

# Econometria

Formulário

Esmeralda Ramalho

2º Semestre do ano lectivo de 2018/2019

Note-se que a definição dos elementos constantes nas formulas é a estabelecida nas aulas

## Modelo de regressão linear para dados seccionais

Estimador OLS:  $\hat{\beta} = (X'X)^{-1}X'Y$ ,  $\hat{u}_i = Y_i - \hat{Y}_i$ ,  $R^2 = \frac{SQE}{SQT} = 1 - \frac{SQR}{SQT}$ ,  $Var(\hat{\beta}|X) = \sigma^2(X'X)^{-1}$ ,  $\hat{\sigma}^2 = \frac{\sum \hat{u}_i^2}{N-k-1}$

Inferência:  $t_j = \frac{\hat{\beta}_j - \beta_j}{\hat{\sigma}_{\beta_j}} \sim t(N - k - 1)$ ,  $F = \frac{(R^2 - R_*^2)/m}{(1 - R^2)/(N - k - 1)} = \frac{(SQR_* - SQR)/m}{SQR/(N - k - 1)} \sim F(m, N - k - 1)$ ,  $LM = NR_{\hat{u}^2}^2 \sim X_m^2$

Interpretação de efeitos parciais

Y	$X_j$	$\Delta X_j = 1 \rightarrow \Delta E(Y X) = \beta_j$
$\ln(Y)$	$X_j$	$\Delta X_j = 1 \rightarrow \Delta E(Y X) = 100\beta_j\%$
Y	$\ln(X_j)$	$\Delta X_j = 1\% \rightarrow \Delta E(Y X) = \beta_j/100$
$\ln(Y)$	$\ln(X_j)$	$\Delta X_j = 1\% \rightarrow \Delta E(Y X) = \beta_j\%$

## Variáveis dummy

Modelo tipo log-lin: efeito parcial exacto de uma dummy associada ao coeficiente  $\delta_0$  é  $[\exp(\delta_0) - 1] * 100\%$

Teste de Chow, modelo base:  $Y = \theta_0 + \theta_1 X_1 + \dots + \theta_k X_k + \gamma_0 D + \gamma_1 DX_1 + \dots + \gamma_k DX_k + v$ ; versão do teste F especifica para este teste:  $F = \frac{(SQR - SQR_A - SQR_B)/(k+1)}{(SQR_A + SQR_B)/(N - 2(k+1))} \sim F((k+1), N - 2(k+1))$

## Modelos para variável dependente binária

Especificação:  $Y \in \{0,1\}$ , sendo  $E(Y|X) = Pr(Y = 1|X)$

Previsão de Y:  $\hat{y} = 1$  se  $Pr(\widehat{Y} = 1|x) \geq 0.5$

Modelo linear de probabilidade

- Especificação:  $Pr(Y = 1|X) = \beta_0 + \beta_1 X_1 + \dots + \beta_k X_k$
- Efeitos parciais:  $\Delta X_j = 1 \Rightarrow \Delta E(Y|X) = \Delta Pr(Y = 1|X) = \beta_j$

## Logit e probit

- Especificação:  $Pr(Y = 1|X) = G(\beta_0 + \beta_1 X_1 + \dots + \beta_k X_k)$  onde  $0 \leq G(\cdot) \leq 1$ , com  $G(\cdot) = \Phi(x'_i \beta) = \int_{-\infty}^{x'_i \beta} \frac{1}{\sqrt{2\pi}} e^{-\frac{(x'_i \beta)^2}{2}} dx\beta$  no modelo probit e  $G(\cdot) = \Lambda(x'_i \beta) = \frac{e^{x'_i \beta}}{1 + e^{x'_i \beta}}$  no modelo logit. Tem-se  $E(Y|X) = G(x'_i \beta)$  e  $V(Y|X) = G(x'_i \beta)(1 - G(x'_i \beta))$
- Efeitos parciais:
  - Regressor contínuo:  $\Delta X_j = 1 \Rightarrow \Delta Pr(Y = 1|X) = \beta_j g(x'_i \beta)$ ,  
onde  $g(x'_i \beta) = \phi(x'_i \beta) = \frac{1}{\sqrt{2\pi}} e^{-\frac{(x'_i \beta)^2}{2}}$  no modelo probit e  $g(x'_i \beta) = \lambda(x'_i \beta) \Lambda(x'_i \beta)[1 - \Lambda(x'_i \beta)]$  no modelo logit
  - Regressor discreto: quando se passa de  $X_j = c$  para  $X_j = c + 1 \Rightarrow \Delta Pr(Y = 1|X) = G(\beta_0 + \dots + \beta_j(c + 1) + \dots) - G(\beta_0 + \dots + \beta_j c + \dots)$
  - Avaliação:
    - média dos regressores: efeito parcial avaliado na média
    - para todos os indivíduos e depois feita a média: efeito parcial médio
- Estimção:  $LL = \sum_{i=1}^N \{y_i \ln[G(x'_i \beta)] + (1 - y_i) \ln[1 - G(x'_i \beta)]\}$
- Inferência:  $LR = 2(LL - LL_*) \sim \chi_m^2$ , para  $m$  restrições,  $W = \frac{\hat{\beta}_j}{\hat{\sigma}_{\hat{\beta}_j}} \sim N(0,1)$

## Análise de regressão básica com séries temporais

Modelo FDL(q):  $y_t = \alpha_0 + \alpha_1 x_t + \alpha_2 x_{t-1} + \dots + \alpha_{q+1} x_{t-q} + u_t$

- Modelo estático para  $\alpha_2 = \dots = \alpha_{q+1} = 0$
- Multiplicador/propensão de impacto:  $\alpha_1$
- Multiplicador/propensão de longo prazo:  $\alpha_1 + \alpha_2 + \dots + \alpha_{q+1}$

Hipóteses e propriedades dos estimadores OLS em pequenas amostras:

- Linearidade nos parâmetros; 2) ausência de colineariedade perfeita; 3) exogeneidade estrita:  $E(u_t|X) = 0, \forall t \rightarrow Cov(x_{sj}, u_t) = 0 \forall t, s, j$ ; 4) Homoscedasticidade:  $Var(u_t|X) = \sigma^2$ ;
- 5) Ausência de autocorrelação:  $Corr(u_t, u_s|X) = 0, \forall t \neq s$ ; 6) Normalidade:  $u_t \sim N(0, \sigma^2)$
- 1-3: estimadores centrados; 1-5 (pressupostos de Gauss-Markov): estimadores BLUE; 1-6: estimadores normalmente distribuídos  $\hat{\beta}|X \sim N(\beta, \sigma^2(X'X)^{-1})$  e testes t e F e IC validos

## Tendência

- Modelo de tendência linear:  $y_t = \beta_0 + \beta_1 t + \beta_2 x_{t1} \dots + u_t$ ;  $\Delta t = 1 \Rightarrow \Delta y_t = \beta_1$
- Modelo de tendência exponencial:  $\ln(y_t) = \beta_0 + \beta_1 t + \beta_2 x_{t1} \dots + u_t$ ;  $\Delta t = 1 \Rightarrow \% \Delta y_t = 100 * \beta_1 \%$
- Modelo de tendência quadrática:  $y_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \beta_3 x_{t1} \dots + u_t$ ;  $\Delta t = 1 \Rightarrow \Delta y_t = \beta_1 + 2\beta_2 t$
- Processo de detrending: para cada variável do modelo: 1) Estimar o modelo  $w_t = \alpha_0 + \alpha_1 t + e_t$ ; 2) Obter:  $\check{w}_t = w_t - (\hat{\alpha}_0 + \hat{\alpha}_1 t)$

Sazonalidade: Incorpora-se no modelo através de 3, 11, e 6 dummies que correspondem a estações do ano, meses, ou dias. Dessazonalizar, corresponde ao processo de "detrending"

## Séries temporais estacionárias e fracamente dependentes

**Processo estocástico estacionário:** processo cuja distribuição é sempre a mesma  $\forall t$

**Processo estocástico estacionário em covariância:** para o intervalo de tempo  $h$ :  $E(y_t) = \mu$ ;  $V(y_t) = E(y_t - \mu)^2 = \sigma^2$ ;  $Cov(y_t, y_{t-h})$  pode depender de  $h$  mas não de  $t$

**Processo fracamente dependente:** requer  $y_t$  e  $y_{t+h}$  "quase" independentes para  $h \rightarrow \infty$ . Com estacionaridade em covariância, será assintoticamente não correlacionada se  $Cov(y_t, y_{t+h}) \rightarrow 0, h \rightarrow \infty$

**Ruído Branco:**  $y_t = \varepsilon_t$ , onde  $E(\varepsilon_t) = \mu_\varepsilon, V(\varepsilon_t) = \sigma_\varepsilon^2, Cov(\varepsilon_t, \varepsilon_{t-h}) = 0$  para  $h \neq 0$

**Modelo AR(1):**  $y_t = \rho y_{t-1} + \varepsilon_t$ , onde  $\varepsilon_t \sim iid(0, \sigma^2), E(y_t) = 0; V(y_t) = \frac{\sigma^2}{1-\rho^2}; Cov(y_t, y_{t-h}) = \gamma_h = \rho^h \sigma^2; Cor(y_t, y_{t-h}) = \frac{\gamma_h}{\gamma_0} = \rho^h$ . Processo estacionário e fracamente dependente se  $|\rho| < 1$

**Modelo MA(1):**  $y_t = \varepsilon_t + \theta \varepsilon_{t-1}, |\theta| < 1$ , onde  $\varepsilon_t \sim iid(0, \sigma^2), E(y_t) = 0, V(y_t) = \sigma^2(1 + \theta^2), Cov(y_t, y_{t-h}) = \begin{cases} \theta \sigma^2 se h = 1 \\ 0 se h > 1 \end{cases}, Cor(y_t, y_{t-h}) = \begin{cases} \frac{\theta \sigma^2}{\sigma^2(1+\theta^2)} = \frac{\theta}{(1+\theta^2)} se h = 1 \\ 0 se h > 1 \end{cases}$ . Processo estacionário e fracamente dependente

**Processo estacionário em tendência:**  $y_t = \beta_0 + \beta_1 t + u_t$ , onde  $E(y_t) = \beta_0 + \beta_1 t$ . Sendo apenas estacionário em tendência, pode ser estimado por OLS, se  $u_t$  for fracamente dependente

### Hipóteses e propriedades dos estimadores OLS em termos assintóticos:

- 1'. Linearidade nos parâmetros, juntamente com dependência fraca; 2'. Ausência de colineariedade perfeita; 3'.  $E(u_t | X_t) = 0$  exogeneidade contemporânea; 4'. Homoscedasticidade:  $Var(u_t | X) = Var(u_t) = \sigma^2$ ; 5'. Ausência de autocorrelação:  $Corr(u_t, u_s | X) = 0, \forall t \neq s$
- 1'-3': estimadores consistentes; 1'-5' estimadores normalmente distribuídos, e testes t, F e LM assintoticamente válidos

## Séries temporais altamente persistentes

- **Passeio Aleatório:**  $y_t = y_{t-1} + \varepsilon_t$ , onde  $E(y_t) = 0, V(y_t) = \sigma_\varepsilon^2 t, Cor(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$
- **Passeio Aleatório com deslocação:**  $y_t = \alpha + y_{t-1} + \varepsilon_t$ , onde  $E(y_t) = \alpha t + y_0, V(y_t) = \sigma_\varepsilon^2 t$
- **Ordem de integração**
  - I(0): série fracamente dependente – OLS pode ser directamente usado
  - I(1): processo de raiz unitária cuja primeira diferença é I(0). Um processo I(1) é estacionário às diferenças

**Modelo dinamicamente completo:** satisfaz o pressuposto 5 de ausência de autocorrelação

### Autocorrelação

Autocorrelação AR(1):  $u_t = \rho u_{t-1} + \varepsilon_t, |\rho| < 1, \varepsilon_t \sim$  ruído branco

Autocorrelação AR(p):  $u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} \dots \rho_p u_{t-p} + \varepsilon_t, \varepsilon_t \sim$  ruído branco

### Testes de autocorrelação: modelos auxiliares

- $t_\rho: \hat{u}_t = \rho \hat{u}_{t-1} + \varepsilon_t$
- H-alt de Durbin:  $\hat{u}_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + \rho \hat{u}_{t-1} + e_t$
- Breusch-Godfrey:  $\hat{u}_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + \rho_1 \hat{u}_{t-1} + \rho_2 \hat{u}_{t-2} + \dots + \rho_p \hat{u}_{t-p} + e_t, LM = (N - p)R_{\hat{u}}^2 \sim \chi_p^2$

### Modelos FGLS:

- Cochrane-Orcutt:  $y_t - \rho y_{t-1} = \beta_0(1 - \rho) + \beta_1(x_t - \rho x_{t-1}) + \varepsilon_t$
- Prais-Winsten: 
$$\begin{cases} \sqrt{1 - \rho^2} y_t = \beta_0 \sqrt{1 - \rho^2} + \beta_1 \sqrt{1 - \rho^2} x_t + \sqrt{1 - \rho^2} u_t \\ y_t - \rho y_{t-1} = \beta_0(1 - \rho) + \beta_1(x_t - \rho x_{t-1}) + u_t \end{cases}$$

### Heteroscedasticidade

#### Testes de heteroscedasticidade: modelos auxiliares

- Breusch Pagan:  $\hat{u}^2 = \gamma_0 + \gamma_1 X_1 + \dots + \gamma_k X_k + e$
- White (k=2):  $\hat{u}^2 = \gamma_0 + \gamma_1 X_1 + \gamma_2 X_2 + \gamma_3 X_1^2 + \gamma_4 X_2^2 + \gamma_5 X_1 X_2 + e$

### Agregação de dados seccionais de diferentes períodos de tempo

Formalização genérica do modelo linear:  $y_{it} = \beta_0 + \beta_1 x_{it1} + \dots + \beta_k x_{itk} + u_{it}, i = 1, \dots, N, t = 1, \dots, T$

#### Introdução de time-dummies e interações

Em dados anuais, para T anos, toma-se o primeiro ano como referência e consideram-se  $(T - 1)$  dummies, uma para cada um dos restantes anos

- Efeito dos regressores sobre y inalterados no tempo: incluem-se essas dummies, que afectarão o intercepto do modelo
- Efeitos parciais dos regressores alteram-se no tempo: acrescentam-se também termos de interação, podendo-se usar o teste Chow para quebra de estrutura

#### Avaliação do efeito de uma política: estimador diferenças nas diferenças ou efeito médio do tratamento

- Amostra em dois momentos diferentes (antes e após a implementação) e dois grupos de indivíduos (não afectados – grupo de controle - e afectados – grupo de tratamento)

	Antes	Após	Após-Antes
Cont. (longe)	$\beta_0$	$\beta_0 + \gamma_1$	$\gamma_1 = E[p_{apos} - p_{antes} cont] \rightarrow 1^a \text{ dif}$
Trat. (perto)	$\beta_0 + \beta_1$	$\beta_0 + \gamma_1 + \beta_1 + \delta_1$	$\gamma_1 + \delta_1 =$ $= E[p_{apos} - p_{antes} trat] \rightarrow 1^a \text{ dif}$
Trat. – Cont.	$\beta_1$	$\beta_1 + \delta_1$	$\delta_1 \rightarrow \text{dif in dif}$

### Dados de painel, T=2

Modelo com efeitos individuais:  $y_{it} = \alpha_i + x'_{it}\beta + u_{it}$  ( $i = 1, \dots, N; t = 1, \dots, T$ )

- Efeitos fixos:  $\alpha_i$  e  $x_{it}$  correlacionados  $\rightarrow$  Estimadores “pooled” OLS viesados
- Efeitos aleatórios:  $\alpha_i$  e  $x_{it}$  não são correlacionados  $\rightarrow$  Estimadores “pooled” OLS válidos

**Estimador “pooled” OLS:**  $y_{it} = \alpha + x'_{it}\beta + v_{it}$

**Estimador das primeiras diferenças:**  $\Delta y_{it} = \Delta x'_{it}\beta + \Delta u_{it}$

- Se o modelo inicial incluir uma time-dummy, o modelo às diferenças terá um intercepto, que é o coeficiente da time-dummy:

### Dados de painel, T>2

$\Delta y_{it} = \Delta x'_{it}\beta + \Delta u_{it}$ ,  $t = 2, 3, \dots$  ou  $\Delta y_{it} = \alpha + \delta_1 d2 + \delta_2 d3 + \Delta x'_{it}\beta + \Delta u_{it}$ ,  $t = 2, 3, \dots$