

Formulário de Econometria – 2ª edição

Artur Silva Lopes, 24/11/2017¹

Revisão – Estatística

$\text{Var}(X) = E(X - \mu)^2 = E(X^2) - \mu^2$; $\text{Cov}(X, Y) = E[(X - \mu_X)(Y - \mu_Y)] = E(XY) - E(X)E(Y)$;
 $\rho_{X,Y} = \text{corr}(X, Y) = \frac{\text{Cov}(X,Y)}{\sigma_X \sigma_Y}$.
 $E(Y) = E[E(Y|X)]$; $E[g(X)|x] = g(x)$; se X e Y são independentes, então $E(Y|X) = E(Y)$;
 se $E(Y|X) = E(Y)$, então $\text{Cov}(Y, X) = 0$ (e $\rho_{X,Y} = 0$).

Modelo de regressão linear para amostras aleatórias de dados seccionais

$$y_i = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} + u_i \Leftrightarrow y_i = x_i \boldsymbol{\beta} + u_i, \quad i = 1, 2, \dots, n \Leftrightarrow \mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}.$$

$$\text{OLS: } \hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}, \quad \hat{u}_i = y_i - \hat{y}_i, \quad \hat{\sigma}^2 = \sum \hat{u}_i^2 / (n - k - 1), \quad R^2 = \frac{SSE}{SST} = 1 - \frac{SSR}{SST}.$$

$\text{Var}(\hat{\boldsymbol{\beta}}|\mathbf{X}) = \hat{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1}$, $\text{Var}(\hat{\beta}_j|\mathbf{X}) = \frac{\hat{\sigma}^2}{SST_j(1-R_j^2)}$, $j = 1, 2, \dots, k$, com $SST_j = \sum (x_{ij} - \bar{x}_j)^2$ e R_j^2 o R^2 da regressão de x_j sobre os restantes regressores.

$$H_0: \beta_j = \beta_j^0, \quad t = (\hat{\beta}_j - \beta_j^0) / \text{se}(\hat{\beta}_j) \sim t_{(n-k-1)} \text{ ou } \overset{a}{\sim} \mathcal{N}(0, 1) \text{ sob } H_0.$$

$$H_0: \beta_1 = \beta_2 = \dots = \beta_k = 0, \quad F = \frac{R^2}{1-R^2} \times \frac{n-k-1}{k} \sim F_{(k, n-k-1)} \text{ sob } H_0.$$

Quaisquer q restrições (com y inalterado): $F = \frac{SSR_R - SSR_{UR}}{SSR_{UR}} \times \frac{n-k-1}{q} = \frac{R_{UR}^2 - R_R^2}{1-R_{UR}^2} \times \frac{n-k-1}{q} \sim F_{(q, n-k-1)}$ sob H_0 , com SSR_{UR} a soma dos quadrados dos resíduos do modelo sem restrições e SSR_R a soma dos quadrados dos resíduos do modelo com as restrições.

Inferência robusta à heteroscedasticidade:

a) matriz de White: $\text{Var}^*(\hat{\boldsymbol{\beta}}|\mathbf{X}) = (\mathbf{X}'\mathbf{X})^{-1} \sum \hat{u}_i^2 \mathbf{x}_i' \mathbf{x}_i (\mathbf{X}'\mathbf{X})^{-1}$;

b) estatísticas $-t$ robustas: $H_0: \beta_j = \beta_j^0$, $t = (\hat{\beta}_j - \beta_j^0) / \text{se}^*(\hat{\beta}_j) \overset{a}{\sim} \mathcal{N}(0, 1)$ sob H_0 ; $\text{se}^*(\hat{\beta}_j) = \sqrt{\text{Var}^*(\hat{\beta}_j|\mathbf{X})}$. EViews: ... estimate ... OPTIONS: coefficient covariance matrix -> White.

Estatísticas de teste (LM) de heteroscedasticidade: $LM = n R_{\hat{u}^2}^2 \overset{a}{\sim} \chi_{(p)}^2$ sob H_0 ; p = número de regressores (excluindo o termo independente) da regressão auxiliar de teste.

Variáveis *dummy*

Afectando apenas o termo independente. Exemplo: $wage = \beta_0 + \delta_0 female + \beta_1 educ + erro$, para não cair na armadilha das variáveis artificiais, violando a hipótese de não colinearidade perfeita. $\delta_0 = E(wage|female = 1, educ) - E(wage|female = 0, educ)$.

Se a característica qualitativa faz uma partição em g grupos distintos, introduzem-se no modelo apenas $g - 1$ variáveis *dummy*, mantendo o termo independente.

Modelo com $\log(y)$: % Δ exacta = $100[\exp(\hat{\beta}_1) - 1]$, com $\hat{\beta}_1$ o coeficiente da *dummy*.

Afectando também o coeficiente de declive. Exemplo: $wage = \beta_0 + \delta_0 female + \beta_1 educ + \delta_1 female \times educ + erro$.

Teste de igualdade de equações de regressão. A) Com D a representar a variável *dummy*, $H_0: \delta_0 = \delta_1 = \dots = \delta_k = 0$ em $y = \beta_0 + \delta_0 D + \beta_1 x_1 + \delta_1 D x_1 + \dots + \beta_k x_k + \delta_k D x_k + erro$. B) $H_0: \alpha_0 = \beta_0, \alpha_1 = \beta_1, \dots, \alpha_k = \beta_k$ em $y = \alpha_0 + \alpha_1 x_1 + \dots + \alpha_k x_k + u$ para grupo 1 e

¹Elaborado com base em Wooldridge, J. M. (2009, 2016), *Introductory Econometrics*, 4th and 6th eds., South-Western, Cengage Learning, e com os comentários e sugestões de Luizete Reis e Ana Pereira, que não têm, no entanto, qualquer responsabilidade nos erros e omissões que possam subsistir

$y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u$ para grupo 2. $F_{CHOW} = \frac{[SSR_p - (SSR_1 + SSR_2)] / (k+1)}{(SSR_1 + SSR_2) / [n - 2(k+1)]} \sim F_{(k+1, n-2(k+1))}$ sob H_0 , com SSR_p a SSR obtida do modelo estimado com o conjunto de todas as observações. Se não interessar testar a igualdade dos termos independentes, a SSR_p é calculada com base num modelo que inclui uma *dummy* com efeito sobre esse coeficiente.

Modelos para variáveis dependentes binárias

$y = 0$ ou 1 . $y | \mathbf{x} \sim B(1, p(\mathbf{x}))$. Revisão: se $X \sim B(1, \theta)$, então $E(X) = \theta$ e $\text{Var}(X) = \theta(1 - \theta)$. $f(x | \theta) = \theta^x (1 - \theta)^{1-x}$, $x = 0, 1$.

Modelo linear de probabilidades: $E(y | \mathbf{x}) = p(\mathbf{x}) = P(y = 1 | \mathbf{x}) = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k$. Logo, $\beta_j = \Delta P(y = 1 | \mathbf{x}) / \Delta x_j$. Deficiências: i) eventuais $\hat{y}_i < 0$ ou $\hat{y}_i > 1$; ii) linearidade (efeitos parciais constantes); iii) heteroscedasticidade.

Previsão dos y_i 's: $\tilde{y}_i = 1$, se $\hat{y}_i \geq 0.5$, e $\tilde{y}_i = 0$, se $\hat{y}_i < 0.5$.

Modelos Logit e Probit: $P(y = 1 | \mathbf{x}) = G(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k) = G(\mathbf{x}\boldsymbol{\beta})$, com $0 < G(z) < 1$. Logit: $G(z) = \Lambda(z) = \frac{\exp(z)}{1 + \exp(z)}$; EViews: @clogistic(.). Probit: $G(z) = \Phi(z) = \int_{-\infty}^z \phi(v) dv$, $\phi(z) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{z^2}{2}\right)$; EViews: @cnorm(.).

Efeitos parciais das variáveis. **A.** Para pequenas variações: A.1 Se x_j é uma variável aproximadamente contínua, pode fazer-se $\frac{\partial p(\mathbf{x})}{\partial x_j} = g(\mathbf{x}\boldsymbol{\beta}) \beta_j = g(\beta_0 + \beta_1 x_1 + \dots + \beta_k x_k) \beta_j$, onde $g(z) = \frac{dG(z)}{dz}$; $g(z) > 0, \forall z$. EViews: @dlogistic(.) e @dnorm(.), respectivamente; A.2 Se x_k é uma variável discreta, quando passa de c_k para $c_k + 1$: $G[(\beta_0 + \beta_1 x_1 + \dots + \beta_k (c_k + 1))] - G(\beta_0 + \beta_1 x_1 + \dots + \beta_k c_k)$. **B.** Outros casos: $\Delta P(y = 1 | \mathbf{x}) = G(\text{novo ponto}) - G(\text{ponto inicial})$.

Estimação dos efeitos parciais médios. i) Para variáveis aproximadamente contínuas: $[\frac{1}{n} \sum_{i=1}^n g(\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k x_{ik})] \hat{\beta}_j = [\frac{1}{n} \sum_{i=1}^n g(\mathbf{x}_i \hat{\boldsymbol{\beta}})] \hat{\beta}_j$. Exemplo EViews: series facesc = @dnorm(c(1) + c(2)*x2) series efeipar = facesc*c(2) scalar epm=@mean(efeipar).

ii) Para variáveis discretas. x_k passa de c_k para $c_k + 1$:

$$\frac{1}{n} \sum_{i=1}^n \left[G(\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k (c_k + 1)) - G(\hat{\beta}_0 + \hat{\beta}_1 x_{i1} + \dots + \hat{\beta}_k c_k) \right].$$

Exemplo de EViews, com $x_2 = D(ummy)$: series a = @cnorm(c(1)+c(2)*x1+c(3)) series b = @cnorm(c(1)+c(2)*x1) scalar epmd=@mean(a-b).

Estimação de MV: $\hat{\boldsymbol{\beta}} = \arg \max \mathcal{L}(\boldsymbol{\beta})$. $\mathcal{L}(\boldsymbol{\beta}) = \sum l_i(\boldsymbol{\beta}) = \sum y_i \log[G(\mathbf{x}_i \boldsymbol{\beta})] + (1 - y_i) \log[1 - G(\mathbf{x}_i \boldsymbol{\beta})] < 0, \forall \boldsymbol{\beta}$. EViews: quick -> estimate equation ... -> METHOD: binary -> logit ou probit. Propriedades: a) $\text{plim}(\hat{\boldsymbol{\beta}}) = \boldsymbol{\beta}$; b) $\hat{\boldsymbol{\beta}} \stackrel{a}{\sim} \mathcal{N}(\cdot, \cdot)$; c) $\hat{\boldsymbol{\beta}}$ é assintoticamente eficiente; d) $se(\hat{\beta}_j)$, $j = 0, 1, \dots, k$, são válidos assintoticamente.

Inferência. $H_0 : \beta_j = 0$, $\hat{\beta}_j / se(\hat{\beta}_j) \stackrel{a}{\sim} \mathcal{N}(0, 1)$ sob H_0 . Quaisquer q restrições de exclusão: $LR = 2(\mathcal{L}_{UR} - \mathcal{L}_R) \stackrel{a}{\sim} \chi_{(q)}^2$ sob H_0 . EViews: view -> coefficient tests -> redundant variables - Likelihood ratio -> ... (nomes das variáveis).

Bondade do ajustamento. % previsões correctas = $\frac{npc}{n} \times 100$, npc = número de previsões correctas. EViews: view -> prediction-expectation evaluation -> valor de limiar = 0.5.

Para comparações grosseiras: coef. probit $\xrightarrow{\times 1.6}$ coef. logit; coef. logit $\xrightarrow{\times 0.625}$ coef. probit; coef. probit $\xrightarrow{\times 0.4}$ coef. MLP; coef. logit $\xrightarrow{\times 0.25}$ coef. MLP.

Regressão básica com séries temporais

Série temporal, x_t , é uma realização de um processo estocástico, $\{x_t\}$, sucessão de variáveis aleatórias indexadas pelo tempo.

Exemplo de modelo estático: $y_t = \beta_0 + \beta_1 z_t + u_t, t = 1, 2, \dots, n$. Exemplo de modelo dinâmico, FDL(2): $y_t = \alpha_0 + \delta_0 z_t + \delta_1 z_{t-1} + \delta_2 z_{t-2} + u_t$; MCP = δ_0 ; MLP = $\delta_0 + \delta_1 + \delta_2$. Variação transitória unitária em t (e $u_t \equiv 0, \forall t$): $\delta_0 = y_t - y_{t-1}; \delta_1 = y_{t+1} - y_{t-1}; \delta_2 = y_{t+2} - y_{t-1}$. Variação permanente unitária em t (e $u_t \equiv 0, \forall t$): $y_t - y_{t-1} = \delta_0; y_{t+1} - y_{t-1} = \delta_0 + \delta_1; y_{t+2} - y_{t-1} = \delta_0 + \delta_1 + \delta_2, \dots$

Modelo clássico. TS.1 Linearidade nos parâmetros: $\{(x_{t1}, x_{t2}, \dots, x_{tk}, y_t)\} : y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + u_t, t = 1, 2, \dots, n; \mathbf{x}_t = (x_{t1}, x_{t2}, \dots, x_{tk}), \mathbf{X}$ é $n \times (k+1)$; notação matricial: $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$. **TS.2** Exogeneidade estrita: $E(u_t | \mathbf{X}) = 0, \forall t \Rightarrow \text{Cov}(u_t, x_{sj}) = 0, \forall t, s, j$. Mais forte que exogeneidade contemporânea: $E(u_t | \mathbf{x}_t) = E(u_t | x_{t1}, x_{t2}, \dots, x_{tk}) = 0, \forall t \Rightarrow \text{Cov}(u_t, x_{tj}) = 0, \forall t, j$. Violações mais importantes: variáveis omitidas correlacionadas com as incluídas e variações dos erros que provocam variações futuras dos regressores (*feedback*). **TS.3** Não colinearidade perfeita: $r(\mathbf{X}) = k + 1$. **Teor.:** TS.1 + TS.2 + TS.3 $\Rightarrow E(\hat{\boldsymbol{\beta}}) = E(\hat{\boldsymbol{\beta}} | \mathbf{X}) = \boldsymbol{\beta}$.

TS.4 Homoscedasticidade: $\text{Var}(u_t | \mathbf{X}) = \sigma^2, t = 1, 2, \dots, n$. **TS.5** Ausência de autocorrelação: $\text{corr}(u_t, u_s) = 0, \forall t, s, t \neq s$. **Teor.:** TS.1 a TS.5 (hipóteses de Gauss-Markov) $\Rightarrow \text{Var}(\hat{\boldsymbol{\beta}}_j | \mathbf{X}) = \frac{\sigma^2}{SST_j(1-R_j^2)}, j = 1, 2, \dots, k$. **Teor.:** TS.1 a TS.5 \Rightarrow com $\hat{\sigma}^2 = SSR/(n-k-1) = SSR/DF, E(\hat{\sigma}^2) = \sigma^2$. **Teor.** (Gauss-Markov): TS.1 a TS.5 \Rightarrow condicional em \mathbf{X} , o estimador OLS, $\hat{\boldsymbol{\beta}}$, é o *BLUE* para $\boldsymbol{\beta}$. **TS.6** Normalidade: u_t 's independentes de \mathbf{X} e $u_t \sim iid\mathcal{N}(0, \sigma^2)$. **Teor.:** TS.1 a TS.6 (hipóteses CLM) \Rightarrow a) $\hat{\boldsymbol{\beta}} | \mathbf{X} \sim \mathcal{N}(\boldsymbol{\beta}, \sigma^2(\mathbf{X}'\mathbf{X})^{-1})$; b) sob as respectivas H_0, t 's $\sim t_{(\cdot)}$ e F 's $\sim F_{(\cdot, \cdot)}$; c) a construção usual de ICs é válida.

Exemplos de EViews: a) *dummy*: `pill=year>1962`; b) variáveis desfasadas: `z(-1), z(-2), \dots`

Modelo simples de tendência linear (determinística): $y_t = \alpha_0 + \alpha_1 t + e_t$, com $e_t \sim iid(0, \sigma^2)$, processo ruído branco, e $t = 1, 2, \dots, n; \Delta y_t \approx \alpha_1$; EViews: (*generate series*) `t = @trend + 1`. Modelo de tendência exponencial: $\log(y_t) = \beta_0 + \beta_1 t + e_t; \Delta \log(y_t) \approx \frac{y_t - y_{t-1}}{y_{t-1}} \approx \beta_1$. Modelo de tendência quadrática: $y_t = \alpha_0 + \alpha_1 t + \alpha_2 t^2 + e_t$.

Variáveis com tendência na regressão. Modelo adequado: $y_t = \beta_0 + \beta_1 x_{t1} + \beta_2 x_{t2} + \beta_3 t + v_t$; os estimadores $\hat{\beta}_1$ e $\hat{\beta}_2$ do modelo $y_t = \beta_0 + \beta_1 x_{t1} + \beta_2 x_{t2} + u_t$ são enviesados se x_{t1} e/ou x_{t2} “tiverem tendência”; alguns dos resultados obtidos poderão ser espúrios.

Teor. FWL I. As estimativas OLS $\hat{\beta}_1$ e $\hat{\beta}_2$ de $y_t = \beta_0 + \beta_1 x_{t1} + \beta_2 x_{t2} + \beta_3 t + u_t$ podem obter-se de: i) remoção da tendência de y_t, x_{t1} e x_{t2} ; por exemplo, $\tilde{y}_t = y_t - \hat{y}_t = y_t - (\hat{\alpha}_0 + \hat{\alpha}_1 t)$; ii) regressão de \tilde{y}_t sobre \tilde{x}_{t1} e \tilde{x}_{t2} . Interpretação dos coeficientes: em termos de variações em torno da tendência. Nota: pode ser útil incluir t numa regressão em que y_t “não tem tendência” mas um regressor tem.

Sazonalidade regular é modelada com *dummies* sazonais. EViews: `@seas(.)`. **Teor. FWL II:** as estimativas OLS $\hat{\beta}_1$ e $\hat{\beta}_2$ de $y_t = \alpha_0 + \delta_1 Q_{t1} + \delta_2 Q_{t2} + \delta_3 Q_{t3} + \beta_1 x_{t1} + \beta_2 x_{t2} + u_t$ (dados trimestrais) podem obter-se de: i) remoção da sazonalidade de y_t, x_{t1} e x_{t2} ; por exemplo, $\tilde{y}_t = y_t - \hat{y}_t = y_t - (\hat{\gamma}_0 + \hat{\gamma}_1 Q_{t1} + \hat{\gamma}_2 Q_{t2} + \hat{\gamma}_3 Q_{t3})$; ii) regressão de \tilde{y}_t sobre \tilde{x}_{t1} e \tilde{x}_{t2} . Interpretação dos coeficientes: em termos de variações após remoção da sazonalidade (dessazonalização).

Tópicos adicionais sobre a utilização do OLS

O processo estocástico $\{x_t\}$, com $E(x_t^2) < \infty$ é **estacionário** (em covariância) se: i) $E(x_t)$ é constante em t ; ii) $\text{Var}(x_t)$ é constante em t ; iii) $\forall t, h \geq 1, \text{Cov}(x_t, x_{t+h})$ só depende de h e não de t . Em termos grosseiros, um processo estacionário $\{x_t\}$ é fracamente dependente se $\lim_{h \rightarrow \infty} \text{corr}(x_t, x_{t+h}) = 0$ (assintoticamente não autocorrelacionado).

Processo MA(1): $x_t = e_t + \alpha e_{t-1}, e_t \sim iid(0, \sigma_e^2)$. $E(x_t) = 0, \forall t; \text{Var}(x_t) = \sigma_e^2(1 + \alpha^2); \text{Cov}(x_t, x_{t+1}) =$

$\alpha \sigma_e^2$ e $\text{corr}(x, x_{t+1}) = \frac{\alpha}{1+\alpha^2}$; $\text{Cov}(x_t, x_{t+h}) = \text{corr}(x_t, x_{t+h}) = 0, \forall h \geq 2$. Os processos MA são sempre estacionários e fracamente dependentes.

Processo AR(1): $y_t = \rho y_{t-1} + e_t$. É estacionário (e fracamente dependente) se $|\rho| < 1$. Nesse caso, $\forall t, E(y_t) = 0, \text{Var}(y_t) = \sigma_y^2 = \frac{\sigma_e^2}{1-\rho^2}, \text{Cov}(y_t, y_{t+1}) = \rho \sigma_y^2, \text{corr}(y_t, y_{t+1}) = \rho, \text{corr}(y_t, y_{t+h}) = \rho^h, \forall h \geq 0$.

Exemplo de processo estacionário em tendência: $y_t = \alpha_0 + \alpha_1 t + e_t$. Mas também $y_t = \alpha_0 + \alpha_1 t + u_t$, com $u_t = e_t + \gamma e_{t-1}$, ou $u_t = \rho u_{t-1} + e_t$, com $|\rho| < 1$, etc. . Embora não estacionários, estes processos não levantam problemas na análise de regressão.

Propriedades assintóticas do OLS. TS.1' Linearidade e dependência fraca: $\{(x_{t1}, x_{t2}, \dots, x_{tk}, y_t)\} : y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + u_t, t = 1, 2, \dots, n$, e é estacionário e fracamente dependente. **TS.2'** Exogeneidade contemporânea: $E(u_t | x_{t1}, \dots, x_{tk}) = E(u_t | \mathbf{x}_t) = 0, \forall t$. Exemplos: y_{t-1} não é estritamente exógeno mas é, em princípio, contemporaneamente exógeno; pode existir efeito de *feedback*, desde que não seja contemporâneo. **TS.3'** = TS.3 Não colinearidade perfeita: $r(\mathbf{X}) = k + 1$. **Teor.:** TS.1' + TS.2' + TS.3' $\Rightarrow \text{plim}(\hat{\beta}_j) = \beta_j, j = 0, 1, \dots, k$.

TS.4' Homoscedasticidade: $\text{Var}(u_t | \mathbf{x}_t) = \sigma^2, \forall t$. **TS.5'** Ausência de autocorrelação: $\text{Cov}(u_t, u_s) = 0, \forall t \neq s$. **Teor.:** TS.1' a TS.5' $\Rightarrow \hat{\beta}_j \stackrel{a}{\sim} \mathcal{N}(\cdot, \cdot)$; os usuais erros-padrão (*se's*), estatísticas-*t*, $-F$ e *LM* são válidos assintoticamente. Exemplo: segundo a HEM, com y_t um rendimento (percentual) de um activo financeiro, $E(y_t | y_{t-1}, y_{t-2}, \dots) = E(y_t), \forall t$.

Séries temporais **altamente persistentes**. Passeio aleatório sem deriva: $y_t = y_{t-1} + e_t$ (AR(1) com $\rho = 1$, processo de **raiz unitária**); $y_t = y_0 + \sum_{i=1}^t e_i = y_0 + \text{tend. estocástica}$; $\text{Var}(y_t) = t \sigma_e^2, \forall t$; $E(y_{t+h} | I_t) = y_t, \forall h \geq 1$; $\text{corr}(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$. Se $y_t = \rho y_{t-1} + e_t$, com $|\rho| < 1, E(y_{t+h} | I_t) = \rho^h y_t, \forall h \geq 1$.

Passeio aleatório com deriva: $y_t = \alpha_0 + y_{t-1} + e_t$ (também AR(1) com $\rho = 1$); $y_t = y_0 + \alpha_0 t + \sum_{i=1}^t e_i = y_0 + \text{tend. determinística} + \text{tend. estocástica}$; não é estacionário em tendência.

Processo fracamente dependente = **I(0)**, não é necessário diferenciar nenhuma vez para poder usar na regressão. Processo fortemente dependente = altamente persistente = de raiz unitária = **I(1)**: necessário diferenciar uma vez para ficar (estacionário e) fracamente dependente (I(0)). Exemplos: passeios aleatórios; mais geralmente: $y_t = (\alpha_0 + \alpha_1) y_{t-1} + u_t$, com $u_t \sim I(0)$ qualquer. Nota: diferenciar uma série também reduz numa unidade o grau do polinómio em t que ela possa ter; Ex.: $y_t = \alpha_0 + \alpha_1 t + v_t \Rightarrow \Delta y_t = \alpha_1 + \Delta v_t$. As séries I(0) têm um comportamento de reversão ou regressão para a média que as séries I(1) não têm.

Decisão sobre I(1) ou I(0): i) estimar ρ_1 (ou ρ) em $y_t = \alpha + \rho_1 y_{t-1} + u_t$; ii) se $\hat{\rho}_1 > 0.9$ ou $0.8 \Rightarrow$ considerar que $y_t \sim I(1)$. Atenção: se y_t “tem tendência”, esta necessita ser removida. Suspeita de regressão espúria “em níveis” \Rightarrow regressão em primeiras diferenças.

Se a igualdade $E(u_t | \mathbf{x}_t, y_{t-1}, \mathbf{x}_{t-1}, \dots) = 0$, for satisfeita, o modelo $y_t = \beta_0 + \beta_1 x_{t1} + \dots + \beta_k x_{tk} + u_t$ diz-se **dinamicamente completo**. A condição anterior é equivalente à condição $E(y_t | \mathbf{x}_t, y_{t-1}, \mathbf{x}_{t-1}, y_{t-2}, \dots) = E(y_t | \mathbf{x}_t)$. Se um modelo é dinamicamente completo, então satisfaz TS.5'.

Autocorrelação e heteroscedasticidade

Se $\exists t, s, t \neq s : \text{Cov}(u_t, u_s) \neq 0$, quais as implicações negativas? No modelo $y_t = \beta_0 + \beta_1 x_t + u_t$,

com $\bar{x} = 0$, $u_t = \rho u_{t-1} + e_t$, $|\rho| < 1$, $e_t \sim iid(0, \sigma^2)$, tem-se

$$\text{Var}(\hat{\beta}_1 | \mathbf{X}) = \frac{\sigma^2}{SST_x} + 2 \frac{\sigma^2}{SST_x^2} \sum_{t=1}^{n-1} \sum_{j=1}^{n-t} \rho^j x_t x_{t+j},$$

ou seja, em geral, a precisão do estimador OLS é sobre-avaliada. Daqui resulta que os métodos usuais de inferência passem a ser inválidos, mesmo assintoticamente. Nalguns modelos dinâmicos passa a ter-se $\text{plim}(\hat{\beta}) \neq \beta$.

Teste-t para autocorrelação AR(1) com regressores estritamente exógenos. $H_0 : \rho = 0$ em $u_t = \rho u_{t-1} + e_t$. Na regressão de \hat{u}_t sobre \hat{u}_{t-1} , sem constante, $t_\rho = \frac{\hat{\rho}}{se(\hat{\rho})} \stackrel{a}{\sim} \mathcal{N}(0, 1)$ sob H_0 .

Teste *h-alt* de Durbin para autocorrelação AR(1) sem exogeneidade estrita dos regressores. Na regressão auxiliar de \hat{u}_t sobre $x_{t1}, x_{t2}, \dots, x_{tk}, \hat{u}_{t-1}$, $t_\rho = \frac{\hat{\rho}}{se(\hat{\rho})} \stackrel{a}{\sim} \mathcal{N}(0, 1)$ sob H_0 .

Testes de Breusch-Godfrey para autocorrelações de ordens mais elevadas, sem exogeneidade estrita dos regressores. $H_0 : \rho_1 = \rho_2 = \dots = \rho_q = 0$ em $u_t = \rho_1 u_{t-1} + \rho_2 u_{t-2} + \dots + \rho_q u_{t-q} + e_t$. Da regressão auxiliar de \hat{u}_t sobre $x_{t1}, x_{t2}, \dots, x_{tk}, \hat{u}_{t-1}, \hat{u}_{t-2}, \dots, \hat{u}_{t-q}$, $BG(q) = LM(q) = (n-q) R_u^2 \stackrel{a}{\sim} \chi_{(q)}^2$ sob H_0 . Versão alternativa: estatística-*F* para testar a significância conjunta de $\hat{u}_{t-1}, \hat{u}_{t-2}, \dots, \hat{u}_{t-q}$.

A diferenciação do modelo pode ser útil para eliminar os sintomas de autocorrelação.

As consequências da heteroscedasticidade são semelhantes às da autocorrelação dos erros. Testes de heteroscedasticidade: de White e de Breusch-Pagan, com \hat{u}_t^2 como variável dependente das regressões auxiliares de teste.

Introdução aos métodos para dados de painel

Os dados seccionais agregados e independentes resultam de amostras aleatórias obtidas em pontos distintos do tempo. Já nos dados de painel, os (mesmos) elementos da amostra são seguidos ao longo do tempo.

Agregação de dados seccionais independentes e de diferentes períodos de tempo

Hipótese implícita: a relação entre a variável dependente e as explicativas é estável no tempo.

Para permitir a possibilidade de diferentes distribuições nos vários períodos de tempo, os termos independentes podem ser diferentes; isto consegue-se com a introdução de *dummies*.

Teste de Chow apenas para mudança nos coeficientes de declive ao longo do tempo:

$F_{CHOW} = \frac{[SSR_p - (SSR_1 + SSR_2 + \dots + SSR_T)]}{SSR_1 + SSR_2 + \dots + SSR_T} \cdot \frac{n-T(k+1)}{(T-1)k} \sim F_{[(T-1)k, n-T(k+1)]}$ sob H_0 , com SSR_p a SSR obtida do modelo estimado com o conjunto de todas as observações e com *dummies* para permitir termos independentes diferentes, e SSR_1 a SSR_T as $SSRs$ para cada um dos (T) períodos de tempo. k é o número de variáveis explicativas, não incluindo o termo independente nem as *dummies*.

Uma **experiência natural (ou quasi-experiência)** ocorre sempre que um acontecimento exógeno — frequentemente uma mudança de política — muda o ambiente em que os elementos da população operam.

Estimador de diferença-das-diferenças. Representando com **C** e **T** os grupos de controlo e de tratamento, respectivamente, e com dT a *dummy* com o valor 1 se o elemento pertence ao grupo T e d_2 a *dummy* para o segundo período (após a mudança), tem-se:

$$y = \beta_0 + \delta_0 d_2 + \beta_1 dT + \delta_1 d_2 \cdot dT + erro,$$

δ_1 é o efeito de tratamento médio e

$$\widehat{\delta}_1 = (\bar{y}_{2,T} - \bar{y}_{2,C}) - (\bar{y}_{1,T} - \bar{y}_{1,C}) = (\bar{y}_{2,T} - \bar{y}_{1,T}) - (\bar{y}_{2,C} - \bar{y}_{1,C}).$$

onde o primeiro índice representa o ano (o período), e o segundo representa o grupo. Nota: se a equação tiver variáveis explicativas adicionais, a expressão da estimativa de δ_1 muda mas o seu significado mantém-se.

Análise de dados de painel de dois períodos

Principal utilidade destes dados: permitem que os efeitos fixos ou não observados estejam correlacionados com os regressores. Exemplo básico de **modelo de efeitos fixos ou não observados**, com apenas uma variável explicativa:

$$y_{it} = \beta_0 + \delta_0 d2_t + \beta_1 x_{it} + a_i + u_{it}, \quad t = 1, 2,$$

onde $d2_t$ é uma *dummy* igual a 1 quando $t = 2$ (e igual a zero se $t = 1$), a_i é o efeito não observado ou efeito fixo ou heterogeneidade não observada e u_{it} é o erro idiosincrático. Em geral, o estimador OLS (da equação sem a_i) é enviesado e inconsistente (tem o “enviesamento de heterogeneidade”). Solução: estimar com o OLS a equação de **primeira diferença**:

$$\Delta y_i = \delta_0 + \beta_1 \Delta x_i + \Delta u_i.$$

Hipótese mais importante: a de exogeneidade, $\text{Cov}(\Delta u_i, \Delta x_i) = 0, \forall i$, que é satisfeita se a hipótese de exogeneidade estrita for satisfeita no modelo inicial; outra condição: Δx_i deve ter alguma variação ao longo de i . Pode acontecer que todas as hipóteses do modelo clássico sejam satisfeitas.

Modelo geral:

$$y_{it} = \beta_0 + \delta_0 d2_t + \beta_1 x_{it1} + \beta_2 x_{it2} + \dots + \beta_k x_{itk} + a_i + u_{it}, \quad t = 1, 2.$$

Em x_{itj} i é o índice de observação seccional, t o do período de tempo e j o de variável.

Análise de política com dados de painel de dois períodos

Modelo de efeitos não observados mais simples:

$$y_{it} = \beta_0 + \delta_0 d2_t + \beta_1 prog_{it} + a_i + u_{it},$$

onde y_{it} é uma “variável de resultado” e $prog_{it}$ é uma *dummy* de participação no programa ($d2_t$ é a *dummy* com valor 1 para o segundo período). Se a participação no programa só ocorreu no segundo período, o estimador (OLS) de β_1 da equação diferenciada é

$$\widehat{\beta}_1 = \overline{\Delta y_{treat}} - \overline{\Delta y_{control}},$$

que é a versão de dados de painel do estimador de diferença das diferenças.

EViews: convém que os dados estejam “empilhados” de acordo com as unidades seccionais e para cada uma delas. Convém **estruturar** o ficheiro de trabalho, para: a) identificar a unidade seccional associada com cada observação e b) identificar as datas ou períodos de tempo das observações. Fazendo: PROC (ou clicando 2 vezes no “range”) -> **workfile structure: balanced panel**. Nas respectivas caixas, indicar as variáveis de data (“date series”) e de identificação das unidades seccionais (“cross-section id series”). Vantagem da “reestruturação”: os desfasamentos e os avanços nunca envolverão os dados de 2 unidades seccionais diferentes.

A estimação da matriz de covariâncias do estimador OLS robusta à heteroscedasticidade, *à la White*, usual, obtém-se com a opção (de painel): **coef covariance method: White (diagonal)**.