

Econometria e Métodos de Modelização I

Licenciatura em Economia

TÓPICOS NO
MODELO DE REGRESSÃO LINEAR MÚLTIPLA,
MRLM

Luís Filipe Martins

luis.martins@iscte.pt

<http://home.iscte.pt/~lfsm>

Departamento de Métodos Quantitativos,
ISCTE - Escola de Gestão

Lisboa, Janeiro de 2006

1 Introdução

- Como definir Econometria? Qual a sua importância?
- Tipos de dados:
 - Seccionais
 - Seccionais agrupados
 - Painel
 - Séries Temporais
 - Spatial
- Descernir causalidade / Efeitos *Ceteribus Paribus*

Example 1 *Retornos na educação:*

$$\text{Salário} = \beta_1 + \beta_2 \text{AnosEscolaridade} + \text{erro}$$

Example 2 *Função de produção Cobb-Douglas:*

$$\text{Output} = \beta_1 \cdot \text{Trabalho}^{\beta_2} \cdot \text{Capital}^{\beta_3} \cdot \exp(\text{erro})$$

Example 3 *Propensão marginal ao consumo:*

$$\text{Consumo} = \beta_1 + \beta_2 \text{PIB} + \text{erro}$$

Example 4 *Curva de Phillips:*

$$\text{TaxaInflação} = \beta_2 \text{OutputGap} + \text{erro}$$

Example 5 *Paridade dos poderes de compra (PPP):*

$$\text{TaxaCambioNom} = \beta_1 + \beta_2 \text{RacioCPI's} + \text{erro}$$

2 Modelo de Regressão Linear Simples

- População:

$$y = \beta_1 + \beta_2 x + u \quad (1)$$

$$(y, x) = \dots; (\beta_1, \beta_2) = \dots; u = \dots$$

- Inferência sobre a Pop. com o recurso a uma Amostra de dimensão n , $\{(x_i, y_i) : i = 1, \dots, n\}$

- Hipóteses:

S1 $\{(x_i, y_i) : i = 1, \dots, n\}$ Amostra **aleatória** (*i.i.d.*) de dimensão n de (1) $\Rightarrow y_i = \beta_1 + \beta_2 x_i + u_i$

$$S2 \quad E(u|x) \stackrel{S2.1}{=} E(u) \stackrel{S2.2}{=} 0 \Rightarrow \begin{cases} E(y|x) = \beta_1 + \beta_2 x \\ Cov(x, u) = E(xu) = 0 \end{cases}$$

S3 $\sum_{i=1}^n (x_i - \bar{x})^2 > 0 \Rightarrow$ Não existe perfeita colinearidade (x tem variação).

$$S4 \quad V(u|x) = E(u^2|x) - [E(u|x)]^2 = \sigma^2, \text{ constante (Homocedasticidade)} \Rightarrow \begin{cases} V(y|x) = \sigma^2 \\ \sigma^2 \stackrel{S2}{=} E(u^2|x) \stackrel{S2.1}{=} E(u^2) = V(u) \end{cases}$$

S5 $u|x \sim Normal \Rightarrow y|x \sim Normal$

- Hypótese S1 é adequada (apenas) para dados seccionais. S1 tem de ser eliminada se independência não existir. Por

definição,

$$Cov(u_i, u_j | x_i, x_j) = E [(u_i - Eu_i | x_i) (u_j - Eu_j | x_j) | x_i, x_j].$$

Por $S2$, $Cov(u_i, u_j | x_i, x_j) = E [u_i u_j | x_i, x_j]$. Note que $S1$ implica $Cov(u_i, u_j | x_i, x_j) = E [u_i | x_i] E [u_j | x_j]$ e portanto $Cov(u_i, u_j | x_i, x_j) = 0, i \neq j$, ausência de autocorrelação nos erros $\Rightarrow Cov(y_i, y_j | x_i, x_j) = 0, i \neq j (S1)$.

- x determinístico (fixo) vs x estocástico; time series (dependência)

2.1 OLS (mínimos quadrados) - Método dos Momentos

- (β_1, β_2) Desconhecido! \Rightarrow Estimação (e inferência)
- Método:

$$(a) \quad (\hat{\beta}_1, \hat{\beta}_2) = \arg \min_{\beta_1, \beta_2} \sum_{i=1}^n u_i^2 =$$

$$\arg \min_{\beta_1, \beta_2} \sum_{i=1}^n (y_i - \beta_1 - \beta_2 x_i)^2 \Rightarrow FOC \quad (2)$$

- (b) (Pop $S2$) \Rightarrow (Amostra)

$$(\hat{\beta}_1, \hat{\beta}_2) : \begin{cases} (1/n) \sum_{i=1}^n (y_i - \hat{\beta}_1 - \hat{\beta}_2 x_i) = 0 \\ (1/n) \sum_{i=1}^n x_i (y_i - \hat{\beta}_1 - \hat{\beta}_2 x_i) = 0 \end{cases} \quad (3)$$

- Estimador:

$$\begin{cases} \widehat{\beta}_2 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} = \frac{n \sum_{i=1}^n x_i y_i - \sum_{i=1}^n x_i \sum_{i=1}^n y_i}{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2} = \beta_2 + \frac{\sum_{i=1}^n (x_i - \bar{x}) u_i}{\sum_{i=1}^n (x_i - \bar{x})^2} \\ \widehat{\beta}_1 = \bar{y} - \widehat{\beta}_2 \bar{x} \end{cases} \quad (4)$$

- Erros u_i Não observados! \Rightarrow Estimação (centrado): Resíduos

$$\widehat{u}_i = y_i - \widehat{y}_i = y_i - \widehat{E}(y_i | x_i) = y_i - \widehat{\beta}_1 - \widehat{\beta}_2 x_i. \quad (5)$$

$$\sum_{i=1}^n \widehat{u}_i = 0; \bar{u} = 0; \sum_{i=1}^n x_i \widehat{u}_i = 0; \bar{y} = \widehat{\beta}_1 + \widehat{\beta}_2 \bar{x}$$

- Coeficiente de determinação

$$R^2 = SSE/SST = 1 - SSR/SST, \quad (6)$$

onde

$$SST = SSE + SSR \quad (7)$$

$$SST = \sum_{i=1}^n (y_i - \bar{y})^2; SSE = \sum_{i=1}^n (\widehat{y}_i - \bar{y})^2; SSR = \sum_{i=1}^n \widehat{u}_i^2.$$

2.2 Valor Esperado e Variância do OLS

Proposition 1 *Sob as hipóteses S1-S3 e (1), o estimador OLS é centrado: $E(\widehat{\beta}_1 | \mathbf{x}) = \beta_1$; $E(\widehat{\beta}_2 | \mathbf{x}) = \beta_2$; $\mathbf{x} = (x_1, \dots, x_n)$*

- Numa dada amostra, $\widehat{\beta}$ pode estar próximo ou longe de β . No entanto, a distribuição de $\widehat{\beta}$ está centrada em torno do verdadeiro parâmetro β . **MAS:** E a variação média

(afastamento de β) na distribuição de $\hat{\beta}$? :

Proposition 2 *Sob as hipóteses S1-S4 e (1),*

$$V(\hat{\beta}_1|\mathbf{x}) = \frac{\sigma^2 (1/n) \sum_{i=1}^n x_i^2}{\sum_{i=1}^n (x_i - \bar{x})^2}; \quad (8)$$

$$V(\hat{\beta}_2|\mathbf{x}) = \frac{\sigma^2}{\sum_{i=1}^n (x_i - \bar{x})^2}; \quad (9)$$

$$\text{Cov}(\hat{\beta}_2, \hat{\beta}_1|\mathbf{x}) = \frac{-\sigma^2 \bar{x}}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (10)$$

- **MAS:** $V(\hat{\beta}|\mathbf{x})$ Desconhecido porque σ^2 Desconhecido! \Rightarrow Estimação:

Proposition 3 *Sob as hipóteses S1-S4 e (1),*

$$\hat{\sigma}^2 = \frac{1}{n-2} \sum_{i=1}^n \hat{u}_i^2 = SSR/(n-2) \quad (11)$$

é um estimador centrado para σ^2 . Idem para o desvio padrão da regressão $\hat{\sigma} = \sqrt{\hat{\sigma}^2}$.

- Substituindo (11) em (8), o desvio padrão de $\hat{\beta}$ é se $(\hat{\beta}|\mathbf{x}) = \sqrt{V(\hat{\beta}|\mathbf{x})}$.

3 Modelo de Regressao Linear Multipla - Estimacao

- Amostra de dimensao n , $\{(x_{i1}, \dots, x_{ik}, y_i) : i = 1, \dots, n\}$:

$$y_i = \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i = x_i' \beta + u_i, i = 1, \dots, n \quad (12)$$

- Incluir o termo independente, $x_{i1} = 1, i = 1, \dots, n$:

$$y_i = \beta_1 + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u_i = x_i' \beta + u_i, i = 1, \dots, n \quad (13)$$

- Notacao matricial:

$$y = X\beta + u$$

$$x_{i \times k} = (1, x_{i2}, \dots, x_{ik})', i = 1, \dots, n; \beta_{k \times 1} = (\beta_1, \beta_2, \dots, \beta_k)';$$

$$y_{n \times 1} = \begin{pmatrix} y_1 \\ \dots \\ y_n \end{pmatrix}; X_{n \times k} = \begin{pmatrix} x_1' \\ \dots \\ x_n' \end{pmatrix} = \begin{pmatrix} 1 & x_{12} & \dots & x_{1k} \\ \dots & \dots & & \dots \\ 1 & x_{n2} & \dots & x_{nk} \end{pmatrix};$$

$$u_{n \times 1} = (u_1, \dots, u_n)'.$$

- Hipoteses (ver S1-S5):

M1 (dados seccionais) $\{(x_{i1}, \dots, x_{ik}, y_i) : i = 1, \dots, n\}$
Amostra **aleatoria** (*i.i.d.*).

M2 (exogeneidade estrita) $E(u_i|X) = E(u_i|x_1, \dots, x_n) = 0, i = 1, \dots, n \Leftrightarrow E(u|X) = 0_{n \times 1}$

M3 (nao existe perfeita colinearidade). $rank(X) = k$.: nenhum dos regressores x_{i2}, \dots, x_{ik} e constante para todo i (existe

termo independente β_1) e não existe qualquer combinação linear entre eles.

M4 (homocedasticidade e ausência de autocorrelação nos erros)

$$\Omega_{n \times n} = V(u|X) \stackrel{M2}{=} E(uu'|X) = \begin{pmatrix} E(u_1^2|X) & \dots & E(u_1u_n|X) \\ \dots & \dots & \dots \\ E(u_nu_1|X) & \dots & E(u_n^2|X) \end{pmatrix} \quad (14)$$

$$M4 : \Omega = \begin{pmatrix} \sigma^2 & \dots & 0 \\ \dots & \dots & \dots \\ 0 & \dots & \sigma^2 \end{pmatrix} = \sigma^2 I_n$$

M4.1 $V(u_i|X) \stackrel{M2}{=} E(u_i^2|X) = \sigma^2$, constante, $i = 1, \dots, n$.

M4.2 $Cov(u_i, u_j|X) \stackrel{M2}{=} E(u_iu_j|X) = 0$, $i, j = 1, \dots, n, i \neq j$.

Nota: $M1 \Rightarrow M4.2$

M5 (normalidade) $u|X \sim Normal$

- Observações:

$$M1 \Rightarrow \begin{cases} E(u_i|X) = E(u_i|x_i) \\ E(u_i^2|X) = E(u_i^2|x_i) \\ E(u_iu_j|X) = E(u_i|x_i)E(u_j|x_j) \end{cases}$$

$$\Leftrightarrow \begin{cases} E(u_i|X) = E(u_i|x_{i1}, \dots, x_{ik}) \\ E(u_i^2|X) = E(u_i^2|x_{i1}, \dots, x_{ik}) \\ E(u_iu_j|X) = E(u_i|x_{i1}, \dots, x_{ik})E(u_j|x_{j1}, \dots, x_{jk}) \end{cases}$$

$M2, M4, M5 \Rightarrow u|X \sim N_n(0, \Omega); y|X \sim N_n(X\beta, \Omega)$

(12), $M1 - M4$: Hipóteses de Gauss-Markov

(12), $M1 - M5$: Hipóteses clássicas do MRLM.

3.1 OLS - Método dos Momentos para $\beta = (\beta_1, \dots, \beta_k)'$

- Método:

$$\hat{\beta} = \arg \min_{\beta} \sum_{i=1}^n (y_i - x_i' \beta)^2 =$$

$$\arg \min_{\beta} (y - X\beta)' (y - X\beta) = \arg \min_{\beta} u' u \Rightarrow FOC$$

(Pop M2) \Rightarrow (Amostra)

$$\hat{\beta} = (\hat{\beta}_1, \dots, \hat{\beta}_k) : \begin{cases} (1/n) \sum_{i=1}^n (y_i - x_i' \beta) = 0 \\ (1/n) \sum_{i=1}^n x_{i2} (y_i - x_i' \beta) = 0 \\ \dots \\ (1/n) \sum_{i=1}^n x_{ik} (y_i - x_i' \beta) = 0 \end{cases} \quad (15)$$

- Estimador:

$$\hat{\beta}_{k \times 1} = (X'X)^{-1} X'y = \left(\sum_{i=1}^n x_i x_i' \right)^{-1} \sum_{i=1}^n x_i y_i \quad (16)$$

$$= \begin{pmatrix} n & \sum_{i=1}^n x_{i2} & \dots & \sum_{i=1}^n x_{ik} \\ \sum_{i=1}^n x_{i2} & \sum_{i=1}^n x_{i2}^2 & \dots & \sum_{i=1}^n x_{i2} x_{ik} \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \sum_{i=1}^n x_{ik}^2 \end{pmatrix}^{-1} \begin{pmatrix} \sum_{i=1}^n y_i \\ \sum_{i=1}^n x_{i2} y_i \\ \dots \\ \sum_{i=1}^n x_{ik} y_i \end{pmatrix} \quad (17)$$

$$= \beta + (X'X)^{-1} X'u = \beta + \left(\sum_{i=1}^n x_i x_i' \right)^{-1} \sum_{i=1}^n x_i u_i \quad (18)$$

- Interpretação: *Ceteribus Paribus*; Efeitos parciais (estimar efeito de x_{il} em \hat{y}_i depois de retirados os efeitos de x_{ih} , $h \neq l$ - parte de x_{il} correlacionada com x_{ih})

$$\hat{y}_i = E(y_i | \widehat{x_{i2}, \dots, x_{ik}}) = \hat{\beta}_1 + \hat{\beta}_2 x_{i2} + \dots + \hat{\beta}_k x_{ik} \Rightarrow \quad (19)$$

$$\begin{cases} \Delta \hat{y}_i = \hat{\beta}_2 \Delta x_{i2} + \dots + \hat{\beta}_k \Delta x_{ik} \\ E(y_i | x_{i2} = 0, \dots, x_{ik} = 0) = \hat{\beta}_1 \end{cases} \quad (20)$$

MRLM \rightarrow *MRLS* se $\hat{\beta}_3 = 0$ ou x_{i2} e x_{i3} não correlacionados (na amostra).

- Resíduos

$$\hat{u}_i = y_i - \hat{y}_i = y_i - E(y_i | x_i) = y_i - x_i' \hat{\beta}, i = 1, \dots, n \quad (21)$$

$$\hat{u}_{n \times 1} = y - X \hat{\beta}; SSR = \hat{u}' \hat{u} \quad (22)$$

- Coeficiente de determinação

$$R^2 = 1 - SSR/SST = \frac{\left(\sum_{i=1}^n (y_i - \bar{y}) (\hat{y}_i - \bar{\hat{y}}) \right)^2}{\left(\sum_{i=1}^n (y_i - \bar{y})^2 \right) \left(\sum_{i=1}^n (\hat{y}_i - \bar{\hat{y}})^2 \right)}, \quad (23)$$

$$R^2 \uparrow \text{ com } k!! \Rightarrow R_{adj}^2 = 1 - (1 - R^2) \frac{n-1}{n-k}.$$

3.2 Momentos do Estimador OLS $\hat{\beta} = (\hat{\beta}_1, \dots, \hat{\beta}_k)'$

Proposition 4 Sob as hipóteses M1-M3 e (12), o estimador OLS

é centrado: $E\left(\widehat{\beta}|X\right) = \beta_{k \times 1}$.

Proposition 5 *Sob as hipóteses M1-M4 e (12), Hipóteses de Gauss-Markov,*

$$\Sigma_{k \times k} = V\left(\widehat{\beta}|X\right) = E\left(\left(\widehat{\beta} - \beta\right)\left(\widehat{\beta} - \beta\right)' | X\right) \quad (24)$$

$$= \begin{pmatrix} V(\widehat{\beta}_1|X) & \dots & Cov(\widehat{\beta}_1, \widehat{\beta}_k|X) \\ \dots & & \dots \\ \dots & \dots & V(\widehat{\beta}_k|X) \end{pmatrix} \quad (25)$$

$$= \sigma^2 \left(X'X\right)^{-1} = \sigma^2 \left(\sum_{i=1}^n x_i x_i'\right)^{-1}; \quad (26)$$

$$V(\widehat{\beta}_j|X) = \frac{\sigma^2}{SST_j (1 - R_j^2)}; SST_j = \sum_{i=1}^n (x_{ij} - \bar{x}_j)^2; \quad (27)$$

$j = 2, \dots, k$ e R_j^2 resulta da regressão de x_{ij} em x_{il} , $l \neq j$ com um termo independente. Nota: Multicolinearidade ...

Proposition 6 *Sob as hipóteses M1-M4 e (12), Hipóteses de Gauss-Markov,*

$$\widehat{\sigma}^2 = \frac{1}{n - k} \sum_{i=1}^n \widehat{u}_i^2 = SSR/(n - k) \quad (28)$$

é um estimador centrado para σ^2 . Idem para o desvio padrão da regressão $\widehat{\sigma} = \sqrt{\widehat{\sigma}^2}$.

- **Portanto,** $\widehat{\Sigma}_{k \times k}$ resulta de substituir σ^2 (desconhecido) por $\widehat{\sigma}^2$ (estimativa). O desvio padrão de $\widehat{\beta}_j$ é se $\left(\widehat{\beta}_j | X\right) = \sqrt{\widehat{\Sigma}_{jj}}$ e é obtido da $diag\left(\widehat{\Sigma}\right)$.
- Inclusão de variáveis estatisticamente insignificativas (irrelevantes) $\Rightarrow \widehat{\beta}$ centrado mas perda de eficiência, " $V\left(\widehat{\beta} | \mathbf{x}\right)$ " \uparrow
- Omissão de variáveis estatisticamente significativas $\Rightarrow \widehat{\beta}$ enviesado (excepto regressores não correlacionados na amostra - ver $MRLM \rightarrow MRLS$) mas " $V\left(\widehat{\beta} | \mathbf{x}\right)$ " \downarrow (excepto regressores não correlacionados na amostra). Medida *Mean Squared Error* ... " $V\left(\widehat{\beta} | \mathbf{x}\right)$ " $\downarrow 0$ quando $n \uparrow \infty$.

Proposition 7 (Gauss-Markov) *Sob as hipóteses M1-M4 e (12), Hipóteses de Gauss-Markov, o estimador OLS $\widehat{\beta}$ é BLUE (best - Eficiência - na classe dos linear unbiased estimators). **Conclusão:** Se as hipóteses de Gauss-Markov forem satisfeitas, utilize-se o OLS.*

4 MRLM - Inferência

- Importância da hipótese $M5$! $M5$ não se verifica em muitos modelos! Para as propriedades assintóticas (ver o próximo capítulo) $M5$ pode ser eliminada.
- Passos: (i) H_0 (e H_1); (ii) Estatística de teste T ; (iii) Distribuição de T ; (iv) Nivel de significância $\alpha = P_{H_0}(\text{Re } j H_0)$ (erro de tipo I, $\alpha = 0.05$ normalmente) e valor(es) crítico(s); (v) Regra de decisão (T_{obs} e v.c.), regiões crítica e de aceitação; (vi) $100(1 - \alpha)\%$ Intervalo de confiança ((iii) sob H_0).
- (v):
 - (a) H_1 Unilateral: $P_{H_0}(T > vc) = \alpha$, para $H_1 : \theta > \theta_0$, OU $P_{H_0}(T < vc) = \alpha$, para $H_1 : \theta < \theta_0$.
 - (b) $H_1 : \theta \neq \theta_0$ Bilateral (normalmente): $P_{H_0}(|T| > vc) = \alpha$, se simétrica OU $P_{H_0}(T > vc_1) = \frac{\alpha}{2}$, $P_{H_0}(T < vc_2) = \frac{\alpha}{2}$ se não é simétrica.
- Potência do teste $\pi(\theta) = 1 - P_{H_1}(AcH_0)$
- $p - value$ é o maior valor para α para o qual ainda não se rejeita H_0 :
 - (a) H_1 Unilateral: $p = P_{H_0}(T > T_{obs})$, para $H_1 : \theta > \theta_0$.
 - (b) $H_1 : \theta \neq \theta_0$ Bilateral: $p = P_{H_0}(|T| > |T_{obs}|)$ se simétrica.

Proposition 8 *Sob as Hipóteses clássicas do MRLM, (12), $M1 -$*

M5, o estimador OLS $\hat{\beta}$ é BUE e

$$\hat{\beta}|X \sim N_k(\beta, \Sigma); \frac{\hat{\beta}_j - \beta_j}{\sqrt{\Sigma_{jj}}} \sim N(0, 1), j = 1, \dots, k \quad (29)$$

- **MAS σ^2 não é conhecido!:**

Proposition 9 *Sob as Hipóteses clássicas do MRLM, (12), M1–M5,*

$$\frac{SSR}{\sigma^2} = \frac{\hat{u}'\hat{u}}{\sigma^2} = (n - k) \frac{\hat{\sigma}^2}{\sigma^2} \sim \chi_{n-k}^2 \text{ e} \quad (30)$$

$$\frac{\hat{\beta}_j - \beta_j}{\sqrt{\hat{\Sigma}_{jj}}} \sim t_{n-k}, j = 1, \dots, k \quad (31)$$

4.1 Testes t (uma restrição linear)

- Rácio t; (In)Significância estatística (a um nível α) de $\beta_j \Rightarrow x_{ij}$:

$$H_0 : \beta_j = 0; t_{\hat{\beta}_j} = \frac{\hat{\beta}_j}{\sqrt{\hat{\Sigma}_{jj}}} \sim t_{n-k}; H_1 : \beta_j \leq 0 \text{ ou } H_1 : \beta_j \neq 0 \quad (32)$$

- Valor específico, não nulo, para β_j : $H_0 : \beta_j = \beta_{j0}$;

$$t = \frac{\hat{\beta}_j - \beta_{j0}}{\sqrt{\hat{\Sigma}_{jj}}} \sim t_{n-k}; H_1 : \beta_j \leq \beta_{j0} \text{ ou } H_1 : \beta_j \neq \beta_{j0} \quad (33)$$

- Uma combinação linear para β :

$$H_0 : r_1\beta_1 + \dots + r_k\beta_k = r'\beta = q; \quad (34)$$

$$t = \frac{\hat{q} - q}{se(\hat{q})} \sim t_{n-k}; \hat{q} = r'\hat{\beta}; se(\hat{q}) = \sqrt{r'\hat{\Sigma}r} \quad (35)$$

Example 6 $H_0 : \beta_2 = \beta_3$;

$$t = \frac{\hat{\beta}_2 - \hat{\beta}_3}{se(\hat{\beta}_2 - \hat{\beta}_3)} \sim t_{n-k}; se(\hat{\beta}_2 - \hat{\beta}_3) = \sqrt{\hat{\Sigma}_{22} + \hat{\Sigma}_{33} - 2\hat{\Sigma}_{23}}.$$

Alternativa: Transformar o modelo sob $H_0 : \beta_2 = \beta_3$.

4.2 Intervalo de Confiança

- σ^2 conhecido e $\alpha = 0.05$:

$$P\left(\hat{\beta}_j - 1.96\sqrt{\Sigma_{jj}} < \beta_j < \hat{\beta}_j + 1.96\sqrt{\Sigma_{jj}}\right) = 0.95$$

- σ^2 não conhecido:

$$P\left(\hat{\beta}_j - t_{n-k,\alpha/2}^*\sqrt{\hat{\Sigma}_{jj}} < \beta_j < \hat{\beta}_j + t_{n-k,\alpha/2}^*\sqrt{\hat{\Sigma}_{jj}}\right) = 1 - \alpha;$$

$$P\left(t_{n-k} > \left|t_{n-k,\alpha/2}^*\right|\right) = \alpha$$

- Notas:

(a) Antes de se obter uma amostra, $\hat{\beta}_j - 1.96\sqrt{\Sigma_{jj}} < \beta_j < \hat{\beta}_j + 1.96\sqrt{\Sigma_{jj}}$ é um intervalo aleatório;

(b) Após a obtenção de uma amostra ($\hat{\beta}_j$ é um numero real), a probabilidade de

$$\beta_j \in \left[\hat{\beta}_j - t_{n-k,\alpha/2}^* \sqrt{\hat{\Sigma}_{jj}}, \hat{\beta}_j + t_{n-k,\alpha/2}^* \sqrt{\hat{\Sigma}_{jj}}\right]$$

é zero ou um;

(c) Como para k fixo, $t_{n-k} \rightarrow N(0, 1)$ quando $n \rightarrow \infty$, usar $t_{n-k,\alpha/2}^* = 1.96$ para n elevado.

4.3 Testes F (múltiplas restrições lineares)

- Teste F; Teste à (in)significância estatística global do modelo (a um nível α , $\beta_j \Rightarrow x_{ij}, j = 2, \dots, k$) :

$$H_0 : \beta_2 = \dots = \beta_k = 0; H_1 : \text{Pelo menos um deles} \neq 0 \quad (36)$$

$$F = \frac{R^2 / (k - 1)}{(1 - R^2) / (n - k)} \sim F_{k-1, n-k}; \quad (37)$$

$$F = \frac{SSE / (k - 1)}{SSR / (n - k)} = \frac{\left(\hat{\beta}' X' y - n\bar{y}^2\right) / (k - 1)}{\left(y'y - \hat{\beta}' X' y\right) / (n - k)} \quad (38)$$

- Forma geral (j restrições), $H_0 : R_{j \times k} \beta_{k \times 1} = q_{j \times 1}$;

(a) σ^2 conhecido: $W = \hat{d} \left[V \left(\hat{d} \right) \right]^{-1} \hat{d}$;

$$W \sim \chi_j; \hat{d} = R\hat{\beta} - q; V \left(\hat{d} \right) = \sigma^2 R \left(X' X \right)^{-1} R' \quad (39)$$

(b) σ^2 não conhecido:

$$F = \frac{\left(R_{UR}^2 - R_R^2 \right) / j}{\left(1 - R_{UR}^2 \right) / \left(n - k \right)} \sim F_{j, n-k} \quad (40)$$

$$F = \frac{\left(SSR_R - SSR_{UR} \right) / j}{SSR_{UR} / \left(n - k \right)} = \hat{d} \left[\widehat{V \left(\hat{d} \right)} \right]^{-1} \hat{d} / j \quad (41)$$

$$\widehat{V \left(\hat{d} \right)} = \hat{\sigma}^2 R \left(X' X \right)^{-1} R' \quad (42)$$

onde R_R^2, SSR_R são para o modelo sob H_0 e R_{UR}^2, SSR_{UR} sobre o modelo original (sem restrições).

Example 7 (In)Significância de m regressores:

H_0 : $\beta_{k-m+1} = \dots = \beta_k = 0$; H_1 : Pelo menos um deles $\neq 0$

$$F = \frac{\left(SSR_R - SSR_{UR} \right) / m}{SSR_{UR} / \left(n - k \right)} = \frac{\left(R_{UR}^2 - R_R^2 \right) / m}{\left(1 - R_{UR}^2 \right) / \left(n - k \right)} \sim F_{m, n-k}.$$

Se $m = 1$, $F = t^2$.

5 MRLM - Propriedades Assimptóticas

- Propriedades quando $n \rightarrow \infty$, ou seja, quando n é "grande" / aumenta indefinidamente? Comparar com propriedades para n fixo / "pequeno" / amostra de dimensão finita dos capítulos anteriores.
- Lei(s) dos grandes numeros ((U)LLN); Teorema(s) do limite central ((F)CLT).

5.1 Consistência

- Consistência *versus* Centrado (ver Prop 4 e 7). E se um estimador não é centrado? Apesar disso, é consistente (à medida que $n \uparrow$ o enviesamento desaparece)? Em caso afirmativo, utilize-se desde que n seja "grande". Caso contrário, nem o considere!
- Um estimador é Consistente se a sua distribuição (que depende de n) fica totalmente concentrada no verdadeiro parametro quando $n \rightarrow \infty$: $p \lim_{n \rightarrow \infty} \hat{\beta} = \beta$. Uma condição necessária (mas não suficiente) é portanto que $V(\hat{\beta}) \rightarrow 0$ quando $n \rightarrow \infty$.
- Hipótese $M2'$: $E(u_i) = 0$ e $Cov(u_i, x_{ij}) = 0, j = 1, \dots, k, \forall i$.
 $M2 \Rightarrow M2'$

Proposition 10 *Sob as hipoteses $M1, M2', M3$ e (12), o estimador*

OLS é consistente: $p \lim_{n \rightarrow \infty} \hat{\beta} = \beta$.

- Notas:

(a) Como corolário, $p \lim_{n \rightarrow \infty} \hat{\beta} = \beta$ também sob hipóteses $M1, M2, M3$ e (12).

(b) Mas, sob $M1, M2', M3$ e (12), $\hat{\beta}$ pode não ser centrado!

(c) Se $M2'$ não se verificar, $\hat{\beta}$ é inconsistente (além de enviesado, claro!)

5.2 Normalidade e Inferência Assimptótica

- Derivar distribuição (assimpt.) de $\hat{\beta}$ e conseqüente inferência SEM impor normalidade (!) dos erros, $M5$ (ver Prop 8 e 9). Para isso, invoca-se CLT e em aplicações utiliza-se uma amostra com n "grande". OLS é BLUE mesmo sem $M5$.

Proposition 11 *Sob as hipóteses $M1-M4$ e (12), $p \lim_{n \rightarrow \infty} \hat{\sigma}^2 = \sigma^2$ e*

$$\sqrt{n} (\hat{\beta} - \beta) \xrightarrow{d} N(0, \sigma^2 M_{XX}^{-1}); \frac{\hat{\beta}_j - \beta_j}{\sqrt{\hat{\Sigma}_{jj}}} \xrightarrow{d} N(0, 1), j = 1, \dots, k \quad (43)$$

onde $M_{XX} = p \lim_{n \rightarrow \infty} \left(\frac{1}{n} \sum_{i=1}^n x_i x_i' \right)$.

- Observação: Para k fixo, $Y_n \xrightarrow{d} N(0, 1)$ em que $Y_n \sim t_{n-k}$.

5.3 Eficiência Assimptótica

- OLS é BLUE sem $M5$ e BUE com $M5$ (ver 7 e 8). E se retirar-mos $M5$ e estiver-mos interessados em $n \rightarrow \infty$ (substituir U por C=consistente)? Há condições em que o OLS é (assimptoticamente) "Best", tendo a menor variância assimptótica para $\sqrt{n} \left(\tilde{\beta}_j - \beta_j \right)$:

Proposition 12 *Sob as hipoteses $M1-M4$ e (12), além de consistente o OLS é BAN (best asymptotically normal) na classe CAN de estimadores lineares.*

6 Alguns Tópicos no MRLM

6.1 Unidades de Medida

- Consequências no modelo quando as unidades de medida das variáveis muda(m):

$$\widehat{E}(y|x) = \hat{\beta}_1 + \hat{\beta}_2 x \rightarrow \widehat{E}(\tilde{y}|\tilde{x}) = \tilde{\beta}_1 + \tilde{\beta}_2 \tilde{x}; \tilde{y} = ay; \tilde{x} = bx$$

-

$$\begin{aligned} \tilde{\beta}_1 &= a\hat{\beta}_1; \tilde{\beta}_2 = \frac{a}{b}\hat{\beta}_2; \\ se(\tilde{\beta}_1) &= a.se(\hat{\beta}_1); se(\tilde{\beta}_2) = \frac{a}{b}se(\hat{\beta}_2); \\ t_{\tilde{\beta}_1}, t_{\tilde{\beta}_2}, R^2 &\text{ inalterados} \end{aligned}$$

6.2 Erros de Medida

- Variável dependente e/ou regressor(es) não é correctamente observado mas contém um erro na sua medição.

Example 8 $Sav^* = \beta_1 + \beta_2 Inc + u$, onde Inc é rendimento disponível e Sav^* é poupança mas que é medida com erro: $e = Sav - Sav^*$, $E(e) = 0$, $V(e) = \sigma_e^2$, onde Sav é o verdadeiro valor. Consequências para $\hat{\beta}$?

- O verdadeiro modelo (DGP) é $Sav = \beta_1 + \beta_2 Inc + (u + e)$.

- $\hat{\beta}$ perde eficiência: $Var(u + e) = \sigma_u^2 + \sigma_e^2 > \sigma_u^2$ com $Cov(u, e) = 0$.
- $\hat{\beta}_1$ não é centrado se $E(e) \neq 0$ e $\hat{\beta}$ é inconsistente se $Cov(Inc, e) \neq 0$.

Example 9 $Sav = \beta_1 + \beta_2 Inc^* + u$, onde Sav é poupança e Inc^* é rendimento disponível mas que é medido com erro: $e = Inc - Inc^*$, $E(e) = 0$, $V(e) = \sigma_e^2$, onde Inc é o verdadeiro valor. Consequências para $\hat{\beta}_2$?

- O DGP é $Sav = \beta_1 + \beta_2 Inc + (u - \beta_2 e)$.
- $\hat{\beta}_2$ é inconsistente:

$$p \lim_{n \rightarrow \infty} \hat{\beta}_2 = \beta_2 + \frac{Cov(u - \beta_2 e, Inc)}{V(Inc)} = \beta_2 \left(\frac{\sigma_{Inc^*}^2}{\sigma_{Inc^*}^2 + \sigma_e^2} \right) < \beta_2,$$

porque

$$\begin{aligned} Cov(u - \beta_2 e, Inc) &= Cov(u, Inc) + Cov(-\beta_2 e, Inc) \\ &= -\beta_2 \sigma_e^2 \neq 0, \end{aligned}$$

com $Cov(e, Inc) = E(e \cdot Inc) = E(e^2) - E(e \cdot Inc^*) = \sigma_e^2$, assumindo que $Cov(u, Inc) = 0$ e $Cov(e, Inc^*) = 0$.

- "Nota": A qualidade do processo de amostragem condiciona a existência de erros de medida.

6.3 Inclusão de Variáveis Irrelevantes e Omissão de

Relevantes

- Consequências para o modelo?

Example 10 $Sal = \beta_1^* + \beta_2^* Exp + \beta_3^* Pet + u$, onde Sal é salário, Exp é anos de experiência e Pet é o número de animais de estimação que o presidente da junta a que pertence o individuo tem (naturalmente, $\beta_3^* = 0$.) Consequências para $\hat{\beta}^*$?

- $\hat{\beta}^*$ centrado mas em geral perde eficiência.

Example 11 $Sal = \beta_1^* + \beta_2^* Exp + u$, onde Sal é salário, Exp é anos de experiência e u inclui a variável idade que está correlacionada com Exp . Consequências para $\hat{\beta}_2^* = \frac{\sum_{i=1}^n (Exp_i - \overline{Exp}) Sal_i}{\sum_{i=1}^n (Exp_i - \overline{Exp})^2}$?

- O verdadeiro modelo é $Sal = \beta_1 + \beta_2 Exp + \beta_3 Id + v$, $\beta_3 \neq 0$.
- $\hat{\beta}_2^*$ não é centrado porque $\beta_3 \neq 0$ e $\hat{\delta}_2 \neq 0$:

$$\begin{aligned} E\left(\hat{\beta}_2^* | Exp, Id\right) &= \beta_2 + \beta_3 \frac{\sum_{i=1}^n (Exp_i - \overline{Exp}) Id_i}{\sum_{i=1}^n (Exp_i - \overline{Exp})^2} \\ &= \beta_2 + \beta_3 \hat{\delta}_2 \neq \beta_2, \end{aligned}$$

onde $E(Id | Exp) = \delta_1 + \delta_2 Exp$, uma função de Exp !

- Inconsistente (não corrige o bias assintoticamente): Como

$$\text{Cov}(Id, Exp) \neq 0,$$

$$p \lim_{n \rightarrow \infty} \hat{\beta}_2^* = \beta_2 + \beta_3 \frac{\text{Cov}(Id, Exp)}{V(Exp)} \neq \beta_2.$$

- Para $\beta_3 > 0$ e $\sum_{i=1}^n (Exp_i - \overline{Exp}) Id_i > 0$ e $\text{Cov}(Id, Exp) > 0$, os enviesamentos (finito ou assintótico) são de sinal positivo ($\hat{\beta}_2^*$ sobreavalia o verdadeiro valor $\hat{\beta}_2$).
- "Observação": A inclusão de variáveis irrelevantes pode e deve ser controlada mas a omissão de relevantes nem sempre é possível de controlar.

6.4 Regressão na Origem

- Para $\beta_1 = 0$,

$$\widehat{E}(y|x) = \tilde{\beta}_2 x; \tilde{\beta}_2 = \frac{\sum_{i=1}^n x_i y_i}{\sum_{i=1}^n x_i^2} = \beta_2 + \frac{\sum_{i=1}^n x_i u_i}{\sum_{i=1}^n x_i^2}.$$

- Se na verdade, $\beta_1 \neq 0$, então $\tilde{\beta}_2$ é inconsistente.
- Se na verdade $\beta_1 = 0$ em $\widehat{E}(y|x) = \hat{\beta}_1 + \hat{\beta}_2 x$ então $\hat{\beta}_2$ perde eficiência.
- "Regra": Sem informação em contrário, especificar o MRLM COM termo independente β_1 .

6.5 Variáveis Dummy e Teste de Chow

- X contém regressores que não são mensuráveis: Uso de

variáveis binárias (Dummy) para representar variáveis de natureza qualitativa, $D_i = \begin{cases} 1, & \text{se } i \in A \\ 0, & \text{se } i \notin A \end{cases}$, A é um certo atributo para a i -ésima observação.

- Notas:
 - (a) Todos os elementos do conjunto correspondente à variável qualitativa têm de estar representados em $D_i = 1$ ou $D_i = 0$.
 - (b) Num modelo com termo independente e para uma variável que admite r atributos diferentes, no máximo apenas se podem utilizar $r - 1$ dummies como regressores.
 - (c) Aplicação natural a modelos time series com sazonalidade.
 - (d) Mantém-se as fórmulas e propriedades do OLS e inferência.

Example 12 $D_i = \begin{cases} 1, & \text{se } i \text{ masculino} \\ 0, & \text{se } i \text{ feminino} \end{cases}$, $D_t = \begin{cases} 1, & \text{se } t \text{ guerra} \\ 0, & \text{se } t \text{ paz} \end{cases}$,

$D_t = \begin{cases} 1, & \text{se } t \text{ é } 1^\circ \text{ trimestre} \\ 0, & \text{se caso contrário} \end{cases}$, $D_i = \begin{cases} 1, & \text{se } i \text{ norte} \\ 0, & \text{se caso contrário} \end{cases}$,

$D_{1i} = \begin{cases} 1, & \text{se } i \text{ formação superior} \\ 0, & \text{se caso contrário} \end{cases}$, $D_{2i} = \begin{cases} 1, & \text{se } i \text{ secundária} \\ 0, & \text{se caso contrário} \end{cases}$,

$D_{3i} = \begin{cases} 1, & \text{se } i \text{ primária} \\ 0, & \text{se caso contrário} \end{cases}$, $D_{4i} = \begin{cases} 1, & \text{se } i \text{ não tem formação} \\ 0, & \text{se caso contrário} \end{cases}$

- Possíveis especificações (ver papel de Dummies no termo independente e declive ...):

- (a) $y_i = \beta_1 + \beta_2 D_i + u_i$
- (b) $y_i = \beta_1 + \beta_2 x_i + \beta_3 D_i + u_i$
- (c) $y_i = \beta_1 + \beta_2 x_i + \beta_3 x_i D_i + u_i$
- (d) $y_i = \beta_1 + \beta_2 x_i + \beta_3 D_i + \beta_4 x_i D_i + u_i$
- (e) $y_i = \beta_1 + \beta_2 D_{1i} + \beta_3 D_{2i} + \beta_4 D_{3i} + u_i$
- (f) $y_i = \beta_1 + \beta_2 D_i + \beta_3 D_{1i} + \beta_4 D_{2i} + \beta_5 D_{3i} + \beta_6 D_i D_{1i} + \beta_7 D_i D_{2i} + \beta_8 D_i D_{3i} + u_i$

- Testar se há diferenças entre **dois** grupos: Teste de Chow (ilustrado para um regressor apenas).

$$y_i = \beta_1 + \beta_2 x_i + u_i, i \in \text{Grupos 1 e 2}, SSR, n$$

$$y_i = \beta_1 + \beta_2 x_i + u_i, i \in \text{Grupo 1}, SSR_1, n_1$$

$$y_i = \beta_1 + \beta_2 x_i + u_i, i \in \text{Grupo 2}, SSR_2, n_2$$

$$n = n_1 + n_2; SSR \geq SSR_1 + SSR_2.$$

- (a) H_0 : Não há diferença estatística entre os **dois** grupos (eliminar Dummies do modelo).

(b)

$$F = \frac{(SSR - (SSR_1 + SSR_2)) / k}{(SSR_1 + SSR_2) / (n - 2k)} \sim F_{k, n-2k} \quad (44)$$

- O teste de Chow é uma alternativa a um teste F standard sob

todos os regressores com dummies

$$y_i = \beta_1 + \beta_2 x_i + \beta_3 D_i + \beta_4 x_i D_i + u_i, SSR_{UR}, n \quad (45)$$

onde $SSR_{UR} = SSR_1 + SSR_2$; $SSR \geq SSR_{UR}$.

6.6 Forma Funcional

- O MRL (1), (12) é não só linear em β (MRL) mas também em X . MAS: Modelos teóricos e Dados podem induzir relações não lineares entre y e X :

- (a) $\ln y = \beta_1 + \beta_2 \ln x + u : \beta_2 = \frac{d \ln y}{d \ln x} = \frac{dy/y}{dx/x}$, elasticidade de y em relação a x .
- (b) $y = \beta_1 + \beta_2 \ln x + u : \beta_2 = \frac{dy}{dx/x}$
- (c) $\ln y = \beta_1 + \beta_2 x + u : \beta_2 = \frac{dy/y}{dx}$
- (d) $y = \beta_1 + \beta_2 x + \beta_3 x^2 + u : \frac{dy}{dx} = \beta_2 + 2\beta_3 x$, não constante
- (e) $y = \beta_1 + \beta_2 x + \beta_3 z + \beta_4 xz + u : \frac{dy}{dx} = \beta_2 + \beta_4 z, \dots$
- (f) $y = \beta_1 + \beta_2 \frac{1}{x} + u$
- (g) ...

6.7 Previsão

- O MRL (1), (12) pode ser usado para prever $E y$ (previsão média) ou y (previsão individual) condicionado à realização $x_{0_{k \times 1}} = (1, x_{02}, \dots, x_{0k})'$.
- Média: Prever $E(y_0 | x_0) = x_0' \beta$:

(a) Pontual: $E(\widehat{y_0|x_0}) = x_0' \widehat{\beta} = \widehat{y_0}$

(b) Intervalo:

$$P\left(\widehat{y_0} - t_{n-k, \alpha/2}^* \widehat{\sigma}_{pm} < E(y_0|x_0) < \widehat{y_0} + t_{n-k, \alpha/2}^* \widehat{\sigma}_{pm}\right) = 1 - \alpha, \quad (46)$$

onde $P\left(t_{n-k} > \left|t_{n-k, \alpha/2}^*\right|\right) = \alpha$ e

$$\widehat{\sigma}_{pm}^2 = V(\widehat{y_0|x_0}) = V\left(x_0' \widehat{\beta} | x_0\right) = x_0' \widehat{\Sigma} x_0 = \widehat{\sigma}^2 x_0' \left(X' X\right)^{-1} x_0 \quad (47)$$

• Individual: Prever $y_0|x_0 = x_0' \beta + u_0$

(a) Pontual: $\widehat{y_0|x_0} = x_0' \widehat{\beta} = \widehat{y_0}$

(b) Intervalo:

$$P\left(\widehat{y_0} - t_{n-k, \alpha/2}^* \widehat{\sigma}_{pi} < E(y_0|x_0) < \widehat{y_0} + t_{n-k, \alpha/2}^* \widehat{\sigma}_{pi}\right) = 1 - \alpha; \quad (48)$$

onde

$$\widehat{\sigma}_{pi}^2 = V(\widehat{y_0} + u_0 | x_0) = \widehat{\sigma}^2 \left(1 + x_0' \left(X' X\right)^{-1} x_0\right) = \widehat{\sigma}^2 + \widehat{\sigma}_{pm}^2 \quad (49)$$

• Erro de Previsão:

$$ep_m = E(y_0|x_0) - \hat{y}_0 = x'_0\beta - \hat{y}_0 = x'_0(\beta - \hat{\beta}) \quad (50)$$

$$E(ep_m|x_0) = 0; V(ep_m|x_0) = V(\hat{y}_0|x_0) = \sigma_{pm}^2$$

$$ep_i = y_0|x_0 - \hat{y}_0 = x'_0\beta - \hat{y}_0 + u_0 = x'_0(\beta - \hat{\beta}) + u_0$$

$$E(ep_i|x_0) = 0; V(ep_i|x_0) = V(\hat{y}_0|x_0) + V(u_0|x_0) = \sigma_{pi}^2$$

6.8 Testes às Hipóteses do Modelo

- **Ênfase: Dados seccionais.**
- Amostra de dimensão n , $\{(x_{i1}, \dots, x_{ik}, y_i) : i = 1, \dots, n\}$, aleatória (*i.i.d.*)?

Técnica de Amostragem!

- Forma Funcional $y_i = \beta_1 + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + u_i = x'_i\beta + u_i, i = 1, \dots, n$ correcta?

Teste Reset (REgression Specification Error Test) para dois termos: $H_0 : \delta_1 = \delta_2 = 0$ em $y_i = x'_i\beta + \delta_1 \hat{y}_i^2 + \delta_2 \hat{y}_i^3 + v_i$.

Estatísticas $F = \frac{(R_{UR}^2 - R_R^2)/2}{(1 - R_{UR}^2)/(n - k - 2)} \sim F_{(2, n - k - 2)}$ ou $LM = nR^2 \xrightarrow{d} \chi_{(2)}^2$.

- Exogeneidade $E(u_i|X) = E(u_i|x_1, \dots, x_n) \stackrel{?}{=} E(u_i) \stackrel{ok}{=} 0, i = 1, \dots, n$?

Ver apontamentos (capítulo ?)

- Não existe perfeita colinearidade, $rank(X) = k$?

”Sintomas” ...

Matriz ($k \times k$) de correlações empíricas dos regressores ($|\cdot| < 0.8$).

$VIF = \frac{1}{1-R_j^2}$ mede a col. de X_j com os outros regressores

(< 10); $CI = \sqrt{\frac{MaxValor Pr oprio X}{MinValor Pr oprio X}}$ col. moderada para $10 < CI < 30$.

- Homocedasticidade nos erros, $V(u_i|X) = E(u_i^2|X) = \sigma^2$, constante, $i = 1, \dots, n$?

Ver apontamentos (capítulo ?)

- Ausência de autocorrelação nos erros $Cov(u_i, u_j|X) = E(u_i u_j|X) = 0, i, j = 1, \dots, n, i \neq j$?

Ver apontamentos - **Dados Time Series!!!**

- Normalidade nos erros, $u|X \sim Normal$?

Teste JB (Jarque-Bera): $JB = n \left[\frac{S^2}{6} + \frac{(K-3)^2}{24} \right] \xrightarrow{d} \chi_{(2)}^2$, onde S é skewness e K é kurtosis dos resíduos OLS.

6.9 Outros Testes de Diagnóstico/Especificação

...

J. Davidson

...