

## CAPÍTULO 6

### IDENTIFICAÇÃO DE MODELOS ARIMA

#### INTRODUÇÃO

Dado que especificamos a classe geral de modelo ARIMA, o próximo passo é a identificação do particular modelo a ser ajustado;

p + q ≤ 3	MA(1)	AR(1)	ARIMA(1,1)
	MA (2)	AR(2)	
		AR(3)	

A escolha baseia-se primariamente nas autocorrelações e autocorrelações parciais (*facv*) estimadas;

Lembrando que a *fac* é estimada por:  $r_j = \frac{c_j}{c_0}$ ,  $j = 0, 1, \dots, N - 1$ .

Onde  $c_j$  é a estimativa da *facv*  $\gamma_j$ :

$$c_j = \frac{1}{N} \sum_{t=1}^{N-j} [(Z_t - \bar{Z})(Z_{t+j} - \bar{Z})], \quad j = 0, 1, \dots, N - 1.$$

Onde  $\bar{Z} = \frac{\sum_{t=1}^{N-j} Z_t}{N}$  é a média amostral e  $r_{-j} = r_j$ .

A idéia geral é determinar um IC para  $r_j$ , para saber se  $r_j$  é nula além de um certo *lag*. Uma expressão aproximada para a variância de  $r_j$ , para um processo estacionário normal, é dado por:

$$\text{Var} (r_j) \simeq \frac{1}{N} \sum_{v=-\infty}^{\infty} (\rho_v^2 + \rho_{v+j} \cdot \rho_{v-j} - 4\rho_j \rho_v \rho_{v-j} + 2\rho_v^2 \rho_j^2)$$

Para um processo em que as autocorrelações são nulas para  $v > q$ , todos os termos do lado direito se anulam para  $j > q$ , exceto o primeiro termo  $r_v^2$ .

Temos, então que:

$$\text{Var} (r_j) \simeq \frac{1}{N} [1 + 2 \sum_{v=1}^q r_v^2], j > q.$$

Como desconhecemos  $\rho_v$  vamos substituir por  $r_v$ , obtendo a seguinte estimativa:

$$\hat{\sigma}^2 (r_j) \simeq \frac{1}{N} [1 + 2 \sum_{v=1}^q r_v^2], j > q.$$

Para  $N$  suficientemente grande e sob a hipótese que  $\rho_j = 0$ , para  $j > q$ , a distribuição de  $r_j$  é aproximadamente normal, com média igual a zero e variância  $\sigma^2 (r_j)$ ;

$$r_j \xrightarrow{\text{D(convergência ditrib.)}} N\left[0, \frac{1}{N} (1 + 2 \sum_{v=1}^q r_v^2)\right], j > q.$$

Dessa forma, podemos construir um intervalo de confiança aproximado para as autocorrelações;

$$r_j \pm t_\gamma \cdot \hat{\sigma} (r_j)$$

Onde  $t_\gamma$  é o valor da estatística  $t$  de Student com  $N-1$  graus de liberdade, t. q.

$P (-t_\gamma < t < t_\gamma) = \gamma$ . Na prática,  $t_\gamma = 2$ .

Podemos considerar  $\rho_j$  como sendo significativamente diferente de zero se:

$$|r_j| > 2 \cdot \hat{\sigma} (r_j), j > q.$$

Para a facp, sob a hipótese de que o processo é AR(p):

$$\text{Var}(\hat{\Phi}_{jj}) \simeq \frac{1}{N}, j > p.$$

De modo que:

$$\hat{\sigma}(\hat{\Phi}_{jj}) \simeq \frac{1}{\sqrt{N}}, j > p.$$

Além disso, para N grande e sob a hipótese de que o processo é AR(p),  $\hat{\Phi}_{jj}$  terá distribuição aproximadamente normal, com média zero e variância  $\text{Var}(\hat{\Phi}_{jj})$ ;

$$\hat{\Phi}_{jj} \xrightarrow{D} N(0, \frac{1}{N}), j > p.$$

Podemos considerar  $\hat{\Phi}_{jj}$  significativamente diferente de zero se:

$$|\hat{\Phi}_{jj}| > \frac{2}{\sqrt{N}}, j > p.$$

## PROCEDIMENTO DE IDENTIFICAÇÃO


O objetivo da identificação consiste em determinar os valores “p”, “d” e “q” do modelo ARIMA (p,d,q).

Vamos dividi-la em três passos:

1. Verificar se existe necessidade de uma transformação na série original, com o objetivo de estabilizar a sua variância. Para se ter uma idéia do tipo de transformação, pode-se utilizar a série de dados em K subconjuntos com k observações em cada subconjunto. Calcula-se a média  $\bar{Z}$  de cada subconjunto, tal que

$$\bar{Z}_k = \frac{1}{k} \sum_{i=1}^k Z_{ti}$$

- i. Calcula-se, também, a amplitude W ou o desvio padrão S de cada subconjunto, tal que:
- ii.  $W_k = \max (Z_{ti}) - \min (Z_{ti})$ , e
- iii.  $S_k = \sqrt{\frac{\sum_{i=1}^k (Z_{ti} - \bar{Z}_k)^2}{k-1}}$
- iv. A seguir, construímos um gráfico que traz no eixo das abscissas a variável  $\bar{Z}_k$  e no eixo das ordenadas,  $W_k$  ou  $S_k$ . O par  $(\bar{Z}_k, W_k)$  ou  $(\bar{Z}_k, S_k)$  será um ponto do gráfico. Podemos obter as seguintes variações gráficas:



As transformações logarítmicas e raiz quadrada são as mais comuns.

Nota: a série pode esconder variância não constante;

2. Após a checagem da variabilidade da série, tomar diferenças da série, tantas quantas necessárias, de modo a torná-la estacionária. Ou seja, até um processo  $\Delta^d Z_t$  se reduzir a um ARMA (p, q). O número de diferenças necessárias para tornar a série estacionária é alcançado quando a fac amostral de  $W_t = \Delta^d Z_t$  decresce rapidamente para zero.

$$r_j \longrightarrow 0, \quad j \rightarrow \infty \quad (d=1 \cong 90\% \text{ casos})$$

Pode-se testar a existência de raiz unitária no polinômio autorregressivo (teste de raiz unitária ou Dickey-Fuller).

3. Identificar o processo ARMA (p, q) resultante, através das fac e facp estimadas, cujos comportamentos devem ser semelhantes às quantidades teóricas.

Ordem	(1,d,0)	(0,d,1)
Comportamento de $\rho_k$	decai exponencialmente	somente $\rho_1 \neq 0$
Comportamento de $\phi_{kk}$	somente $\phi_{11} \neq 0$	decai exponenc.
Ordem	(2,d,0)	(0,d,2)
Comportamento de $\rho_k$	mistura de exponenciais ou ondas senóides amortecidas	somente $\rho_1 \neq 0$ e $\rho_2 \neq 0$
Comportamento de $\phi_{kk}$	somente $\phi_{11} \neq 0$ e $\phi_{22} \neq 0$	mistura de exponenciais ou ondas senóides amortecidas
(1,d,1)		
Comportamento de $\rho_k$	decai exponencialmente após lag 1	
Comportamento de $\phi_{kk}$	decai exponencialmente após lag 1	

Modelos ARMA  $\rightarrow$  fac e facp não são muito úteis. Sugestão: a) Ajustar modelos de baixa ordem e utilizar critérios que permitam escolher o modelo mais adequado. b) utilizar a função de autocorrelação estendida.

A justificativa de (2) é a seguinte:

Para um modelo ARMA estacionário, as fac's são dadas por:

$$\rho_j = A_1 G_1^j + A_2 G_2^j + \dots + A_p G_p^j, j > q - p.$$

Supondo raízes distintas. Como  $\Phi(B) = \prod_{i=1}^p (1 - G_i B)$  e as raízes de  $\Phi(B) = 0$  devem estar fora do círculo unitário, devemos ter  $|G_i| < 1$ .

Pela equação nota-se que se nenhuma raiz está muito próxima do círculo unitário, as autocorrelações  $\rho_j$  decrescerão para zero, conforme  $j$  aumenta;

Por outro lado, supondo que uma raiz real  $G_i$ , esteja próxima de um, ou seja:

$$G_1 = 1 - \varepsilon, \varepsilon > 0 \text{ (pequeno)}$$

Como  $j = (1 - \varepsilon)^j \simeq 1 - j\varepsilon$ , ver que para  $\varepsilon = 0,05$ :  $0,95^2 = 0,9025 \simeq 1 - j\varepsilon = 0,90$ ;  $0,95^3 = 0,8574 \simeq 1 - j\varepsilon = 0,85$ .

$\rho_j \simeq A_1(1 - j\varepsilon)$ , o que mostra que a  $\rho_j$  decairá lentamente para zero e de forma aproximadamente linear.

Deve-se evitar um excesso de diferenças (**superdiferenciação**).

Notas:

- i. Um número excessivo de diferenças resulta em um valor negativo de autocorrelação de ordem 1 da série diferenciada. Neste caso,  $\rho_1 = -0,5$ ;
- ii. Um número correto de diferenças diminui a variância da série transformada, por outro lado, excesso de diferenças aumentará a variância;
  - O movimento da variância pode ser utilizado para a escolha de  $d$ ;
- iii. Autocorrelações parciais tornam-se negativas;
  - Na prática  $d = 0, 1$  ou  $2$  e é suficiente verificar as primeiras 20 autocorrelações da série e de suas diferenças.

Convém testar se  $E(W_t) = \mu_W$  é zero, comparando  $\bar{W}$  com seu desvio padrão estimado. Lembrando que se  $d = 0$ ,  $\bar{W} = \bar{Z}$  (quadro 6.1);

Quadro 6.1. Variâncias aproximadas, para  $\bar{W}$ , onde  $W_t = \Delta^d Z_t$ ,  $n = N - d$ ;

AR(1)	MA(1)	ARMA(1,1)
$\frac{c_o(1+r_1)}{n(1-r_1)}$	$\frac{c_o(1+2r_1)}{n}$	$\frac{c_o}{n} \left[ 1 + \frac{2r_1^2}{r_1-r_2} \right]$

AR(2)	MA(2)
$\frac{c_o(1+r_1)(1-2r_1^2+r_2)}{n(1-r_1)(1-r_2)}$	$\frac{c_o(1+2r_1+2r_2)}{n}$

Exercício: Qual o modelo melhor se ajusta as informações abaixo, em que

$N = 50$ ;  $\bar{Z} = 0,5327$  e  $S^2 = 6,0579$ .

j	1	2	3	4	5	6	7	8
$r_j$	0,81	0,69	0,58	0,44	0,3	0,26	0,19	0,15
$\hat{\Phi}_{jj}$	0,81	0,11	-0,03	-0,12	-0,13	0,17	-0,01	0,02

---

Exemplos R

---



## FORMAS ALTERNATIVAS DE IDENTIFICAÇÃO

### MODELOS BASEADOS EM UMA FUNÇÃO PENALIZADORA

A idéia é escolher as ordens  $k$  e  $\ell$  que minimizem a quantidade:

$$P(k, \ell) = \ln \hat{\sigma}_{k,\ell}^2 + (k + \ell) \frac{C(N)}{N}$$

Em que  $\hat{\sigma}_{k,\ell}^2$  é uma estimativa de variância residual obtida ajustando um modelo ARMA  $(k, \ell)$  às  $N$  observações da série, e  $C(N)$  é uma função do tamanho da série;

$(k + \ell) \frac{C(N)}{N}$  é o termo penalizador e  $\uparrow$  n° parâmetro,  $\uparrow (k + \ell) \frac{C(N)}{N}$ ;  $\uparrow$  n° parâmetro,  $\downarrow \hat{\sigma}_{k,\ell}^2$  (variância residual);

Assim, minimizar  $P(k, \ell)$  corresponde a identificar as ordens  $k$  e  $\ell$  que equilibrem esse comportamento.

Algumas funções penalizadoras particulares:

- i. Critério de Informação de Akaike (AIC)

$$AIC(k, d, \ell) = N \ln \hat{\sigma}_a^2 + \frac{N}{N-d} 2(k + \ell + 1 + \delta_{do}) + N \ln 2\pi + N$$

$$\delta_{do} = \begin{cases} 1, & d = 0 \\ 0, & d \neq 0 \end{cases}$$

$\hat{\sigma}_a^2$  é o estimador de máxima verossimilhança de  $\sigma_a^2$ .

Com  $N$  fixo e com a série apropriadamente diferenciada, obtemos:

$$AIC(k, \ell) = N (\ln \hat{\sigma}_a^2) + 2 (k+\ell+2)$$

Para o caso de um  $AR(p)$ , o critério reduz-se a:

$$AIC(k) = N \ln \hat{\sigma}_k^2 + 2k, k \leq K$$

Onde  $K$  é o limite superior para  $k$ . Em geral,  $K = \ln N$ .

ii. Critério de Informação Bayesiano (BIC)

A idéia é minimizar a quantidade BIC:

$$BIC(k, \ell) = \ln \hat{\sigma}_{k,\ell}^2 + (k+\ell) \frac{\ln N}{N}$$

Onde  $\hat{\sigma}_{k,\ell}^2$  é a estimativa da variância residual do modelo  $ARMA(k, \ell)$

iii. Critério de HANNAN e QUINN (HQC)

Minimizar a quantidade HQC:

$$HQC(k, \ell) = \ln \hat{\sigma}_{k,\ell}^2 + 2(k+\ell)c \frac{\ln \ln N}{N}, c > 1.$$

Para o modelo  $AR(p)$ , o critério HQC reduz-se a

$$HQC(k) = \ln \hat{\sigma}_k^2 + 2ck \frac{\ln \ln N}{N}, c > 1.$$

## RESUMO

- fac e facp teóricas:

$$\begin{array}{ll}
 \text{AR}(p) & \begin{array}{l} \rho_k \rightarrow 0, \quad k \rightarrow \infty \\ \left\{ \begin{array}{ll} \Phi_{kk} \neq 0, & k \leq p \\ \Phi_{kk} = 0, & k > p \end{array} \right. \end{array} \quad \begin{array}{l} \text{"corte na facp"} \\ p = 1, 2 \text{ (nunca} \\ \text{maior)} \end{array} \\
 \text{MA}(q) & \begin{array}{l} \Phi_{kk} \rightarrow 0, \quad k \rightarrow \infty \\ \left\{ \begin{array}{ll} \rho_k \neq 0, & k \leq q \\ \rho_k = 0, & k > q \end{array} \right. \end{array} \quad \begin{array}{l} \text{"corte na fac"} \\ p = 1, 2 \text{ (nunca} \\ \text{menor)} \end{array} \\
 \text{ARIMA}(p,q) & 
 \end{array}$$

$$\rho_k \rightarrow 0, \quad k \rightarrow \infty \quad \text{a partir de lag } p$$

Decai exponencialmente a partir de lag  $q$

$$\Phi_{kk} \rightarrow 0, \quad k \rightarrow \infty$$

- fac e facp amostrais:
- Determinar as variâncias das fac e facp e construir IC;
- Lembrando que  $\hat{V}ar(r_j) \simeq \frac{1}{N} [1 + 2 \sum_{v=1}^q r_v^2], j > q$ .

### 1º Caso.

- Assim, devemos testar:

$$\begin{cases} H_0 : \text{O modelo é MA}(q) \\ H_1 : \text{O modelo não é MA}(q) \end{cases}$$

Sob  $H_0$ , então:

$$\hat{\sigma}^2(r_j) \simeq \frac{1}{N} [1 + 2 \sum_{v=1}^q r_v^2], j > q$$

Ou  $n = N - d$  (número de observações com a série diferenciada)

- Desconfiando-se que o processo é MA(2), verifica-se se há outras fac's amostrais  $r_j$ ,  $j > 2$ , fora do IC.
- Caso particular:  $MA(0) \Leftrightarrow Z_t = a_t$ . Neste caso,  $q = 0$  e  $\hat{\sigma}^2(r_j) = \frac{1}{N}$

## 2º Caso.

- Testar:
 
$$\begin{cases} H_0 : \text{O modelo é AR}(p) \\ H_1 : \text{O modelo não é AR}(p) \end{cases}$$

Lembrando que  $\hat{\sigma}^2(\Phi_{jj}) \simeq \frac{1}{N}$ ,  $j > p$  sob  $H_0$ .

- O IC fica  $\left[-1,96 \frac{1}{\sqrt{N}}, 1,96 \frac{1}{\sqrt{N}}\right]$