

Capítulo 2

Processos Não Estacionários

Econometria II · UFBA

Prof. Pablo Castro

Parte I

- Processos estacionários
- **Processos não estacionários**
- Processos com tendência determinística

Parte II

- Metodologia de Box-Jenkins
- Previsão
- Cointegração
- Autoregressão vetorial

Seção 2.1

Processos Não Estacionários e Processos Integrados

O que estudamos neste capítulo?

Objetivo:

Revisão de processos não estacionários, compreender o conceito de raiz unitária e aprender os testes para detectá-la.

Roteiro

1. Motivação: regressão espúria e choques permanentes
2. Passeio aleatório (*random walk*)
3. Processos integrados $I(d)$
4. Teste Dickey-Fuller (DF)
5. Exercícios

Onde estamos?

- ✓ Introdução ao MQO
- ✓ Regressão e inferência
- ✓ Processos estacionários
- **Raiz unitária / $I(d)$**
 - Testes DF e ADF
 - Box-Jenkins
 - Cointegração / VAR

Séries Estacionárias vs. Não Estacionárias

Série estacionária

Oscila em torno de uma **média fixa**.
Choques têm efeito **temporário**.

A variância não cresce com o tempo.
O passado distante não importa.

Exemplo

Taxa de inflação (IPCA mensal): sobe, desce, mas gravita em torno de uma média histórica.

Série não estacionária

Sem média fixa para onde retornar.
Choques têm efeito **permanente**.

A variância **cresce** com o tempo.
O passado inteiro se acumula no presente.

Exemplo

Nível de preços (IPCA acumulado): nunca “volta” a um patamar anterior — cada choque desloca o índice para sempre.

Séries Estacionárias vs. Não Estacionárias

Consequência

Se a série for não estacionária e isso não for tratado, os modelos produzirão **inferências inválidas** e **previsões enganosas**. Verificar a estacionariedade é o **primeiro passo** de qualquer análise de séries temporais.

Definição

Dizemos que $\{y_t\}$ é **integrado de ordem** d , $y_t \sim I(d)$, se são necessárias d **diferenciações** para torná-lo estacionário:


$$\Delta^d y_t \sim I(0)$$

A notação $I(d)$ indica quantas vezes a série precisa ser **diferenciada** para se tornar estacionária.

- **$I(0)$** — já estacionário.
- **$I(1)$** — uma diferença torna a série estacionária: $\Delta y_t = y_t - y_{t-1} \sim I(0)$
- **$I(2)$** — duas diferenças são necessárias:

$$\Delta^2 y_t = \Delta(\Delta y_t) = \Delta(y_t - y_{t-1}) = \Delta y_t - \Delta y_{t-1} = (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) \sim I(0)$$

Exemplo: IPCA



Fonte: IBGE/SIDRA — Série 1737 (IPCA), 2010-2023.

O que é

Quando duas séries $I(1)$ **não relacionadas** são regredidas uma na outra, frequentemente obtemos R^2 alto e t -estatísticas significativas — sem nenhuma relação causal real.

Por que acontece?

- Séries $I(1)$ acumulam choques permanentes
- Duas séries com tendência estocástica “andam juntas” por coincidência
- A inferência via t de Student **não é válida** para séries $I(1)$

Solução: verificar se as séries são $I(1)$ **antes** de estimar qualquer regressão, usando os testes que veremos a seguir.

Problema

Quando duas séries $I(1)$ **não relacionadas** são regredidas uma na outra, frequentemente obtemos R^2 alto e t -estatísticas significativas — sem nenhuma relação causal real.

Por que acontece?

- Séries $I(1)$ acumulam choques permanentes ao longo do tempo
- Duas séries com tendência estocástica “andam juntas” por coincidência
- A inferência via t de Student **não é válida** para séries não estacionárias
- Durbin-Watson ≈ 0 é um sinal de alerta clássico

Exemplo

PIB e Ibovespa: ambas as séries crescem ao longo do tempo. Uma regressão do PIB no índice em *nível* produz $R^2 \approx 0,9$ e coeficientes altamente significativos — mesmo sem relação causal direta entre os dois.

Dois Tipos de Tendência

Séries com tendência podem ser de dois tipos muito diferentes:

Tipo 1: Tendência Determinística

$$y_t = \mu + \beta t + u_t, \quad u_t \sim I(0)$$

A série é *estacionária em torno de uma tendência*.

Choque: efeito **temporário** — a série retorna à tendência.

Tratamento: remover βt por regressão; **não diferenciar**.

Regressão Espúria:

A solução depende do tipo de não-estacionariedade: tendência **estocástica** → diferenciar; tendência **determinística** → remover a tendência.

Tipo 2: Tendência Estocástica – $I(1)$

$$y_t = \mu + y_{t-1} + \varepsilon_t$$

A série é *estacionária em primeira diferença*.

Choque: efeito **permanente** — a série não retorna.

Tratamento: tomar Δy_t ; **não regredir tendência**.

Choques Temporários vs. Permanentes

Processo estacionário: $I(0)$

Choque tem efeito **temporário**.

$$y_t = \phi y_{t-1} + \varepsilon_t, \quad |\phi| < 1$$

A série retorna à média após o choque.
Função impulso-resposta decai a zero.

Exemplo

Taxa Selic: um choque de política monetária eleva a taxa por alguns trimestres, mas ela converge de volta à taxa neutra de longo prazo.

Processo não estacionário: $I(1)$

Choque tem efeito **permanente**.

$$y_t = y_{t-1} + \varepsilon_t$$

Não há retorno a nenhuma média fixa.
Função impulso-resposta **não decai**.

Exemplo

Nível de preços (IPCA acumulado): o choque inflacionário de 2021–22 elevou o nível de preços permanentemente. Ele não “volta” ao patamar anterior.

Seção 2.2

Passeio Aleatório

Definição

O **passeio aleatório** (*random walk*) é o AR(1) com $\phi_1 = 1$:

$$y_t = y_{t-1} + \varepsilon_t, \quad \varepsilon_t \sim \text{RB}(0, \sigma^2), \quad \text{com } y_0 \text{ fixo}$$

Por que os choques se acumulam? Substituindo recursivamente:

$$y_1 = y_0 + \varepsilon_1$$

$$y_2 = y_1 + \varepsilon_2 = y_0 + \varepsilon_1 + \varepsilon_2$$

$$y_3 = y_2 + \varepsilon_3 = y_0 + \varepsilon_1 + \varepsilon_2 + \varepsilon_3$$

⋮

$$y_t = y_0 + \sum_{i=1}^t \varepsilon_i$$

Cada choque ε_i é incorporado **permanentemente** — nenhum é amortecido ou esquecido.

Propriedades

$$\mathbb{E}[y_t] = y_0$$

$$\text{Var}(y_t) = t\sigma^2 \xrightarrow{t \rightarrow \infty} \infty$$

$$\text{Cov}(y_t, y_{t+s}) = t\sigma^2, \quad s > 0$$

Intuição de $\text{Var} = t\sigma^2$: y_t é a soma de t choques independentes, cada um com variância σ^2 . Quanto mais períodos, mais incerteza acumulada.

Intuição de $\text{Cov}(y_t, y_{t+s}) = t\sigma^2$: y_t e y_{t+s} compartilham os mesmos t primeiros choques; os s adicionais são independentes de y_t .

Exemplo

Taxa de câmbio R\$/US\$: absorve choques permanentes a cada período. O melhor preditor da taxa de amanhã é a taxa de hoje.

Comparação com AR(1) estacionário

No AR(1) com $|\phi| < 1$, cada choque é amortecido pelo fator $\phi^k \rightarrow 0$.

No passeio aleatório ($\phi = 1$), o fator de amortecimento é $1^k = 1$ — o choque nunca decai.

Passeio Aleatório: Violação da Estacionariedade

Três condições e o passeio aleatório

Condição	Exige	Passeio aleatório
1. Média	$\mathbb{E}[y_t] = \mu$ constante	$\mathbb{E}[y_t] = y_0$ ✓*
2. Variância	$\text{Var}(y_t) < \infty$	$t\sigma^2 \rightarrow \infty$ viola
3. Covariância	Cov só de k	$t\sigma^2$: depende de t

*Para o passeio aleatório *puro* a média é constante em y_0 , mas as condições 2 e 3 são violadas.

Intuição

A série “anda” sem amarras: cada choque é absorvido **permanentemente**, fazendo a variância crescer sem limite.

Quanto maior t , mais incerta é a posição de y_t — mesmo que a média formal seja y_0 .

Passeio Aleatório com Drift

Definição

$$y_t = c + y_{t-1} + \varepsilon_t, \quad \text{com } y_0 \text{ fixo}$$

Iteração: Substituindo recursivamente:

$$y_1 = c + y_0 + \varepsilon_1$$

$$y_2 = c + y_1 + \varepsilon_2 = 2c + y_0 + \varepsilon_1 + \varepsilon_2$$

$$y_3 = c + y_2 + \varepsilon_3 = 3c + y_0 + \varepsilon_1 + \varepsilon_2 + \varepsilon_3$$

⋮

$$y_t = y_0 + ct + \sum_{i=1}^t \varepsilon_i$$

O c aparece **uma vez por período** — após t períodos acumula ct .

Passeio Aleatório com Drift: Propriedades

Propriedades

$$\mathbb{E}[y_t] = y_0 + ct \quad \longrightarrow \text{cresce com } t$$

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

A série combina **tendência determinística** (ct) com **tendência estocástica** ($\sum \varepsilon_i$).

Com $c \neq 0$, as **três condições** de estacionariedade são violadas.

Ao diferenciar: $\Delta y_t = c + \varepsilon_t$ — **estacionário**.

Exemplo

PIB real brasileiro: cresce de forma persistente ($c > 0$), mas com desvios cumulativos aleatórios em torno da tendência.

Crises como 2015–16 e 2020 deixam “cicatrices” permanentes no nível do PIB — o produto não recupera o patamar anterior.

Takeaway

c é o drift: desloca a série para cima a cada período.

$\sum \varepsilon_i$ é a tendência estocástica: acumula choques permanentemente.

Seção 2.3

Teste de Dickey-Fuller

Hipóteses e Reformulação do Teste DF

Ponto de partida: $y_t = \phi_1 y_{t-1} + \varepsilon_t$.

Hipóteses

$$H_0: \phi_1 = 1 \quad (\text{raiz unitária}) \quad H_1: |\phi_1| < 1 \quad (\text{estacionário})$$

Reformulação — subtraindo y_{t-1} de ambos os lados:

$$\underbrace{y_t - y_{t-1}}_{\Delta y_t} = (\phi_1 - 1) y_{t-1} + \varepsilon_t \implies \boxed{\Delta y_t = \delta y_{t-1} + \varepsilon_t, \quad \delta = \phi_1 - 1}$$

Hipóteses equivalentes

$$H_0: \delta = 0 \quad H_1: \delta < 0$$

Teste **unicaudal à esquerda**: rejeitamos H_0 quando $\hat{\delta}$ é suficientemente negativo.

Três Especificações do Teste DF

Equações estimadas

Caso	Equação	Quando usar
1. Sem constante	$\Delta y_t = \delta y_{t-1} + \varepsilon_t$	Série em torno de zero
2. Com constante	$\Delta y_t = c + \delta y_{t-1} + \varepsilon_t$	Série com média não-nula
3. Com tendência	$\Delta y_t = c + \beta t + \delta y_{t-1} + \varepsilon_t$	Série com tendência visível

Como escolher?

- Olhe o gráfico da série antes de testar
- Tendência visível \rightarrow inclua tendência (caso 3)
- Oscila em torno de nível não-nulo \rightarrow caso 2
- Cada caso tem **seus próprios valores críticos**

Referência de valores críticos (caso 2, $T = 100$)

Nível 1%	-3,51
Nível 5%	-2,89
Nível 10%	-2,58

Distribuição da Estatística DF e Regra de Decisão

Distribuição não padrão

A estatística $\tau = \hat{\delta}/\text{ep}(\hat{\delta})$ sob H_0 **não** segue a distribuição t de Student. Ela segue a **distribuição Dickey-Fuller**, com caudas mais espessas à esquerda e valores críticos mais negativos.

Regra de decisão

Resultado	Conclusão
$\tau < VC_{DF}$	Rejeita H_0 : série estacionária
$\tau \geq VC_{DF}$	Não rejeita H_0 : raiz unitária

VC_{DF} é **negativo**: só rejeitamos se a estatística for suficientemente negativa.

Seção 2.4

Exercícios

Enunciado

Seja o processo auto-regressivo: $y_t = \phi y_{t-1} + \varepsilon_t$. Julgue as afirmativas como **Verdadeiro (V)** ou **Falso (F)**:

- (a) O processo é estacionário para $\phi < 1$.
- (b) Se $\phi = 1$, o processo é dito um caminho aleatório (*random walk*).
- (c) O estimador de mínimos quadrados ordinários do parâmetro ϕ é não tendencioso.
- (d) A estatística t de Student pode ser usada para testar a presença de raiz unitária.
- (e) O processo pode ser escrito na forma alternativa $\Delta y_t = \delta y_{t-1} + \varepsilon_t$, em que $\delta = \phi - 1$ e $\Delta y_t = y_t - y_{t-1}$.

- (a) F A condição correta é $|\phi| < 1$. Se $\phi = -1,2$, por exemplo, temos $\phi < 1$ mas o processo *não* é estacionário.
- (b) V $\phi = 1 \Rightarrow y_t = y_{t-1} + \varepsilon_t$: definição do passeio aleatório.
- (c) F O estimador MQO de ϕ é **tendencioso** quando $\phi \approx 1$. Sob H_0 : raiz unitária, sua distribuição não é centrada em ϕ .
- (d) F Sob H_0 , a estatística t **não** segue a distribuição t de Student. Deve-se usar os valores críticos de Dickey-Fuller.
- (e) V $y_t - y_{t-1} = (\phi - 1)y_{t-1} + \varepsilon_t = \delta y_{t-1} + \varepsilon_t$, com $\delta = \phi - 1$. Essa é a forma usada no teste DF para detectar raiz unitária.

Reformulação DF

$$y_t = \phi y_{t-1} + \varepsilon_t$$

$$\Downarrow (-y_{t-1})$$

$$\Delta y_t = \delta y_{t-1} + \varepsilon_t$$

$$\delta = \phi - 1$$

$$H_0: \delta = 0$$

$$H_1: \delta < 0$$

Enunciado

Julgue as afirmativas como **Verdadeiro (V)** ou **Falso (F)**:

- (a) Toda série temporal estacionária com variância finita pode ser escrita como um modelo de média móvel com termo de erro serialmente não correlacionado.
- (b) Um modelo de séries temporais não estacionário tem pelo menos uma raiz unitária.
- (c) O teste de Dickey-Fuller é monocaudal.
- (d) Um modelo AR(2) dado por $Y_t = a + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \varepsilon_t$ será estacionário se $\phi_1 < 1$ e $\phi_2 < 1$.
- (e) Um passeio aleatório é um processo estacionário.

- (a) **V** Teorema de Wold: qualquer processo $I(0)$ com variância finita admite representação $MA(\infty)$ com inovações não correlacionadas.
- (b) **V** Não-estacionariedade do tipo raiz unitária implica que o polinômio AR tem pelo menos uma raiz no círculo unitário.
- (c) **V** $H_1: \delta < 0$: a rejeição ocorre apenas à **esquerda**. O teste é unicaudal.
- (d) **F** Para AR(2), a condição correta exige que as raízes de $1 - \phi_1 z - \phi_2 z^2 = 0$ estejam fora do círculo unitário, o que impõe três desigualdades simultâneas.
- (e) **F** $\text{Var}(y_t) = t\sigma^2 \rightarrow \infty$: variância cresce com t , violando a segunda condição de estacionariedade.

AR(2): condições de estacionariedade

$$\phi_1 + \phi_2 < 1$$

$$\phi_2 - \phi_1 < 1$$

$$|\phi_2| < 1$$

Apenas $\phi_1 < 1$ e $\phi_2 < 1$
não são suficientes.

Enunciado

Considere o seguinte processo: $Y_t = \delta + Y_{t-1} + u_t$, $t = 1, 2, \dots$, em que $Y_0 = 2$ e $u_t \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2)$.

Julgue as afirmativas como **Verdadeiro (V)** ou **Falso (F)**:

- (a) $\mathbb{E}(Y_t) = 2$
- (b) Y_t é um processo não-estacionário.
- (c) Se $\delta = 0$, Y_t é um processo estacionário.
- (d) $\text{Var}(Y_t) = t\sigma^2$
- (e) Definindo $\Delta Y_t = Y_t - Y_{t-1}$, o processo ΔY_t é estacionário.

- (a) F Por iteração: $Y_t = Y_0 + t\delta + \sum_{i=1}^t u_i$.
Logo $\mathbb{E}(Y_t) = 2 + t\delta$, que **depende de** t se $\delta \neq 0$.
- (b) V $\text{Var}(Y_t) = t\sigma^2$ cresce com t : segunda condição de estacionariedade violada.
- (c) F Mesmo com $\delta = 0$: $\text{Var}(Y_t) = t\sigma^2 \rightarrow \infty$. A variância cresce — o processo **ainda** é não estacionário.
- (d) V $Y_t = Y_0 + t\delta + \sum_{i=1}^t u_i \Rightarrow \text{Var}(Y_t) = t\sigma^2$.
✓
- (e) V $\Delta Y_t = \delta + u_t$: constante mais ruído branco \Rightarrow processo estacionário.

Passeio aleatório com drift

$$Y_t = \underbrace{Y_0 + \delta t}_{\text{tend. det.}} + \underbrace{\sum_{i=1}^t u_i}_{\text{tend. estoc.}}$$

$$\mathbb{E}(Y_t) = 2 + \delta t$$

$$\text{Var}(Y_t) = t\sigma^2$$

$$\Delta Y_t = \delta + u_t \sim I(0)$$

Conceitos revisados

- Regressão espúria e inferência inválida
- Choques permanentes ($I(1)$) vs. temporários ($I(0)$)
- Passeio aleatório: $\text{Var}(y_t) = t\sigma^2$
- Passeio aleatório com drift:
 $\mathbb{E}(y_t) = y_0 + ct$
- Processos $I(d)$: d diferenciações para $I(0)$
- Teste DF: reformulação, 3 especificações
- Distribuição não padrão da estatística τ

Para a próxima aula

- Tendência determinística (*trend-stationary*)
- Distinguir $I(1)$ de tendência determinística
- Modelos SARIMA
- Sazonalidade estocástica e determinística

Takeaway:

Num processo $I(1)$, choques são **permanentes**. Diferenciar remove a tendência estocástica — mas **não deve ser feito** se a tendência for determinística.

Dúvidas?

Próxima aula: Tendência Determinística e SARIMA