

Formulário de Econometria

Artur Silva Lopes, 28/4/2016¹

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

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

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

$\text{Var}(\widehat{\boldsymbol{\beta}}|\mathbf{X}) = \widehat{\sigma}^2(\mathbf{X}'\mathbf{X})^{-1}$, $\text{Var}(\widehat{\beta}_j|\mathbf{X}) = \frac{\widehat{\sigma}^2}{SST_j(1-R_j^2)}$, $j = 1, 2, \dots, k$, 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.

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

$H_0 : \beta_1 = \beta_2 = \dots = \beta_k = 0$, $F = \frac{R^2}{1-R^2} \times \frac{n-k-1}{k} \sim F_{(k, n-k-1)}$ 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: $\text{Var}^*(\widehat{\boldsymbol{\beta}}|\mathbf{X}) = (\mathbf{X}'\mathbf{X})^{-1} \sum \widehat{u}_i^2 \mathbf{x}_i \mathbf{x}_i' (\mathbf{X}'\mathbf{X})^{-1}$;

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

Estatísticas de teste (LM) de heteroscedasticidade: $LM = n R_{u^2}^2 \stackrel{a}{\sim} \chi_{(p)}^2$ 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 = $100[\exp(\widehat{\beta}_1) - 1]$, com $\widehat{\beta}_1$ 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 $y = \beta_0 + \beta_1 x_1 + \dots + \beta_k x_k + u$ para grupo 2. $F_{CHOW} = \frac{[SSR_p - (SSR_1 + SSR_2)] / (k+1)}{(SSR_1 + SSR_2) / [n - 2(k+1)]} \sim F_{(k+1, n-2(k+1))}$

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

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: $\Delta P(y = 1|\mathbf{x}) = G(\text{novos pontos}) - G(\text{ponto inicial})$.

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 $x_2 = D(\text{ummy})$: 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: $\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \mathbf{u}$. Importante: a hipótese de amostragem aleatória não é assumida. **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 de TS.2: forma funcional incorrecta; variáveis omitidas correlacionadas com as incluídas; alguns casos de erros de medição de regressores; 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) $\Rightarrow \text{Var}(\hat{\beta}_j | \mathbf{X}) = \frac{\sigma^2}{SST_j(1-R_j^2)}, j = 1, 2, \dots, k$. **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.

Forma funcional: tudo o que foi estudado para dados seccionais mantém-se válido. Idem para variáveis *dummy*. Exemplos de EViews: `pill=year>1962`; 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): $x_t = e_t + \alpha e_{t-1}$, $e_t \sim iid(0, \sigma_e^2)$. $E(x_t) = 0, \forall t$; $Var(x_t) = \sigma_e^2(1 + \alpha^2)$; $Cov(x_t, x_{t+1}) = \alpha \sigma_e^2$ e $corr(x_t, x_{t+1}) = \frac{\alpha}{1 + \alpha^2}$; $Cov(x_t, x_{t+h}) = corr(x_t, x_{t+h}) = 0, \forall h \geq 2$. 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, $\forall t$, $E(y_t) = 0$, $Var(y_t) = \sigma_y^2 = \frac{\sigma_e^2}{1 - \rho^2}$, $Cov(y_t, y_{t+1}) = \rho \sigma_y^2$, $corr(y_t, y_{t+1}) = \rho$, $corr(y_t, y_{t+h}) = \rho^h, \forall h \geq 0$.

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: $Var(u_t | \mathbf{x}_t) = \sigma^2, \forall t$. **TS.5'** Ausência de autocorrelação: $Cov(u_t, u_s) = 0, \forall t \neq s$. **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**); $y_t = y_0 + \sum_{i=1}^t e_i = y_0 + \text{tend. estocástica}$; $Var(y_t) = t \sigma_e^2, \forall t$; $E(y_{t+h} | I_t) = y_t, \forall h \geq 1$; $corr(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$. 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: $y_t = (\alpha_0 + \rho) y_{t-1} + u_t$, 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.: $y_t = \alpha_0 + \alpha_1 t + v_t \Rightarrow \Delta y_t = \alpha_1 + \Delta v_t$. Não nos preocuparemos com a possibilidade I(2).

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 $\exists t, s, t \neq s : Cov(u_t, u_s) \neq 0$, 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 de 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.

“Tópicos Avançados”

Testes de Dickey-Fuller (DF) de raiz unitária. Caso base: $y_t = \alpha + \rho y_{t-1} + e_t$. $H_0 : \rho = 1$ vs. $H_1 : \rho < 1 \Leftrightarrow H_0 : y_t \sim I(1)$ vs. $H_1 : y_t \sim I(0) \Leftrightarrow H_0 : \theta = 0$ vs. $H_1 : \theta < 0$ em $\Delta y_t = \alpha + \theta y_{t-1} + e_t$, $\theta = \rho - 1$. $DF = t_\theta = \hat{\theta}/se(\hat{\theta}) \stackrel{a}{\sim} DF$ sob H_0 ; $vc_{0.05} = -2.86$. Complicações: a) o AR(1) pode não ter dinâmica suficiente; b) a série pode ter tendência. Regressão auxiliar no caso mais geral:

$$\Delta y_t = \alpha + \beta t + \theta y_{t-1} + \sum_{i=1}^p \gamma_i \Delta y_{t-i} + e_t, \quad e_t \sim iid(0, \sigma^2).$$

$H_0 : \theta = 0$ vs. $H_1 : \theta < 0$, (A)DF = $t_\theta = \hat{\theta}/se(\hat{\theta}) \stackrel{a}{\sim} DF$ sob H_0 , com a distribuição a deslocar-se para a esquerda(direita) com a inclusão(exclusão) de regressores determinísticos.

Escolha de p : com método “*general-to-specific*” (GTS) $t - sig$, com testes com nível de 10%. **i.** Fixar p_{MAX} ; **ii.** estimar regressão com $p = p_{MAX}$ e testar significância de γ_p com teste assintótico com $\alpha = 0.10$. **iii.** Se $\hat{\gamma}_p$ for estatisticamente significativo, fazer $\hat{p} = p_{MAX}$ e $t_\theta = ADF(\hat{p})$; no caso contrário, repetir ii. e iii. com $p = p_{MAX} - 1$. Paragem: quando $\hat{\gamma}_p$ significativo (a 10%) ou $\hat{p} = 0$.

Que regressores determinísticos? Em excesso => testes perdem potência; a menos => testes perdem potência. Critérios: i) razoabilidade económica; a série tem relação com a de produtividade, ou com a da população ou com a de preços? ii) análise gráfica.

Regressões espúrias com processos I(1) independentes (passeios aleatórios, para simplificar). Sejam $x_t = x_{t-1} + a_t$, $a_t \sim iid(0, \sigma_a^2)$ e $y = y_{t-1} + e_t$, $e_t \sim iid(0, \sigma_e^2)$, com a_t e e_t independentes. Na regressão $y_t = \alpha + \beta x_t + u_t$, tem-se: a) $\text{plim}(\hat{\beta}) \neq \beta = 0$; b) $|t_\beta| \rightarrow +\infty$ (i.e., o resultado $t_\beta \stackrel{a}{\sim} \mathcal{N}(0, 1)$ sob $H_0 : \beta = 0$ não é válido); c) $R^2 \rightarrow$ variável aleatória.

Propriedades de combinações lineares de séries $I(0)$ e $I(1)$. Com a e b constantes não nulas: 1) se $y_t \sim I(0)[I(1)] \Rightarrow (a + by_t) \sim I(0)[I(1)]$; 2) se $y_t \sim I(0)$ e $x_t \sim I(0) \Rightarrow (ay_t + bx_t) \sim I(0)$; 3) se $y_t \sim I(1)$ e $x_t \sim I(0) \Rightarrow (ay_t + bx_t) \sim I(1)$; 4) *em geral*, se $y_t \sim I(1)$ e $x_t \sim I(1) \Rightarrow (ay_t + bx_t) \sim I(1)$. Todavia, se $\exists \beta \neq 0 : y_t - \beta x_t = u_t \sim I(0)$ (com média nula), y_t e x_t dizem-se cointegradas, $(y_t, x_t) \sim CI(1, 1)$, e β é o parâmetro de cointegração. Neste caso, na regressão $y_t = \alpha + \beta x_t + u_t$, $\text{plim}(\hat{\beta}) = \beta$.

Testes de cointegração. **A)** se β for conhecido: testes (A)DF sobre u_t ; **B)** se β for desconhecido: testes de Engle-Granger (EG) sobre \hat{u}_t . Nota: se y_t e/ou x_t tem(têm) deriva, deve incluir-se um termo em t na potencial equação de cointegração.

Teorema de representação de Granger (versão “light”). Sejam $y_t \sim I(1)$ e $x_t \sim I(1)$, mas $y_t(-\alpha - \gamma t) - \beta x_t = u_t \sim I(0)$ (com média nula), isto é, $(y_t, x_t) \sim CI(1, 1)$; então, existe representação em modelo de correcção de erros (MCE). Por exemplo:

$$\Delta y_t = \alpha_0 + \alpha_1 \Delta y_{t-1} + \gamma_0 \Delta x_t + \gamma_1 \Delta x_{t-1} + \delta u_{t-1} + e_t, \quad \text{com } \delta < 0.$$

A recíproca também é, em geral, verdadeira: se existe representação MCE para $y_t \sim I(1)$ e $x_t \sim I(1)$, então $(y_t, x_t) \sim CI(1, 1)$.

Estimação do MCE. **A)** Se β conhecido: imediata. **B)** Se β desconhecido: método de Engle-Granger em 2 passos. i) estimação OLS de β e de u_t ; ii) emprego de \hat{u}_{t-1} no MCE e estimação deste com o OLS.