

Capítulo 9

- ▶ **9. Análise da estacionaridade**
 - ▶ 9.1. Variáveis estacionárias e fracamente dependentes
 - ▶ 9.2. Propriedades assintóticas do OLS
 - ▶ 9.3. Variáveis altamente persistentes
 - ▶ 9.4. Testes de raízes unitárias
 - ▶ 9.5. Regressões espúrias

9.1. Variáveis estacionárias e fracamente dependentes

► Séries estacionárias

► Definição intuitiva

Uma série é estacionária se as características do seu comportamento estatístico e a estrutura de dependência não se modificam com o tempo.

► Estacionaridade em covariância:

o processo estocástico $\{y_t : t = 1, 2, \dots\}$ é estacionário em covariância se

$$1) E(y_t) = \mu \quad 2) Var(y_t) = \sigma_y^2 \quad 3) Cov(y_t, y_{t+h}) = f(h)$$

► Dependência fraca:

o processo estocástico $\{y_t : t = 1, 2, \dots\}$ é fracamente dependente se,

$$\lim_{h \rightarrow \infty} corr(y_t, y_{t+h}) = 0 \text{ de forma suficientemente rápida}$$

► Observações

- Uma série pode ser não estacionária mas ser fracamente dependente
- Estes dois conceitos são necessários para que se possa aplicar a lei dos grandes números e o teorema do limite central

9.1. Variáveis estacionárias e fracamente dependentes

Exemplos de séries estacionárias e fracamente dependentes


Processos MA

$$y_t = e_t + \alpha e_{t-1} \quad \text{MA(1)}$$

Com e_t um ruído branco (white noise) $\longleftrightarrow e_t$ i.i.d. $(0, \sigma^2)$

Processos AR

$$y_t = \alpha + \rho y_{t-1} + e_t \quad \text{AR(1)} \quad |\rho| < 1 \quad e_t \text{ i.i.d. } (0, \sigma^2)$$



$$y_t = 0.5y_{t-1} + e_t$$

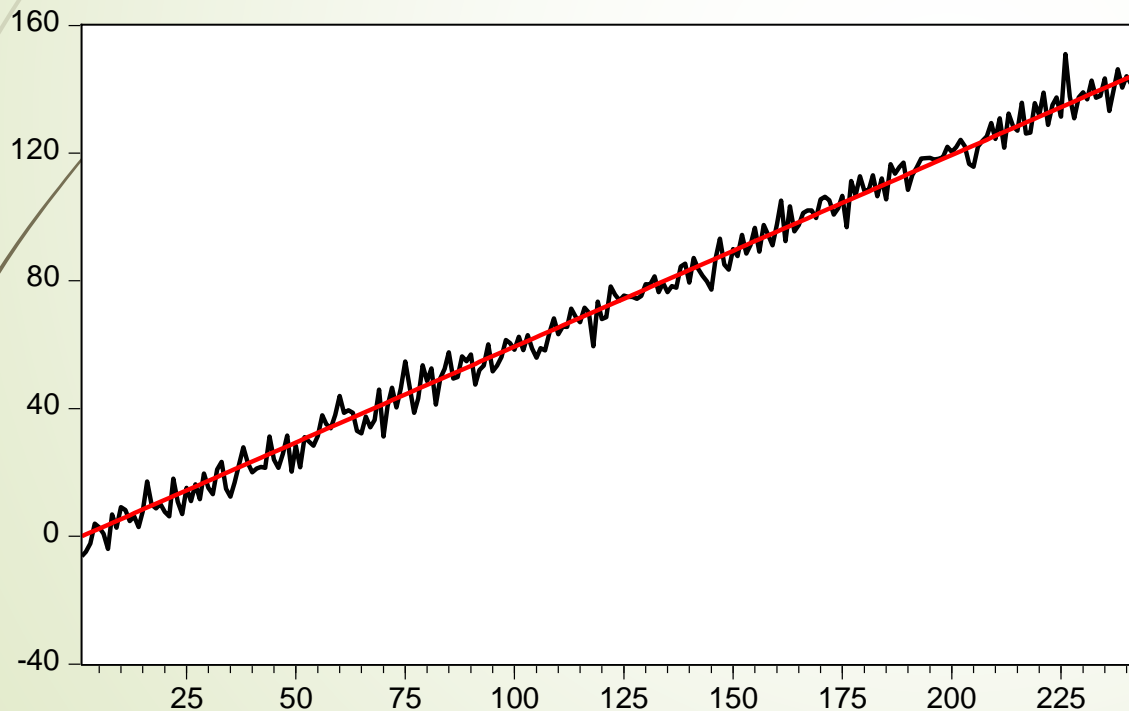
Comportamento de reversão para a média

9.1. Variáveis estacionárias e fracamente dependentes

Estacionaridade em tendência

o processo estocástico $\{y_t : t = 1, 2, \dots\}$ com $y_t = \delta_0 + \delta_1 t + u_t$ é estacionário em tendência se u_t for um processo fracamente dependente.

$$y_t = 0.5y_{t-1} + 0.6t + e_t$$



Comportamento de reversão para a média
(reversão para a tendência)

9.2 Propriedades assintóticas do OLS

► Hipóteses

► ST.1': Modelo linear nos parâmetros

$$y_t = \beta_0 + \beta_1 x_{t1} + \beta_2 x_{t2} + \dots + \beta_k x_{tk} + u_t$$

os processos estocásticos $\{y_t, x_{t1}, \dots, x_{tk} : t=1, 2, \dots\}$ são **estacionários e fracamente dependentes**

► ST.2': Não existe multicolinearidade perfeita

Na amostra nenhuma variável explicativa pode ser constante (supondo que existe termo independente) ou ser uma função linear das outras variáveis explicativas

► ST.3': média condicionada igual a zero – exogeneidade contemporânea

$$E(u_t | \mathbf{x}_t) = 0 \quad \text{com} \quad \mathbf{x}_t = [1 \quad x_{t1} \quad \dots \quad x_{tk}]$$

► Teorema: consistência do OLS: supondo que se verificam ST1' a ST3' então,

$$\text{plim}(\hat{\beta}_j) = \beta_j \quad j = 0, 1, 2, \dots, k$$

Na realidade para que o OLS seja consistente basta que as variáveis explicativas não sejam contemporaneamente correlacionadas com o erro

9.2 Propriedades assintóticas do OLS

- **Hipótese TS.4': homocedasticidade**

$$Var(u_t | \mathbf{x}_t) = Var(u_t) = \sigma^2$$

A variância dos erros num dado momento de tempo não pode depender das variáveis explicativas desse mesmo período e é constante no tempo

- **Hipótese TS.5': ausência de autocorrelação**

$$Cov(u_t, u_s | \mathbf{x}_t, \mathbf{x}_s) = Cov(u_t, u_s) = 0 \quad t \neq s$$

os erros não podem ser correlacionados no tempo condicionado às variáveis explicativas

- **Teorema: Normalidade assintótica**

Sob as hipóteses TS.1' a TS.5' prova-se que o estimador OLS tem uma distribuição assintótica normal,

$$t = \frac{\hat{\beta}_j - \beta_j}{se(\hat{\beta}_j)} \underset{\sim}{\sim} N(0, \sigma^2)$$

A inferência habitual (testes t , testes F e intervalos de confiança) é válida assintoticamente.

9.2 Propriedades assintóticas do OLS

► Observações

- Se as séries forem estacionárias em tendência (estacionárias em torno da tendência e fracamente dependentes) então verificam a hipótese TS.1' mas deve incluir-se uma tendência entre os regressores.
- A exogeneidade contemporânea garante que o OLS seja consistente mas poderá ser enviesado.
- Em modelos com variável dependente desfasada nos regressores o OLS é enviesado mas poderá ser consistente se $E(u_t | y_{t-1}, \mathbf{x}_t) = 0$. Esta condição dificilmente se verifica se houver autocorrelação.
- Para a garantia da consistência é fundamental ter séries estacionárias e fracamente dependentes (ou estacionárias em tendência). Se tal não acontecer, i.e., se as séries forem altamente persistentes, então devem ser transformadas em séries fracamente dependentes e a regressão OLS deve proceder-se sobre as séries transformadas.

9.3. Variáveis altamente persistentes

► Passeio aleatório

$$y_t = y_{t-1} + e_t \quad e_t \text{ i.i.d } N(0, \sigma^2)$$

$$y_t = y_0 + e_1 + e_2 + \dots + e_t$$

$$E(y_t) = E(y_0) \text{ não depende de } t$$

$$\text{Var}(y_t) = \sigma^2 t \text{ depende de } t$$

$$\text{corr}(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$$

Pode ser entendido como um processo
AR(1) com $\rho = 1 \rightarrow$ raíz unitária

O valor presente da série depende do valor inicial e de todos os choques passados até ao presente; os choques não são amortecidos com o tempo por isso a série é **altamente persistente**

É também altamente persistente pois a correlação entre as observações tende muito lentamente para zero e depende de t



Não existe comportamento de reversão para a média

9.3. Variáveis altamente persistentes

- **Passeio aleatório com deriva** É também um processo de raíz unitária

$$y_t = \alpha + y_{t-1} + e_t \quad e_t \text{ i.i.d } N(0, \sigma^2)$$

$$y_t = y_0 + \alpha t + e_1 + e_2 + \dots + e_t$$

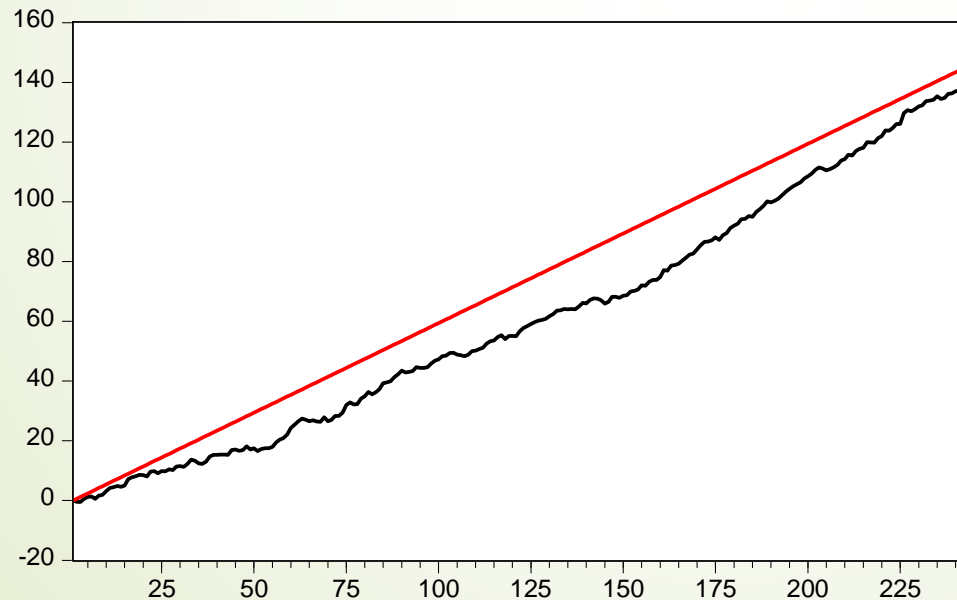
$$E(y_t) = E(y_0) + \alpha t \quad \text{depende de } t$$

$$\text{Var}(y_t) = \sigma^2 t \quad \text{depende de } t$$

$$\text{corr}(y_t, y_{t+h}) = \sqrt{\frac{t}{t+h}}$$

É também altamente persistente pois a correlação entre as observações tende muito lentamente para zero e depende de t

O valor presente da série depende do valor inicial, de uma tendência e de todos os choques passados até ao presente ► **altamente persistente**



Não existe comportamento de reversão para a média

9.3. Variáveis altamente persistentes

► Transformação de séries altamente persistentes

- Motivação:

$$y_t = y_{t-1} + e_t \Leftrightarrow y_t - y_{t-1} = e_t \Leftrightarrow \Delta y_t = e_t$$

y_t é altamente persistente mas Δy_t é estacionária e fracamente dependente

- Diferenciação: a diferenciação de séries altamente persistentes pode gerar séries estacionárias e fracamente dependentes.

- Séries integradas

uma série y_t é integrada de ordem d se for necessário d diferenciações para se obter uma série estacionária e fracamente dependente, integrada de ordem zero, $y_t \sim I(d) \Rightarrow \Delta^d y_t \sim I(0), \Delta^{d-1} y_t \sim I(1), d > 1$

- Se y_t é um passeio aleatório então $y_t \sim I(1)$ pois $\Delta y_t \sim I(0)$

- Uma grande parte das variáveis económicas são $I(1)$

- As variáveis a preços correntes por vezes são $I(2)$

9.4. Testes de raízes unitárias

► Testes de Dickey-Fuller

► Variáveis sem tendência

$$y_t = \alpha + \rho y_{t-1} + e_t$$

► Se $\alpha = 0, \rho = 1$ então y_t é um passeio aleatório $\Rightarrow y_t \sim I(1)$

► Se $|\rho| < 1$ então y_t é AR(1) $\Rightarrow y_t \sim I(0)$

► $H_0 : \rho = 1$ $H_1 : \rho < 1$

► É mais conveniente transformar o modelo:

$$y_t - y_{t-1} = \alpha + \rho y_{t-1} - y_{t-1} + e_t \quad \Delta y_t = \alpha + \gamma y_{t-1} + e_t \quad \text{com } \gamma = \rho - 1$$

$H_0 : \gamma = 0 (\rho = 1)$ $H_1 : \gamma < 0 (\rho < 1)$

$$\tau = \frac{\hat{\gamma}}{se(\hat{\gamma})} \sim DF_c$$

sob H_0 a série não é estacionária e fracamente dependente como tal os resultados habituais não são válidos \Rightarrow o rácio t não tem distribuição habitual t -student

9.4. Testes de raízes unitárias

- Existência de autocorrelação na equação de teste



- Teste aumentado de Dickey-Fuller

- Procedimento de teste:

- Escolher um número de defasamentos suficientemente grande, q
- Estimar a equação de teste pelo OLS:

$$\Delta y_t = \alpha + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \delta_2 \Delta y_{t-2} + \dots + \delta_q \Delta y_{t-q} + e_t$$

- Escolher o defasamento ótimo, p e estimar pelo OLS:

$$\Delta y_t = \alpha + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \delta_2 \Delta y_{t-2} + \dots + \delta_p \Delta y_{t-p} + e_t$$

- Testar

$$H_0 : \gamma = 0 (\rho = 1) \quad H_1 : \gamma < 0 (\rho < 1)$$

$$\tau = \frac{\hat{\gamma}}{se(\hat{\gamma})} \sim DF_c \quad \begin{array}{l} \text{rejeitar } H_0 \rightarrow y_t \sim I(0) \\ \text{não rejeitar } H_0 \rightarrow y_t \sim I(1) \end{array}$$

9.4. Testes de raízes unitárias

► Séries com tendência

► Procedimento de teste:

1. Escolher um número de defasamentos suficientemente grande, q
2. Estimar a equação de teste pelo OLS:

$$\Delta y_t = \alpha_0 + \alpha_1 t + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \delta_2 \Delta y_{t-2} + \dots + \delta_q \Delta y_{t-q} + e_t$$

3. Escolher o defasamento ótimo, p e estimar pelo OLS:

$$\Delta y_t = \alpha_0 + \alpha_1 t + \gamma y_{t-1} + \delta_1 \Delta y_{t-1} + \delta_2 \Delta y_{t-2} + \dots + \delta_p \Delta y_{t-p} + e_t$$

4. Testar

$$H_0 : \gamma = 0 (\rho = 1) \quad H_1 : \gamma < 0 (\rho < 1)$$

$$\tau = \frac{\hat{\gamma}}{se(\hat{\gamma})} \sim DF_{ct} \quad \begin{array}{l} \text{rejeitar } H_0 \Rightarrow y_t \sim I(0) \\ \text{não rejeitar } H_0 \Rightarrow y_t \sim I(1) \end{array}$$

9.5. Regressões Espúrias

- ▶ **Regressão espúria:** regressão com elevado R^2 , estatísticas- t que apontam para uma relação estatisticamente significativa entre as variáveis quando na realidade não existe relação causal entre elas.
- ▶ Verificou-se em estudos de simulação que regressões OLS com variáveis $I(1)$ independentes podem originar regressões espúrias
- ▶ Em estudos empíricos regista-se frequentemente resultados inesperados quando se aplica o OLS com variáveis $I(1)$
- ▶ **Recomendação:** Transformar as variáveis $I(1)$ (ou integradas de ordem superior) em variáveis $I(0)$ antes de as introduzir na regressão com OLS