

# Séries Temporais

Econometria II · UFBA

Prof. Pablo Castro

Referência: Notas de Aula

## Parte I

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

## Parte II

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

# Introdução

# Processo estocástico vs. série temporal

---

## Definição

Um processo estocástico é uma sequência de variáveis aleatórias  $\{y_t, t \in \mathbb{Z}\}$  cujos valores são governados pelas leis da probabilidade.

### Processo estocástico

O mecanismo gerador de dados: todas as realizações possíveis.

*Nunca observado diretamente.*

### Série temporal

Uma única realização desse processo: os dados que de fato coletamos.

*O que aparece na planilha / banco de dados.*

### Exemplo

O IPCA de janeiro/2024 (0,42%) é **uma** realização do processo estocástico “inflação brasileira”. Poderíamos ter observado um valor diferente se o choque do petróleo em dezembro/2023 tivesse sido outro.

Capítulo 1

# Processos Estacionários

Econometria II · UFBA

Prof. Pablo Castro

## O que estudamos neste capítulo?

---

### Objetivo:

Revisar os conceitos fundamentais do Capítulo 1 antes de avançarmos para processos não-estacionários, testes de raiz unitária e ARIMA.

### Roteiro

1. Estacionariedade fraca e ruído branco
2. Processos  $AR(1)$  e  $AR(p)$
3. Processos  $MA(q)$  e  $ARMA(p,q)$
4. ACF e PACF: como ler os gráficos
5. Exercícios

### Onde estamos?

- ✓ Introdução ao MQO
- ✓ Regressão e inferência
- **Séries temporais**
  - Processos estacionários
  - Raiz unitária / ARIMA
  - Box-Jenkins
  - Cointegração / VAR

## Estacionariedade Fraca

---

### Definição 1 – Processo fracamente estacionário

O processo  $\{y_t\}$  é fracamente estacionário (ou estacionário de segunda ordem) se:

1.  $\mathbb{E}[y_t] = \mu < \infty$ , para todo  $t$
2.  $\text{Var}(y_t) = \gamma_0 < \infty$ , para todo  $t$
3.  $\text{Cov}(y_t, y_{t-k}) = \gamma_k$ , depende *apenas* de  $k$ , não de  $t$

### Estacionário – exemplos

**Taxa de inflação** (IPCA): oscila em torno de uma média, sem tendência sistemática de crescimento.

**Retorno de ações** (log-retorno): media próxima de zero, variância relativamente estável.

### Não-estacionário – exemplos

**Nível do PIB**: cresce ao longo do tempo – a média muda.

**Preço de ações**: apresenta tendência e variância crescente.

**Taxa de câmbio nominal**: persistente, com choques permanentes.

### Definição 2 – Ruído Branco

O processo  $\{\varepsilon_t\}$  é um ruído branco se:

$$\mathbb{E}[\varepsilon_t] = 0, \quad \text{Var}(\varepsilon_t) = \sigma^2, \quad \text{Cov}(\varepsilon_t, \varepsilon_{t-k}) = 0 \quad \forall k \neq 0$$

Quando  $\varepsilon_t \stackrel{iid}{\sim} \mathcal{N}(0, \sigma^2)$ : **ruído branco gaussiano**.

### Intuição

Cada observação é “nova informação pura”: não carrega informação sobre o passado nem sobre o futuro.

**Importante:** O ruído branco é o bloco de construção de todos os modelos ARMA.

### Exemplo

Se a taxa de câmbio fosse ruído branco, nenhum operador de câmbio conseguiria lucro sistemático olhando o histórico.

Na prática, *retornos* de ativos são bem aproximados por ruído branco; os *níveis* não.

## Processo AR(1)

---

$$y_t = c + \phi_1 y_{t-1} + u_t, \quad u_t \sim \text{RB}(0, \sigma^2)$$

### Condição de estacionariedade

O AR(1) é **fracamente estacionário** se, e somente se,  $|\phi_1| < 1$ .

### Propriedades (sob $|\phi_1| < 1$ )

$$\mathbb{E}[y_t] = \frac{c}{1 - \phi_1}, \quad \text{Var}(y_t) = \frac{\sigma^2}{1 - \phi_1^2}$$

$$\gamma_k = \text{Cov}(y_t, y_{t-k}) = \phi_1^k \cdot \gamma_0$$

### Exemplo

**Inflação mensal:** se a inflação de janeiro foi alta, a de fevereiro tende a ser também (inércia inflacionária). O AR(1) captura essa persistência.

$\phi_1 = 0.5$ : metade do desvio da semana passada persiste hoje.

Se  $|\phi_1| \geq 1$ : variância diverge  $\rightarrow$  processo não-estacionário.

## Processo AR( $p$ ) e o Operador Lag

---

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + u_t$$

**Operador lag:**  $L^i y_t = y_{t-i}$ . Então:

$$\Phi(L) y_t = c + u_t, \quad \text{com } \Phi(L) = 1 - \phi_1 L - \phi_2 L^2 - \dots - \phi_p L^p$$

onde  $\Phi(L)$  é o polinômio característico do AR( $p$ ).

### Condição de Estacionariedade – AR( $p$ )

As raízes do polinômio característico  $\Phi(z) = 0$  devem estar **fora do círculo unitário**  $|z| > 1$  (equivalentemente, os *inversos* das raízes devem estar *dentro* do círculo).

### Exemplo: AR(2) para o crescimento do PIB

$$y_t = 0.4 y_{t-1} + 0.2 y_{t-2} + u_t$$

Polinômio:  $1 - 0.4z - 0.2z^2 = 0 \Rightarrow$  raízes fora do círculo  $\Rightarrow$  **estacionário**.

Interpretação: crescimento do PIB neste trimestre depende dos dois anteriores.

## Processo MA(1)

---

$$y_t = \mu + u_t + \theta_1 u_{t-1}, \quad u_t \sim \text{RB}(0, \sigma^2)$$

### Propriedade

O processo MA(1) é **sempre fracamente estacionário**, pois é uma combinação linear finita de um ruído branco.

### Propriedades

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

$$\text{Var}(y_t) = (1 + \theta_1^2) \sigma^2$$

$$\gamma_k = \text{Cov}(y_t, y_{t-k}) = \begin{cases} \theta_1 \sigma^2 & k = 1 \\ 0 & k > 1 \end{cases}$$

$$\text{Autocorrelação: } \rho_k = \begin{cases} \frac{\theta_1}{1 + \theta_1^2} & k = 1 \\ 0 & k > 1 \end{cases}$$

### Exemplo

**Erros de previsão do orçamento público:** um choque inesperado na arrecadação afeta a previsão deste mês e ainda aparece no mês seguinte, mas depois desaparece.

**Intuição:** no MA(1), o efeito do choque dura apenas um período – memória curta.

## Processo MA( $q$ )

---

$$y_t = \mu + u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \cdots + \theta_q u_{t-q}$$

### Propriedade

Todo processo MA( $q$ ) é **sempre fracamente estacionário**, pois é uma combinação linear finita de ruídos brancos contemporâneos e passados.

### Propriedades gerais

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

$$\text{Var}(y_t) = (1 + \theta_1^2 + \theta_2^2 + \cdots + \theta_q^2) \sigma^2$$

$$\gamma_k = (\theta_k + \theta_{k+1}\theta_1 + \theta_{k+2}\theta_2 + \cdots + \theta_q\theta_{q-k}) \sigma^2, \quad k \leq q$$

$$\gamma_k = 0, \quad k > q$$

### Exemplo

**Choques temporários de oferta:** uma greve, um problema climático ou um reajuste pontual de energia pode afetar a série por alguns períodos, mas o efeito desaparece depois.

No MA( $q$ ), o choque dura no máximo  $q$  períodos.

## Processo ARMA( $p,q$ )

---

$$y_t = c + \underbrace{\phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p}}_{\text{componente AR}} + \underbrace{u_t + \theta_1 u_{t-1} + \theta_2 u_{t-2} + \cdots + \theta_q u_{t-q}}_{\text{componente MA}}$$

Combina memória de **valores passados** (AR) com memória de **choques passados** (MA).

### Estacionariedade

Determinada **somente pelo componente AR**: as raízes de  $\Phi(z) = 0$  devem estar fora do círculo unitário. O componente MA não impõe restrições adicionais.

### Exemplo

**IPCA acumulado em 12 meses**: combina inércia inflacionária do passado (AR) com resposta a choques de energia e câmbio (MA).

## Propriedade: um processo AR(1) pode ser escrito como um MA( $\infty$ )

---

Considere um AR(1) **estacionário** ( $|\phi_1| < 1$ ) com  $u_t \sim \text{RB}(0, \sigma^2)$ :

$$y_t = c + \phi_1 y_{t-1} + u_t$$

**Ideia:** substituir  $y_{t-1}$  pela sua própria definição, depois  $y_{t-2}$ , e assim por diante.

### Substituição recursiva

$$\begin{aligned} y_t &= c + \phi_1 \underbrace{(c + \phi_1 y_{t-2} + u_{t-1})}_{y_{t-1}} + u_t \\ &= c(1 + \phi_1) + \phi_1^2 y_{t-2} + u_t + \phi_1 u_{t-1} \end{aligned}$$

Substituindo agora  $y_{t-2} = c + \phi_1 y_{t-3} + u_{t-2}$ :

$$y_t = c(1 + \phi_1 + \phi_1^2) + \phi_1^3 y_{t-3} + u_t + \phi_1 u_{t-1} + \phi_1^2 u_{t-2}$$

## Propriedade: um processo AR(1) pode ser escrito como um MA( $\infty$ )

---

**Repetindo o procedimento  $n$  vezes**, obtemos uma expressão com três blocos: a constante acumulada, o termo que sobra com  $y_{t-n}$ , e a soma dos choques passados.

**Após  $n$  substituições – escrevendo termo a termo:**

$$y_t = c(1 + \phi_1 + \phi_1^2 + \cdots + \phi_1^{n-1}) + \phi_1^n y_{t-n} \\ + u_t + \phi_1 u_{t-1} + \phi_1^2 u_{t-2} + \cdots + \phi_1^{n-1} u_{t-(n-1)}$$

**A mesma expressão, agora em notação compacta:**

$$y_t = c \sum_{i=0}^{n-1} \phi_1^i + \phi_1^n y_{t-n} + \sum_{i=0}^{n-1} \phi_1^i u_{t-i}$$

## AR(1) como MA( $\infty$ ) – tomando o limite

---

Partindo da expressão obtida após  $n$  substituições:

$$y_t = c \sum_{i=0}^{n-1} \phi_1^i + \phi_1^n y_{t-n} + \sum_{i=0}^{n-1} \phi_1^i u_{t-i}$$

Sob a hipótese de estacionariedade  $|\phi_1| < 1$ , fazendo  $n \rightarrow \infty$ :

- $\sum_{i=0}^{n-1} \phi_1^i \rightarrow \frac{1}{1 - \phi_1}$  (soma da PG infinita)
- $\phi_1^n y_{t-n} \rightarrow 0$  (em média quadrática, pois  $|\phi_1|^n \rightarrow 0$ )
- $\sum_{i=0}^{n-1} \phi_1^i u_{t-i} \rightarrow \sum_{i=0}^{\infty} \phi_1^i u_{t-i}$

## AR(1) como MA( $\infty$ )

---

Resultado: AR(1) = MA( $\infty$ )

$$y_t = \underbrace{\frac{c}{1 - \phi_1}}_{\mu} + \sum_{i=0}^{\infty} \phi_1^i u_{t-i}$$

Ou seja, o AR(1) tem a forma de um MA( $\infty$ ) com média  $\mu = c/(1 - \phi_1)$  e coeficientes  $\theta_i = \phi_1^i$ , que **decaem geometricamente** em  $i$ .

## Demonstração *alternativa* via operador lag

---

Reescrevendo o AR(1) com o operador  $L$ :

$$y_t - \phi_1 L y_t = c + u_t \iff (1 - \phi_1 L) y_t = c + u_t$$

Sob  $|\phi_1| < 1$ , o polinômio  $1 - \phi_1 L$  é invertível e

$$(1 - \phi_1 L)^{-1} = \sum_{i=0}^{\infty} \phi_1^i L^i,$$

em analogia à série geométrica  $\frac{1}{1-x} = \sum_{i=0}^{\infty} x^i$  válida para  $|x| < 1$ .

Aplicando  $(1 - \phi_1 L)^{-1}$  dos dois lados:

$$y_t = (1 - \phi_1 L)^{-1}(c + u_t) = \frac{c}{1 - \phi_1} + \sum_{i=0}^{\infty} \phi_1^i u_{t-i}$$

– mesmo resultado obtido pela substituição recursiva. ■

### Interpretação econômica

Cada choque  $u_{t-i}$  continua afetando  $y_t$ , mas com peso  $\phi_1^i$  que diminui geometricamente. Quanto maior  $\phi_1$  (mais perto de 1), **mais persistente** é o efeito de choques antigos sobre o presente.

## Generalização: Teorema de Wold

### Teorema de Wold

Todo processo  $\{y_t\}$  **fracamente estacionário** admite uma representação única da forma

$$y_t = \mu + \sum_{i=0}^{\infty} \psi_i u_{t-i},$$

em que:

- $\{u_t\}$  é um ruído branco com  $\text{Var}(u_t) = \sigma^2$ ;
- os coeficientes  $\{\psi_i\}$  satisfazem  $\psi_0 = 1$  e  $\sum_{i=0}^{\infty} \psi_i^2 < \infty$ .

**Consequência:** todo processo **AR**( $p$ ) – e, mais geralmente, todo **ARMA**( $p, q$ ) – *estacionário* admite uma representação **MA**( $\infty$ ).

A demonstração feita aqui para o **AR**(1) é apenas o caso particular mais simples desse resultado geral. Não demonstraremos o teorema geral, pois sua prova formal foge ao escopo do curso.

## ACF e PACF: o que são?

---

### ACF — Autocorrelation Function

Mede a correlação entre  $y_t$  e sua defasagem  $y_{t-k}$ , **sem remover** o efeito dos lags intermediários.

$$\rho_k = (y_t, y_{t-k}) = \frac{\gamma_k}{\gamma_0}$$

*Exemplo:* a inflação de janeiro correlaciona com a de março em parte porque ambas passaram por fevereiro. A ACF inclui esse caminho indireto.

#### Como ler a ACF

→ Indica a ordem do processo **MA**.

ACF corta após lag  $q \Rightarrow$  provavelmente  $MA(q)$ .

### PACF — Partial Autocorrelation Function

Mede a correlação “direta” entre  $y_t$  e  $y_{t-k}$ , **controlando** os lags  $y_{t-1}, \dots, y_{t-k+1}$ .

$$\phi_{kk} = (y_t, y_{t-k} \mid y_{t-1}, \dots, y_{t-k+1})$$

*Exemplo:* a PACF de ordem 3 mede se há ligação direta entre a inflação de janeiro e a de outubro, *depois de remover* o efeito de novembro e dezembro.

#### Como ler a PACF

→ Indica a ordem do processo **AR**.

PACF corta após lag  $p \Rightarrow$  provavelmente  $AR(p)$ .

## Enunciado

Considere o processo  $X_t = Y_t + 0,5 Y_{t-1} - 0,2 Y_{t-2}$ , em que  $Y_t$  é ruído branco com  $\mathbb{E}[Y_t] = 0$ ,  $\text{Var}(Y_t) = \sigma^2$  e  $\mathbb{E}[Y_t Y_s] = 0$  para  $t \neq s$ .

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

- (a)  $\mathbb{E}[X_t] = 0$
- (b)  $\text{Var}(X_t) = 1,29 \sigma^2$
- (c)  $\text{Cov}(X_t, X_{t-1}) = 0,4 \sigma^2$
- (d)  $\text{Cov}(X_t, X_{t-2}) = 0$
- (e)  $\text{Cov}(X_t, X_{t-3}) = 0$

$X_t$  é MA(2) com  $\theta_1 = 0,5$  e  $\theta_2 = -0,2$ .

- (a) V  $\mathbb{E}[X_t] =$   
 $\mathbb{E}[Y_t] + 0,5 \mathbb{E}[Y_{t-1}] - 0,2 \mathbb{E}[Y_{t-2}] = 0$
- (b) V  $\text{Var}(X_t) = (1 + 0,5^2 + 0,2^2) \sigma^2 = 1,29 \sigma^2$
- (c) V  $\text{Cov}(X_t, X_{t-1}) = (\theta_1 + \theta_1\theta_2) \sigma^2$   
 $= (0,5 + 0,5 \cdot (-0,2)) \sigma^2 = 0,4 \sigma^2$
- (d) F  $\text{Cov}(X_t, X_{t-2}) = \theta_2 \sigma^2 = -0,2 \sigma^2 \neq 0$
- (e) V MA(2): autocovariância é zero para lags  
 $k > q = 2$ .

Fórmula geral MA( $q$ )

$$\gamma_k = \begin{cases} \left( \sum_{j=0}^{q-k} \theta_j \theta_{j+k} \right) \sigma^2 & k \leq q \\ 0 & k > q \end{cases}$$

com  $\theta_0 = 1$ .

## Enunciado

Considere o processo  $Y_t = 5 + e_t + 0,3e_{t-1}$ , em que  $e_t$  é ruído branco com  $\mathbb{E}[e_t] = 0$ ,  $\text{Var}(e_t) = \sigma^2$  e  $\mathbb{E}[e_t e_s] = 0$  para  $t \neq s$ .

Julgue as afirmativas como **V** ou **F**:

(a)  $\mathbb{E}[Y_t] = 5$

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

(c)  $\text{Cov}(Y_t, Y_{t-1}) = \frac{3\sigma^2}{10}$

(d)  $\text{Cov}(Y_t, Y_{t-3}) = 0$

(e)  $\text{Cov}(Y_t, Y_{t-1}) = \frac{1}{4}$

$Y_t$  é MA(1) com média 5 e  $\theta_1 = 0,3$ .

(a) V  $\mathbb{E}[Y_t] = 5 + \mathbb{E}[e_t] + 0,3 \mathbb{E}[e_{t-1}] = 5$

(b) F  $\text{Var}(Y_t) = (1 + 0,3^2)\sigma^2 = 1,09 \sigma^2$

(c) V  $\gamma_1 = \theta_1 \sigma^2 = 0,3 \sigma^2 = \frac{3\sigma^2}{10} \checkmark$

(d) V MA(1):  $\gamma_k = 0$  para  $k > 1$ , portanto  $\gamma_3 = 0$ .

(e) F  $\rho_1 = \frac{0,3}{1,09} \approx 0,275 \neq \frac{1}{4}$

Resumo MA(1)

$$\text{Var} = (1 + \theta_1^2)\sigma^2$$

$$\rho_1 = \frac{\theta_1}{1 + \theta_1^2}$$

$$\rho_k = 0, \quad k > 1$$

**Atenção (b):** confusão comum –

$\text{Var}(Y_t) \neq \sigma^2$  sempre que  $\theta_1 \neq 0$ .

## Enunciado

Considere o modelo AR(1):

$$Y_t = \phi_1 Y_{t-1} + u_t, \quad |\phi_1| < 1, \quad u_t \stackrel{iid}{\sim} \mathcal{N}(0, \sigma_u^2)$$

Julgue as afirmativas como **V** ou **F**:

- (a)  $Y_t$  pode ser representado como  $Y_t = \sum_{i=0}^{\infty} \phi_1^i u_{t-i}$
- (b)  $\mathbb{E}[Y_t] = 0$
- (c)  $\text{Var}(Y_t) = \sigma_u^2$
- (d)  $Y_t$  tem distribuição normal
- (e)  $\text{Cov}(Y_{t-1}, Y_{t-2}) = \phi_1^2 \sigma_u^2$

(a) V Substituições recursivas:

$$Y_t = u_t + \phi_1 Y_{t-1} = u_t + \phi_1 u_{t-1} + \phi_1^2 Y_{t-2} = \dots$$

Sob  $|\phi_1| < 1$  a série converge.

(b) V  $\mathbb{E}[Y_t] = \sum_{i=0}^{\infty} \phi_1^i \mathbb{E}[u_{t-i}] = 0$  (constante  $c = 0$  no modelo)

(c) F  $\text{Var}(Y_t) = \frac{\sigma_u^2}{1 - \phi_1^2} \neq \sigma_u^2$  (exceto se  $\phi_1 = 0$ )

(d) V  $Y_t$  é combinação linear infinita de normais iid  $\Rightarrow$  normal.

(e) F  $\text{Cov}(Y_{t-1}, Y_{t-2}) = \phi_1 \text{Var}(Y_t) = \frac{\phi_1 \sigma_u^2}{1 - \phi_1^2}$

A alternativa diz  $\phi_1^2 \sigma_u^2$ , que estaria errada.

Resumo AR(1) estacionário

$$\mathbb{E}[Y_t] = \frac{c}{1 - \phi_1}$$

$$\text{Var}(Y_t) = \frac{\sigma_u^2}{1 - \phi_1^2}$$

$$\gamma_k = \phi_1^k \cdot \text{Var}(Y_t)$$

$$\rho_k = \phi_1^k$$

# Resumo da aula

### Conceitos revisados

- Processo estocástico vs. série temporal
- Estacionariedade fraca (3 condições)
- Ruído branco
- $AR(1)$ ,  $AR(p)$ : condição das raízes
- $MA(1)$ ,  $MA(q)$ : sempre estacionário
- $ARMA(p,q)$ : combinação de  $AR(p)$  e  $MA(q)$
- ACF e PACF: leitura e interpretação

### Para a próxima aula

- Processos não-estacionários
- Passeio aleatório (*random walk*)
- Efeitos permanentes de choques
- Diferenciação e processo  $I(1)$
- Teste ADF

### Takeaway:

Num processo estacionário, choques são **temporários**.

Num não-estacionário, são **permanentes**.

**Dúvidas?**

Próxima aula: Processos Não Estacionários