

# Processos Estacionários

Domingos Sávio de O. Santos Jr.

Capítulo 2

3 de septiembre de 2018

# Processos Lineares

- Os processos lineares envolvem os modelos:
  - ▶ AR (auto-regressivo);
  - ▶ MA (médias móveis);
  - ▶ ARMA (auto-regressivo e médias móveis);
- Esses modelos provêm um framework para o estudo de processos estacionários;

# Processos Lineares

- Série temporal  $X_t$  é um processo linear se tiver a representação:

$$X_t = \sum_{j=-\infty}^{\infty} \psi_j Z_{t-j}, \quad (1)$$

para todo  $t$  no qual  $Z_t \sim \text{WN}(0, \sigma^2)$  e  $\psi_j$  é uma sequência de constantes com  $\sum_{j=-\infty}^{\infty} \psi_j^2 < \infty$

# Processos Lineares

- Em termos do operador de deslocamento para trás  $B$ , Eq. 3 pode ser descrita em:

$$X_t = \psi(B)Z_t, \quad (2)$$

no qual  $\psi(B) = \sum_{j=-\infty}^{\infty} \psi_j B^j$ . Um processo linear

é chamado de média móvel (MA) se  $\psi_j = 0$  para todo  $j < 0$ . Exemplo se:

$$X_t = \sum_{j=0}^{\infty} \psi_j Z_{t-j}, \quad (3)$$

# Processos Lineares

- Observação: A condição  $\sum_{j=-\infty}^{\infty} \psi_j < \infty$  garante convergência, desde que:

$$E|Z_t| \leq \sigma, \quad (4)$$

$$E|X_t| \leq \sum_{j=-\infty}^{\infty} (|\psi_j| E|Z_{t-j}|) \leq \left( \sum_{j=-\infty}^{\infty} |\psi_j| \right) \sigma < \infty. \quad (5)$$

- $\psi(B)Z_t$  pode ser considerado como um filtro linear, no qual é produzido a saída  $X_t$  a partir do  $Z_t$ .

# Processos Lineares

- Um processo AR(1) é definido como uma solução estacionária de  $X_t$  de :

$$X_t - \phi_{t-1}X_{t-1} = Z_t, \quad (6)$$

no qual  $Z_t \sim \text{WN}(0, \sigma^2)$ ,  $|\phi_{t-1}| < 1$  não possui correlação com  $X_s$  para cara  $s < t$ .

- Um processo linear é dado por:

$$X_t = \sum_{j=-\infty}^{\infty} \psi_j Z_{t-j}, \quad (7)$$

# Processos Lineares

- Mostrando que  $X_t = \sum_{j=-\infty}^{\infty} \psi_j Z_{t-j}$  é a única solução estacionária de  $X_t - \phi X_{t-1} = Z_t$ , considerando  $Y_t$  uma solução de série estacionária qualquer.

$$\begin{aligned} Y_t &= \phi Y_{t-1} + Z_t \\ &= Z_t + \phi Z_{t-1} + \phi^2 Y_{t-2} \\ &= \dots \\ &= Z_t + \phi Z_{t-1} + \dots + \phi^k Z_{t-k} + \phi^{k+1} Y_{t-k-1} \end{aligned} \tag{8}$$

# Introdução ao processo ARMA

- A série temporal  $X_t$  é um processo ARMA se sua estacionariedade for satisfeita (para todo t):

$$X_t - \phi X_{t-1} = Z_t + \theta Z_{t-1}, \quad (9)$$

no qual  $Z_t \sim \text{WN}(0, \sigma^2)$ ,  $\phi + \theta \neq 0$ ;



# Propriedades da média da amostra e função de autocorrelação

- A estimação de  $\mu$ ,  $\gamma$  e  $p(\cdot) = \gamma(\cdot) / \gamma(0)$  a partir das observações de  $X_1 \dots X_T$  desempenha um papel importante nos problemas de inferência e no desenvolvimento de um modelo apropriado para os dados;

# Propriedades da média da amostra e função de autocorrelação

## ■ Estimação de $\mu$

- ▶ a estimação de da  $\mu$  média de um processo estacionário é dada pela média da amostra:

$$\hat{X}_n = n^{-1}(X_1, X_2, \dots, X_n), \quad (10)$$

Este é um estimador imparcial de  $\mu$ , desde que:

$$E(\hat{X}_n) = n^{-1}(EX_1, \dots, EX_n) = \mu \quad (11)$$

# Propriedades da média da amostra e função de autocorrelação

## ■ Estimação de $\mu$

- ▶ Para muitas séries temporais para modelos lineares e ARMA, (para largos "n"),  $\hat{X}_n$  é aproximadamente normal com média  $\mu$  e variância  $n^{-1} \sum_{|h|<\infty} \gamma(h)$
- ▶ então um intervalo de confiança de  $\mu$  é aproximadamente 95%:

$$(\hat{X}_n - 1,96\nu^{1/2}/\sqrt{n}, \hat{X}_n + 1,96\nu^{1/2}/\sqrt{n}) \quad (12)$$

# Propriedades da média da amostra e função de autocorrelação

## ■ Estimação de $\mu$

- ▶ Para muitas séries temporais para modelos lineares e ARMA, (para largos "n"),  $\hat{X}_n$  é aproximadamente normal com média  $\mu$  e variância  $n^{-1} \sum_{|h|<\infty} \gamma(h)$
- ▶ então um intervalo de confiança de  $\mu$  é aproximadamente 95%:

$$(\hat{X}_n - 1,96\nu^{1/2}/\sqrt{n}, \hat{X}_n + 1,96\nu^{1/2}/\sqrt{n}) \quad (13)$$

# Propriedades da média da amostra e função de autocorrelação

## ■ Estimação de $\gamma(\cdot)$ e $\rho(\cdot)$

- ▶ autocovariância:

$$\gamma(h) = n^{-1} \sum_{t=1}^{n-|h|} (X_{t+|h|} - \hat{X}_n)(X_t - \hat{X}_n) \quad (14)$$

- ▶ autocorrelação:

$$\hat{\rho}(h) = \frac{\gamma(h)}{\gamma(0)} \quad (15)$$

# Propriedades da média da amostra e função de autocorrelação

- Estimação de  $\gamma(\cdot)$  e  $p(\cdot)$ 
  - ▶ Sem informações adicionais retirada dos dados observados  $(X_1, \dots, X_n)$  é impossível obter estimativas razoáveis de  $\gamma(h)$  e  $p(h)$  para  $h \geq n$ ;
  - ▶ Até mesmo para casos em que  $h$  é um pouco maior que  $n$ , as estimações são inconfiáveis (desde haja apenas poucos dados disponíveis);

# Propriedades da média da amostra e função de autocorrelação

- Estimação de  $\gamma(\cdot)$  e  $p(\cdot)$ 
  - ▶ Então qual tamanho da amostra mínima que devemos utilizar?

# Forecasting time series

- Previsão de um passo à frente de uma série AR(1)

$$X_t = Z_t + \phi X_{t-1}, t = 0, \pm 1, \dots, \quad (16)$$

no qual  $|\phi| < 1$  e  $Z_t \sim \text{WN}(0, \sigma^2)$

- Chamaremos de  $P_n X_{n+h}$  o melhor preditor linear a partir de  $X_n, \dots, X_1$ , para  $n \geq 1$ ;
- solução é  $a_n = (\phi, 0, \dots, 0)'$
- Então:

$$P_n X_{n+1} = a_n' X_n = \phi X_n \quad (17)$$