{n-3} \\ \vdots & & & \vdots \\ 1 & & & & \end{bmatrix} \frac{\sigma^2}{1-\rho^2}$$

$$V = \begin{bmatrix} 1 & \rho & \rho^2 & \dots & \rho^{n-1} \\ 1 & \rho & \dots & \rho^{n-2} \\ \vdots & & & \rho^{n-3} \\ \vdots & & & \vdots \\ 1 & & & & \end{bmatrix}$$

Verifica-se que

$$V^{-1} = \begin{bmatrix} 1 & -\rho & 0 & \dots & 0 & 0 \\ -\rho & 1+\rho^2 & -\rho & & 0 & 0 \\ 0 & -\rho & 1+\rho^2 & & 0 & 0 \\ \vdots & & & & & \\ 0 & 0 & 0 & 1+\rho^2 & -\rho & \\ 0 & 0 & 0 & -\rho & 1 & \end{bmatrix} \frac{1}{(1-\rho^2)}$$

Se ρ é conhecido, V é conhecida e $\hat{\beta}_G = (X'V^{-1}X)^{-1}X'V^{-1}\tilde{y}$
 com $X = \begin{bmatrix} 1 & x_1 \\ & x_2 \\ \vdots & \\ & x_n \end{bmatrix}$

Observações

O melhor previsor não viado de Y_h (não presente na amostra) não é $\hat{X}_h \hat{\beta}_G$ como no caso em que $\text{Var}(\varepsilon) = \sigma^2 I$.

Se Y_h é correlacionada com $\mathbf{Y}' = (Y_1 \ Y_2 \dots Y_n)$, verifica-se que o melhor previsor não viado de Y_h (possui erro quadrático médio mínimo na classe de todos os previsores não viados de Y_h) é

$$\hat{Y}_h = \hat{X}_h \hat{\beta}_G + W \Sigma^{-1} (\mathbf{Y} - X \hat{\beta}_G),$$

onde $W = \text{Cov}(Y_h, \mathbf{Y})_{1 \times n}$

$$\Sigma = \text{Var}(\varepsilon) = \sigma^2 V_\varepsilon$$

Exemplo 3 (continuação)

Prever Y_{n+1} admitindo que o modelo do exemplo 3 é válido para Y_{n+1} .

$$h = n+1$$

$$E(Y_{n+1}) = \beta_0 + \beta_1 x_{n+1}$$

$$\text{Var}(Y_{n+1}) = \sigma^2_\varepsilon$$

$$\text{Cov}(\varepsilon_{n+1}, \varepsilon_i) = \text{Cov}(Y_{n+1}, Y_i) = \rho^{n+1-i} \sigma^2_\varepsilon \quad i=1, 2, \dots, n$$

$$\text{Cov}(Y_{n+1}, \tilde{Y}) = [\rho^n \ \rho^{n-1} \dots \ \rho^2 \ \rho] \ \sigma_e^2 = W$$

$$W\Sigma^{-1} = \sigma_e^2 [\rho^n \ \rho^{n-1} \dots \ \rho^2 \ \rho] \frac{\Sigma^{-1}}{\sigma_e^2} =$$

$$= [\rho^n \ \rho^{n-1} \dots \ \rho^2 \ \rho] \begin{bmatrix} 1 & -\rho & 0 & \dots & 0 & 0 \\ -\rho & 1+\rho^2 & -\rho & & 0 & 0 \\ 0 & -\rho & 1+\rho^2 & & 0 & 0 \\ 0 & 0 & 0 & 1+\rho^2 & -\rho & \\ 0 & 0 & 0 & -\rho & 1 & \end{bmatrix} \frac{1}{1-\rho^2}$$

$$= [0 \ 0 \ \dots \ 0 \ \rho(1-\rho^2)] \frac{1}{1-\rho^2} = [0 \ 0 \ \dots \ 0 \ \rho]$$

$$\hat{Y}_{n+1} = \underbrace{\hat{\beta}_0 + \hat{\beta}_1 x_{n+1}}_{x_n \hat{\beta}_0} + \underbrace{[0 \ 0 \ \dots \ 0 \ \rho]}_{W\Sigma^{-1}} \begin{bmatrix} Y_1 - \tilde{x}_1 \hat{\beta}_0 \\ Y_2 - \tilde{x}_2 \hat{\beta}_0 \\ \vdots \\ Y_n - \tilde{x}_n \hat{\beta}_0 \\ \tilde{Y} - \tilde{x} \hat{\beta}_0 \end{bmatrix}$$

$$= \hat{\beta}_0 + \hat{\beta}_1 x_{n+1} + \rho (Y_n - \hat{\beta}_0 - \hat{\beta}_1 x_n)$$

Obs:

- $\hat{\beta}_G = (X'V^{-1}X)^{-1} X'V^{-1}Y$ minimiza a soma de quadrados do resíduo ponderado

$$S = (Y - X\hat{\beta})' V^{-1} (Y - X\hat{\beta})$$

- se $V = I$, $\hat{\beta}_G = (X'X)^{-1} X'Y = \hat{\beta}$

- se $V \neq I$, $E(\hat{\beta}_G) = (X'X)^{-1} X' E(Y) = (X'X)^{-1} X' X \beta = \beta$

$\hat{\beta}_G$ é não viável mas não é ótimo pois

as estatísticas suficientes e completas para o modelo

$$Y = X\beta + \varepsilon, \quad \varepsilon \sim N(0, \sigma^2 V)$$

$$\text{são } \hat{\beta}_G \text{ e } \hat{\sigma}^2_G.$$

