

# **Estimação no Domínio do tempo: Covariâncias e modelos ARIMA**

Airlane Pereira Alencar

25 de março de 2025

# Índice

## 1 Metodologia Box-Jenkins (1970)

- ARMA(p,q)
- Modelos ARIMA(p,d,q)

## 2 Referências

## Ajuste de modelos ARIMA(p,d,q).

Análise descritiva: série veio de processo estacionário?

- Tirar tendência e sazonalidade determinística e "efeitos" de outras var.

$X_t = \mu_t + e_t$ , em que  $e_t$  é estacionário talvez ARMA

$$\mu_t = \text{tendencia}(t) + \text{sazon}(t) + \text{tend2}(t)$$

Exemplo: Produção industrial com mudança de tendência em 2008 e 2014 + AR(4)

Evitar regressão espúria.

- Se parece ter tendência estocástica: Diferenças

$$Z_t = \Delta X_t = X_t - X_{t-1} = (1 - B)X_t \text{ ou}$$

$$Z_t = \Delta^{12} X_t = (1 - B^{12}) = X_t - X_{t-12}$$

Se tira uma diferença e  $\Delta X_t$  parece estacionária, dizemos

$$X_t \sim I(1).$$

# Metodologia

- **Especificação:** Definir classe de modelos. ex:ARIMA(p,d,q)
- **Identificação:** Tirar tendências e com base na FAC e FACP propor (p,q)
- **Estimação** dos parâmetros
- **Verificação:** Análise de resíduos padronizados como RB, gaussiano
- Depois, inferência e **previsão**

# ARMA(p,q)

$$\begin{aligned}\tilde{Z}_t &= \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \\ (1 - \phi_1 B - \dots - \phi_p B) \tilde{Z}_t &= (1 - \theta_1 B - \dots - \theta_q B^q) a_t \\ \Phi(B) \tilde{Z}_t &= \Theta(B) a_t\end{aligned}$$

com  $a_t \sim RB$

- Estacionário: se as raízes de  $\Phi(B) = 0$  estiverem fora do círculo unitário
- Invertível: se as raízes de  $\Theta(B) = 0$  estiverem fora
- FAC e FACP parece cair para zero e deve propor valores (p,q) até ter resíduo como RB
- Deve propor valores (p,q) até ter resíduo como RB

# Modelos ARIMA(p,d,q)

$X_t$  não estac.  $\Rightarrow Z_t = \Delta^d X_t$  estacionário  $\Rightarrow Z_t \sim ARMA(p, q)$

$$\tilde{Z}_t = Z_t - \mu.$$

$$\begin{aligned}\tilde{Z}_t &= \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots \theta_q a_{t-q} \\ (1 - \phi_1 B - \dots) \tilde{Z}_t &= (1 - \theta_1 B - \dots \theta_q B^q) a_t \\ \Phi(B) \tilde{Z}_t &= \Theta(B) a_t,\end{aligned}$$

$$a_t \sim RB(0, \sigma^2).$$

- Estimação de ARIMA consiste na estimativa do ARMA(p,q)
- Máxima verossimilhança cond.:  $a_t \sim N(0, \sigma_a^2)$  indep.
- Generalizações: outras dist como a t, variância não constante, inclusão de covariáveis.

# Estimação ARIMA - Verossimilhança Condisional

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

$$E(\tilde{Z}_t | past) = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

$$Var(\tilde{Z}_t | past) = \sigma_a^2$$

$$\tilde{Z}_t | past \sim N(E(\tilde{Z}_t | past), \sigma_a^2)$$

Verossimilhança Condisional a valores iniciais de  $\tilde{Z}_t$ 's e  $a$ 's (MT).

$$\begin{aligned} L(\theta) &= f(\tilde{z}_1, \tilde{z}_2, \dots, \tilde{z}_T | \text{valores iniciais}) = \prod_{t=1}^T f_{\theta}(\tilde{z}_t | \tilde{z}_{t-1}, \dots) \\ &= \left[ \frac{1}{\sqrt{2\pi\sigma_a^2}} \right]^T \exp \left\{ - \sum_{t=1}^T \frac{[\tilde{z}_t - E(\tilde{z}_t | past)]^2}{2\sigma_a^2} \right\} \\ &= \left[ \frac{1}{\sqrt{2\pi\sigma_a^2}} \right]^T \exp \left\{ - \sum_{t=1}^T \frac{a_t^2}{2\sigma_a^2} \right\} \end{aligned}$$

# Estimação ARIMA

Log-Verossimilhança Condicional

$$I(\theta) = -\frac{T}{2} \ln(\sigma_a^2) - \frac{S(\eta|\tilde{z}_t, past)}{2\sigma_a^2}$$

$$S(\eta|\tilde{z}_t, past) = \sum_{t=1}^T a_t^2(\eta|\tilde{\mathbf{Z}}, past)$$

$\eta = (\phi, \theta)$  em MT (poderia incluir  $\mu$  ou intercepto e efeitos)

- Escolha dos p valores iniciais  $\tilde{Z}_0, \tilde{Z}_{-1}, \dots, \tilde{Z}_{-p+1}$  e q valores iniciais de  $a_t (= E(a_t) = 0)$
- Predizer  $a_t$  fixando  $\eta$  (ex. 7.1. MT(2018))

# Estimação ARIMA

- Escolha dos p valores iniciais  $\tilde{Z}_0, \tilde{Z}_{-1}, \dots, \tilde{Z}_{-p+1}$  e q valores iniciais de  $a_t (= E(a_t) = 0)$

ex:  $Y_t = c + \phi_1 Y_{t-1} - \theta_1 a_{t-1} + a_t, a_t \sim iidN(0, \sigma^2)$

Precisa fixar os valores iniciais  $y_0$  e  $a_0$ .

Prediz a sequência de erros usando os estimadores iniciais de  $\eta = (c, \phi, \theta)$ :

$$a_t = y_t - c - \phi y_{t-1} + \theta a_{t-1}$$

$$\ln L(\Theta) = -\frac{T}{2} \ln(2\pi) - \frac{T}{2} \ln(\sigma^2) - \sum_{t=1}^T \frac{(y_t - c - \phi y_{t-1} + \theta a_{t-1})^2}{2\sigma^2}$$

Atualiza os valores dos parâmetros, recalcula os erros,....

- Predizer  $a_t$  fixando parâmetro  $\eta$  (ex.7.1. MT(2018))

# Estimação ARIMA

- Escolha dos p valores iniciais  $\tilde{Z}_0, \tilde{Z}_{-1}, \dots, \tilde{Z}_{-p+1}$  e q valores iniciais de  $a_t (= E(a_t) = 0)$   
 ex:  $Y_t = c + \beta x_t + e_t$ ,  $e_t = \phi_1 e_{t-1} - \theta_1 a_{t-1} + a_t$ ,  $a_t \sim iidN(0, \sigma^2)$   
 Precisa fixar os valores iniciais  $y_0$  e  $a_0$ .  
 Prediz a sequência de erros usando os estimadores iniciais de  $\eta = (c, \beta, \phi, \theta)$ :  
 $e_t = y_t - c - \beta x_t$

$$\ln L(\Theta) = -\frac{T}{2} \ln(2\pi) - \frac{T}{2} \ln(\sigma^2) - \sum_{t=1}^T \frac{(y_t - c - \beta x_t - \phi y_{t-1} + \theta a_{t-1})^2}{2\sigma^2}$$

Atualiza os valores dos parâmetros, recalcula os erros,....

- Predizer  $a_t$  fixando  $\eta$  (ex.7.1. MT(2018))

# Estimação ARIMA

- **Não condicional**

- Agora, Esperança não condicional ao passado

$$[a_t(\eta | \tilde{\mathbf{Z}}, \text{past})] = E[(a_t | \eta, W)]$$

- Precisa de backforecasting, usando equivalência entre

$$\Phi(B)W_t = \Theta(B)a_t \quad \Phi(F)W_t = \Theta(F)e_t$$

- Verossimilhança exata: AR(1) em MT inclui parâmetro para média de  $Z_0, Z_{-1}$

# Variância dos estimadores

$\eta = (\phi, \theta)$  é  $k \times 1$ ,  $k = p + q$

Para n grande, estimador de MV

$$\hat{\eta} \stackrel{D}{\rightarrow} N_k(\eta, \mathbf{V}) \quad (1)$$

$$\mathbf{V} = 2\sigma_a^2 \begin{bmatrix} \frac{\partial^2 S(\eta)}{\partial \eta_1^2} & \cdots & \frac{\partial^2 S(\eta)}{\partial \eta_1 \partial \eta_k} \\ \vdots & & \vdots \\ \frac{\partial^2 S(\eta)}{\partial \eta_k \partial \eta_1} & \cdots & \frac{\partial^2 S(\eta)}{\partial \eta_k^2} \end{bmatrix}^{-1} \quad (2)$$

EMV de  $\sigma^2$  é  $\hat{\sigma}_a^2 = \frac{S(\hat{\eta})}{n}$

Para n grande  $\hat{\sigma}^2$  e  $\hat{\eta}$  são não correlacionados

Ex: AR(1):  $\text{var}(\hat{\phi}) \approx \frac{1-\phi^2}{n}$  e MA(1):  $\text{var}(\hat{\theta}) \approx \frac{1-\theta^2}{n}$

# Modelo espaço de estados

- Os modelos ARMA podem ser escritos como modelo espaço de estados.
- Filtro de Kalman para predizer as variáveis latentes
- Arima da library(forecast)
- Propor prioris e estimar maximizando a dist. a posteriori
- Estimar usando Arima da library(forecast) com exemplo Airlines.
- Podem tentar só ajustar escrevendo a verossimilhança em planilha e maximizar usando solver.

# Referências

## All Time series analysis

- Morettin e Toloi
- Shumway and Stoffer
- Wei
- Hyndman. Forecasting