

## CAPÍTULO 9

### MODELOS SAZONAIS

#### INTRODUÇÃO

Uma série temporal pode apresentar a componente de tendência e a componente sazonal, como vimos anteriormente.

No entanto, mesmo após estimar e eliminar a componente sazonal determinística pode restar correlação significativa em:

- i. “lags” de baixa ordem, indicando que resíduos ainda são correlacionados;
- ii. “lags” sazonais, ou seja, múltiplos de período  $s$ . Nesse caso, há necessidade de se considerar uma sazonalidade estocástica ajustando um modelo ARIMA sazonal (SARIMA).

Por simplicidade, assume-se que os dados são observados mensalmente e a sazonalidade é de período  $s=12$ .

#### SAZONALIDADE DETERMINÍSTICA

Considere que  $\{Z_t\}$  exibe um comportamento sazonal com período  $s=12$ .

Podemos ajustar:

$$Z_t = \mu_t + N_t$$

onde  $\mu_t$  é função determinística periódica, satisfazendo  $\mu_t - \mu_{t-12} = 0$ , ou

$$(1 - B^{12})\mu_t = 0$$

e  $N_t$  é um processo estacionário que pode ser modelado por um ARMA(p,q).

Dessa forma:

$$\phi(B)N_t = \theta(B)a_t \quad (10.1)$$

com  $a_t \sim RB$  e  $\mu_t$  tem solução dada por:

$$\mu_t = \mu + \sum_{j=1}^6 \left[ \alpha_j \cos \frac{(2\pi jt)}{12} + \beta_j \operatorname{sen} \frac{(2\pi jt)}{12} \right]$$

com  $\mu, \alpha_j, \beta_j$ , constantes desconhecidas;  $j = 1, 2, \dots, 6$

Para um modelo sazonal determinístico, aplicando a diferença sazonal

$(1 - B^{12})$  em  $Z_t = \mu_t + N_t$ , obtemos:

$$(1 - B^{12})Z_t = (1 - B^{12})\mu_t + (1 - B^{12})N_t \quad (10.2)$$

como  $\mu_t - \mu_{t-12} = 0$ , então:

$$(1 - B^{12})Z_t = (1 - B^{12})N_t$$

substituindo  $\phi(B)N_t = \theta(B)a_t \rightarrow N_t = \phi(B)^{-1} \cdot \theta(B)a_t$ , na equação ARMA

obtemos:

$$\begin{aligned} (1 - B^{12})Z_t &= (1 - B^{12})\phi(B)^{-1}\theta(B)a_t \\ \phi(B)(1 - B^{12})Z_t &= \theta(B)(1 - B^{12})a_t \\ \phi(B)W_t &= \theta(B)(1 - B^{12})a_t \end{aligned} \quad (10.3)$$

onde  $W_t = (1 - B^{12})Z_t$

## PROCESSO DE IDENTIFICAÇÃO

A identificação do modelo  $\phi(B)W_t = \theta(B)(1 - B^{12})a_t$  é realizada da seguinte forma:

- i. Obter as estimativas preliminares  $\tilde{\mu}, \tilde{\alpha}_j, \tilde{\beta}_j$  de  $\mu, \alpha_j, \beta_j$ ,  $j = 1, \dots, 6$ , por meio de uma análise de regressão de  $Z_t$  sobre 1,  $\text{sen} \frac{2\pi jt}{12}$  e  $\text{cos} \frac{2\pi jt}{12}$ ,  $j = 1, \dots, 6$ .
- ii. Calculamos os resíduos:

$$\tilde{N}_t = Z_t - \tilde{\mu}_t = Z_t - \tilde{\mu} - \sum_{j=1}^6 \left[ \tilde{\alpha}_j \cos \frac{(2\pi jt)}{12} + \tilde{\beta}_j \text{sen} \frac{(2\pi jt)}{12} \right]$$

e examinamos as funções de autocorrelação e autocorrelação parcial para identificar um modelo ARMA(p,q) para  $N_t$ .

## PREVISÃO

A previsão de valores futuros  $Z_{t+h}$ , dados  $Z_1, \dots, Z_t$  é obtido notando que:

$$\begin{aligned} \hat{Z}_t(h) &= E[Z_{t+h} | Z_t, Z_{t-1}, \dots] \\ &= E[\mu_{t+h} + N_{t+h} | Z_t, Z_{t-1}, \dots] \\ &= \mu_{t+h} + E[N_{t+h} | Z_t, Z_{t-1}, \dots] \end{aligned}$$

$$\text{Portanto, } \hat{Z}_t(h) = \mu_{t+h} + \hat{N}_t(h)$$

onde  $\mu_{t+h}$  e  $\hat{N}_t(h)$  são calculados utilizando os modelos  $Z_t = \mu_t + N_t$  e  $(1 - B^{12})\mu_t = 0$ . Nota-se que os parâmetros são não conhecidos por isso utilizamos  $\hat{\mu}_t$  no lugar de  $\mu_t$  e  $N_t$  por  $\hat{N}_t = Z_t - \hat{\mu}_t$ .

## SAZONALIDADE ESTOCÁSTICA

Do mesmo modo que podemos modelar uma série  $Z_t$ , observada mês a mês, por exemplo, por um modelo ARIMA:

$$Z_t = \phi Z_{t-1} + a_t$$

Poderíamos modelar uma associação ano a ano na série  $Z_t$  através de um modelo ARIMA sazonal.

$$Z_t = \Phi Z_{t-12} + a_t$$

Do mesmo modo, poderíamos considerar um modelo de médias móveis sazonais, como:

$$Z_t = a_t - \Theta a_{t-12}$$

A ideia é relacionar uma observação  $Z_t$ , correspondente a um determinado mês, janeiro, por exemplo, com observações correspondentes a janeiros anteriores, através de um modelo ARIMA sazonal da forma:

$$\Phi(B^{12})\Delta_{12}^D Z_t = \Theta(B^{12})a_t$$

onde:

$\Phi(B^{12}) = 1 - \Phi_1 B^{12} - \dots - \Phi_P B^{12P}$  que é o operador autorregressivo sazonal de ordem P, estacionário;

$\Theta(B^{12}) = 1 - \Theta_1 B^{12} - \dots - \Theta_Q B^{12Q}$  que é o operador de médias móveis sazonal de ordem Q, invertível;

$\Delta_{12} = (1 - B^{12})$  é o operador diferença sazonal;

$\Delta_{12}^D = (1 - B^{12})^D$ , indicando o número de diferenças sazonais;

Analogamente, poderíamos ter também um modelo que relacionasse os meses de dezembro:

$$\Phi(B^{12})\Delta_{12}^D Z_{t-1} = \Theta(B^{12})\alpha_{t-1}$$

E, assim por diante, onde os polinômios  $\Phi(\cdot)$  e  $\Theta(\cdot)$  seriam os mesmos definidos anteriormente

Porém, diferentemente do modelo ARIMA usual, os  $\alpha_t, \alpha_{t-1}, \dots$  não seriam RB. Por exemplo, a precipitação em janeiro 1980 tem de estar relacionada com janeiros anteriores, também está relacionada com dezembro, novembro, etc, de 1979, o que implica que  $\alpha_t, \alpha_{t-1}, \dots$  estejam relacionados.

Para modelar essas relações de dependência temos:

$$\phi(B)\Delta^d \alpha_t = \theta(B)\alpha_t$$

onde  $\alpha_t$  é RB.

Segue de 10.2 e 10.1 que:

$$\phi(B)\Phi(B^{12})\Delta^d \Delta_{12}^D Z_t = \theta(B)\Theta(B^{12})\alpha_t$$

Conhecido como ARIMA sazonal multiplicativo (SARIMA) de ordem  $(p, d, q)x(P, D, Q)_{12}$ .

O modelo  $\phi(B)N_t = \theta(B)\alpha_t$  implica que devemos tomar “d” diferenças simples e “D” diferenças sazonais da série  $Z_t$ , de modo que:

$$W_t = \Delta^d \Delta_{12}^D Z_t$$

seja estacionário.

Exemplo 10.2: Considere o modelo de médias móveis sazonal:

$$Z_t = a_t - \Theta_1 a_{t-12} - \dots - \Theta_Q a_{t-12Q}$$

Sua fac será não nula somente nos lags 12, 24, ..., 12Q.

As autocorrelações serão dadas por:

$$\rho_{12} = \frac{-\Theta_1 + \Theta_1\Theta_2 + \dots + \Theta_{Q-1}\Theta_Q}{1 + \Theta_1^2 + \dots + \Theta_Q^2}$$

.

.

.

$$\rho_{12Q} = \frac{-\Theta_Q}{1 + \Theta_1^2 + \dots + \Theta_Q^2}$$

Por exemplo, o modelo SMA(1)

$$Z_t = a_t - \Theta a_{t-12}$$

Terá autocorrelação não nula, somente no lag 12, ou seja,

$$\rho_{12} = \frac{-\Theta}{1 + \Theta^2}, \rho_j = 0, j \neq 0(\pm 12)$$

Exemplo 10.3: Seja o modelo autorregressivo sazonal puro SAR(P):

$$Z_t = \Phi_1 Z_{t-12} + \dots + \Phi_P Z_{t-12P} + a_t$$

No caso particular onde P = 1, temos:

$$Z_t = \Phi Z_{t-12} + a_t$$

com fac dada por:

$$\left\{ \begin{array}{l} \rho_{12} = \Phi \\ \rho_{24} = \Phi^2 \\ \rho_{12j} = \Phi^j, j = 0, 1, \dots \end{array} \right.$$

Ou seja, a fac será não nula nos lags múltiplos de 12.

Observe ainda que o modelo SAR(1) é estacionário se  $|\Phi| < 1$  e o efeito sazonal é transitório e vai se amortecendo. Do mesmo modo SMA(1) é invertível se  $|\Theta| < 1$ .

Exemplo 10.4: Um modelo bastante conhecido utilizado é o SARIMA(0,1,1) $\times$ (0,1,1)<sub>12</sub> que tem a forma:

$$(1 - B)(1 - B^{12})Z_t = (1 - \theta B)(1 - \Theta B^{12})a_t$$

$$W_t = (1 - \Theta B^{12} - \theta B + \theta \Theta B^{13})a_t$$

(ver Box, Jenkins, Reinsel, pg.333, exemplo 9.2)

A função de autocovariância será dada por:

$$\gamma(0) = \sigma^2(1 + \theta^2 + \Theta^2 + \theta^2\Theta^2)$$

$$\gamma(1) = \sigma^2(-\theta - \theta\Theta^2)$$

$$\gamma(2) = \gamma(3) = \dots = \gamma(10) = 0$$

$$\gamma(11) = \sigma^2(\theta\Theta)$$

$$\gamma(12) = \sigma^2(-\Theta - \theta^2\Theta)$$

$$\gamma(13) = \sigma^2(\theta\Theta)$$

$$\gamma(j) = 0, j > 13$$

Ou seja, a fac tem valores diferentes de zero nos lags 1,11,12,13 (com  $\rho_{11} = \rho_{13}$ )

## IDENTIFICAÇÃO; ESTIMAÇÃO E VERIFICAÇÃO

Procederemos da mesma forma que nos modelos ARIMA. A diferença é que teremos que diferenciar a série com respeito a  $\Delta$  e  $\Delta_{12}$  para produzir estacionariedade.

O próximo passo consiste em verificar as  $f_{ac}$  e  $f_{acp}$  para identificar um modelo preliminar e obter os valores de “p” e “q” nos lags 1,2,3,... e os valores de “P” e “Q” nos lags 12,24,36,...

Em seguida, estimar os parâmetros identificados utilizando EMV. Para o diagnóstico utilizaremos os testes de autocorrelação residual, parcial, Box-pierce, etc. E, Por último, procederemos na previsão para um modelo SARIMA multiplicativo.

Exemplos  $\rightarrow$  R