

Macroeconometria - Séries de tempo

FAUSTO JOSÉ ARAÚJO VIEIRA

Aula 2


17 de abril a 22 de maio de 2018

RESUMO - SÉRIES DE TEMPO (AULA ANTERIOR)


Estacionaridade x Tendência

Sem tendência

$$x_t = \mu + \beta x_{t-1} + u_t, \text{ onde } \beta < 1$$




$$x_t = x_{t-1} + u_t$$




Com tendência

$$x_t = \mu + \delta t + u_t$$



$$x_t = \mu + x_{t-1} + u_t$$



Alguns conceitos básicos

1. Autocovariância;
2. Estacionariedade;
3. Ruído branco;
4. Ergodicidade;
5. Processo de médias móveis;
6. Processo autoregressivo;
7. Invertibilidade.

Autocovariância e autocorrelação

- ▶ Autocovariância

- ▶ $\gamma_k = E(Y_t - \mu_t)(Y_{t-k} - \mu_{t-k}) = \text{cov}(Y_t, Y_{t-k})$

- ▶ Autocorrelação

- ▶ $\rho(k) = \frac{\gamma(k)}{\gamma(0)}$

- ▶ Matriz de covariância (dividido pelo desvio padrão - autocorrelação):

$$\Sigma_{XX} = \sigma^2 \begin{bmatrix} 1 & \rho(1) & \rho(2) & \dots & \rho(p-1) \\ \rho(1) & 1 & \rho(1) & \dots & \rho(p-2) \\ \rho(2) & \rho(1) & 1 & \dots & \\ \vdots & & & \dots & \rho(1) \\ \rho(p-1) & & & \rho(1) & 1 \end{bmatrix}$$

- ▶ Pressupõe estacionariedade

Estacionaridade

- ▶ Propriedades estatísticas são invariantes no tempo
- ▶ Média finita e constante
 - ▶ $E(Y_t) = \mu$ para todo t
- ▶ Variância finita
 - ▶ $E(Y_t)^2 < \infty$
- ▶ Autocovariância
 - ▶ $E(Y_t - \mu)(Y_{t-j} - \mu) = \gamma_j$ para todo t e j
- ▶ Ambos independem de t e são finitos - fracamente estacionário;
- ▶ Descrição de fracamente estacionário x estritamente estacionário
 - ▶ Estrictamente estacionário: as funções de distribuição da série com mesmo tamanho de intervalo temporal terão propriedades estatísticas similares.
 - ▶ Para todo j , A função $(Y_{t_1}, Y_{t_2}, \dots, Y_{t_n})$ é semelhante a função de $(Y_{t_1-j}, Y_{t_2-j}, \dots, Y_{t_n-j})$

Ruído branco

- ▶ Média zero, variância constante e finita, não há autocorrelação
- ▶ $E(\varepsilon_t) = 0$
- ▶ $E(\varepsilon_t^2) = \sigma^2$
- ▶ $E(\varepsilon_t \varepsilon_k) = 0$ para todo t diferente de k

Ergodicidade

- ▶ O processo aleatório manterá as propriedades estatísticas da população;
- ▶ Ou seja, como as séries temporais econômicas são únicas, espera-se que a média temporal das observações seja uma boa aproximação da média populacional.
 - ▶ $E(\bar{y}^a) = \text{p} \lim_{T \rightarrow \infty} \frac{1}{T} \sum_{i=0}^T y_t^a = E(y_t)$, onde “a” representa a amostra
- ▶ Em termos práticos, um processo é ergódico para a média desde que a autocovariância convirja suficientemente rápido para zero.
- ▶ Ruído branco é ergódico para todos os momentos.
- ▶ Ergodicidade não implica necessariamente em estacionariedade, nem o contrário.

Operador de defasagem e invertibilidade

- ▶ Seja z_t uma variável aleatória;
- ▶ $Lz_t = z_{t-1}$
- ▶ $L^j z_t = z_{t-j}$ para j pertencentes aos naturais

▶ Exemplo:

$$z_t + \alpha_1 z_{t-1} + \alpha_2 z_{t-2} + \alpha_3 z_{t-3} = (1 + \alpha_1 L + \alpha_2 L^2 + \alpha_3 L^3) z_t$$

▶ Se $|\alpha| < 1$, então:

▶ $(1 + \alpha L)^{-1} = 1 + \alpha L + \alpha^2 L^2 + \alpha^3 L^3 \dots$

▶ Exemplo:

$$z_t + \alpha z_{t-1} = e_t$$

$$(1 + \alpha L) z_t = e_t$$

$$z_t = \frac{e_t}{(1 + \alpha L)} = e_t (1 + \alpha L + \alpha^2 L^2 + \alpha^3 L^3 \dots) = e_t + \alpha e_{t-1} + \alpha^2 e_{t-2} + \alpha^3 e_{t-3} \dots$$

Estimar um modelo ARMA

- ▶ Para estimar uma série temporal, é necessário que o processo seja:
 - ▶ Estocástico;
 - ▶ Estacionário;
 - ▶ Ergótico.

RESUMO DA AULA



Resumo

1. Processo de Médias Móveis;
2. Processo Autoregressivo;
3. Invertibilidade;
4. Função de Autocorrelação (FAC) e Autocorrelação Parcial (FACP);
5. Estimação dos modelos;
6. Critério de informação;
7. Projeção.

PROCESSO AUTORREGRESSIVO E MÉDIAS MÓVEIS

Médias Móveis - MA(1)

- ▶ Considere o seguinte processo estocástico:

$$y_t = \mu + \varepsilon_t + \theta\varepsilon_{t-1} \quad \text{onde } \varepsilon_t \text{ é um ruído branco } \sim N(0, \sigma^2);$$

- ▶ Média móvel mais geral do que normalmente escutamos:

- ▶ Exemplo: média móvel de 3 meses da produção industrial.
- ▶ Pesos não são necessariamente idênticos.

- ▶ Processo é estacionário?

- ▶ Média:

- ▶ $E(y_t) = \mu + E(\varepsilon_t) + \theta E(\varepsilon_{t-1}) = \mu$

Médias Móveis - MA(1)

► Função

$$y_t = \mu + \varepsilon_t + \theta\varepsilon_{t-1}$$

► Variância

$$\begin{aligned} \text{Var}(y_t) &= (y_t - \mu)^2 \\ &= (\varepsilon_t + \theta\varepsilon_{t-1})^2 \\ &= (\varepsilon_t^2 + 2\theta\varepsilon_t\varepsilon_{t-1} + \theta^2\varepsilon_{t-1}^2) \\ &= \sigma^2 + 0 + \theta^2\sigma^2 \end{aligned}$$

$$= \sigma^2(1 + \theta^2)$$

► Covariância

$$\begin{aligned} &= E[(y_t - \mu)(y_{t-1} - \mu)] \\ &= E[(\varepsilon_t + \theta\varepsilon_{t-1})(\varepsilon_{t-1} + \theta\varepsilon_{t-2})] \\ &= E[(\varepsilon_t\varepsilon_{t-1} + \theta\varepsilon_{t-1}^2 + \theta\varepsilon_t\varepsilon_{t-2})] \\ &= \theta\sigma^2 \end{aligned}$$

Médias Móveis - MA(1)

$$y_t = \mu + \varepsilon_t + \theta\varepsilon_{t-1}$$

▶ Processo é estacionário?

Sim, média constante, variância finita e covariância independe de t

▶ Processo é ergótico?

Sim, a autocovariância converge rapidamente para zero

▶ **IMPORTANTE!!!**

▶ Autocovariância

$$\begin{aligned} \rho_1 &= \gamma_1 / \gamma_0 \\ &= \frac{\theta\sigma^2}{\sigma^2(1 + \theta^2)} = \frac{\theta}{(1 + \theta^2)} \end{aligned}$$


▶ $\rho_j=0$ para todo $j>1$

Médias Móveis - MA(1)


- ▶ Criar um script no R
- ▶ Digitar as seguintes linhas:
 - ▶ `y<- e <- rnorm(100,0,1)`
 - ▶ `y[0]=0`
 - ▶ `y[1]=0`
 - ▶ `for (t in 2:100) y[t] <- e[t]+0.1*e[t-1]`
 - ▶ `plot(y,type= "l")`
- ▶ Colocar a primeira linha como comentário “#” para usar diferentes coeficientes, mas com a mesma amostra aleatória.
- ▶ Salvar os valores: `y_ma1_0_3=y`
`y_ma1_0_9=y`

Médias Móveis - MA(1)


$$y_t = \mu + \varepsilon_t$$




$$y_t = \mu + \varepsilon_t + 0.3\varepsilon_{t-1}$$



$$y_t = \mu + \varepsilon_t + 0.6\varepsilon_{t-1}$$



$$y_t = \mu + \varepsilon_t + 0.9\varepsilon_{t-1}$$



Médias Móveis - MA(1)

- ▶ Séries ficaram mais persistentes com a elevação do coeficiente do MA(1)
- ▶ Variância também aumenta:
 - ▶ A escala dos gráficos aumenta com o coeficiente do MA(1)
 - ▶ $= \sigma^2(1 + \theta^2)$
- ▶ Autocorrelação aumenta com o valor maior de θ

Médias Móveis - MA(q)

- ▶ Definição do modelo geral

$$y_t = \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q}, \text{ onde } \theta_1, \theta_2, \dots, \theta_q \ (\theta_q \neq 0)$$

- ▶ Usando o operador de defasagem

$$y_t = \theta(B)\epsilon_t, \text{ onde } \theta(B) = 1 + \theta_1 B + \theta_2 B^2 + \dots + \theta_q B^q$$

- ▶ Momentos do MA(q)

- ▶ Média:

$$\begin{aligned} E[y_t] &= E[\epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q}] \\ &= E[\epsilon_t] + \theta_1 E[\epsilon_{t-1}] + \theta_2 E[\epsilon_{t-2}] + \dots + \theta_q E[\epsilon_{t-q}] = 0 \end{aligned}$$

Médias Móveis - MA(q)

► Momentos do MA(q)

► Variância:

$$\begin{aligned} \text{Var}[y_t] &= \text{Var}[\epsilon_t + \theta_1\epsilon_{t-1} + \theta_2\epsilon_{t-2} + \dots + \theta_q\epsilon_{t-q}] \\ &= \text{Var}[\epsilon_t] + \theta_1^2 \text{Var}[\epsilon_{t-1}] + \theta_2^2 \text{Var}[\epsilon_{t-2}] + \dots + \theta_q^2 \text{Var}[\epsilon_{t-q}] \\ &= (1 + \theta_1^2 + \theta_2^2 + \dots + \theta_q^2)\sigma^2 \quad \text{- Covariância é nula (Ruído Branco)} \end{aligned}$$

► Covariância:

$$\gamma_j = E\left(\sum_{i=0}^q \theta_i \epsilon_{t-i} \sum_{i=0}^q \theta_i \epsilon_{t-i-j}\right) = E(\theta_j \epsilon_{t-j}^2 + \theta_{j+1} \theta_1 \epsilon_{t-j-1}^2 + \dots + \theta_q \theta_{q-j} \epsilon_{t-q}^2)$$

$$\gamma_j = E(\theta_j + \theta_{j+1} \theta_1 + \theta_{j+2} \theta_2 + \dots + \theta_q \theta_{q-j})\sigma^2 \quad \text{para } j=1,2,\dots,q$$

$$\gamma_j = 0 \quad \text{para } j > q$$

Médias Móveis - MA(q)

$$y_t = \theta_0 + \epsilon_t - \theta_1\epsilon_{t-1} - \theta_2\epsilon_{t-2} - \theta_3\epsilon_{t-3} - \dots - \theta_q\epsilon_{t-q}$$


► MA(q) é estacionário?

- (Hamilton, 1994): As raízes de $\theta(L) = 0$ tem que estar fora do círculo unitário.

$$\theta(L) = 1 - \theta_1L - \theta_2L^2 - \theta_3L^3 - \dots - \theta_qL^q$$

- (Enders, 2009): As raízes de $\theta(L) = 0$ tem que estar dentro do círculo unitário.

$$\theta(L) = \lambda^2 - \theta_1\lambda - \theta_2\lambda^2 - \theta_3\lambda^3 - \dots - \theta_q\lambda^q$$



Exemplos de MA(2)

- ▶ MA(2)

$$\gamma_0 = (1 + \theta_1^2 + \theta_2^2)\sigma^2$$

$$\gamma_1 = (\theta_1 + \theta_1\theta_2)\sigma^2$$

$$\gamma_2 = (\theta_2)\sigma^2$$


$$\gamma_j = 0, \text{ para } j > 2$$

- ▶ Autocorrelação é dividir por γ_0

- ▶ **Importante!!!**

- ▶ A defasagem do MA é determinada pelo autocorrelação

$$\rho_j = \begin{cases} 1, & j = 0 \\ \frac{\theta_1 + \theta_1\theta_2}{1 + \theta_1^2 + \theta_2^2}, & j = 1 \\ \frac{\theta_2}{1 + \theta_1^2 + \theta_2^2}, & j = 2 \\ 0, & j > 2. \end{cases}$$



Autorregressivo - AR(1)

- ▶ Considere o seguinte processo estocástico:

$$y_t = c + \varphi y_{t-1} + \varepsilon_t \quad \text{onde } \varepsilon_t \text{ é um ruído branco } \sim N(0, \sigma^2) \text{ e } |\varphi| < 1;$$

- ▶ Usando o operador de defasagem e a invertibilidade:

$$y_t = c + \varphi y_{t-1} + \varepsilon_t \rightarrow (1 - \varphi L) y_t = c + \varepsilon_t$$

$$y_t = \frac{c}{1 - \varphi} + \sum_{j=0}^{\infty} \varphi^j \varepsilon_{t-j} = \mu + \vartheta(L) \varepsilon_t, \text{ desde que } |\varphi| < 1$$

- ▶ Prova (sem constante):

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

$$y_{t-1} = \phi y_{t-2} + u_{t-1}$$

$$y_t = \phi(\phi y_{t-2} + u_{t-1}) + u_t$$



$$y_t = \phi^2 y_{t-2} + \phi u_{t-1} + u_t$$

$$y_t = \phi^m y_{t-m} + \sum_{j=0}^{m-1} \phi^j u_{t-j}, \quad |\phi| < 1$$

$$y_t = \sum_{j=0}^{\infty} \phi^j u_{t-j}$$

Autorregressivo - AR(1)

$$y_t = c + \phi y_{t-1} + \varepsilon_t$$

► É estacionário?

► Média:

$$E(y_t) = \mu + \sum_{j=0}^{\infty} \phi^j E(\varepsilon_{t-j}) = \mu$$

► Variância:

$$\text{Var}(y_t) = E(y_t - \mu)^2 = E\left(\sum_{j=0}^{\infty} \phi^j \varepsilon_{t-j}\right)^2 = \sum_{j=0}^{\infty} \phi^{2j} E(\varepsilon_{t-j}^2) = \frac{\sigma^2}{1 - \phi^2}$$

Autorregressivo AR(1)


► Covariância:

$$\begin{aligned} E[(y_t - \mu)(y_{t-j} - \mu)] &= E\left[\left(\sum_{s=0}^{\infty} \phi^s \varepsilon_{t-s}\right) \left(\sum_{s=0}^{\infty} \phi^s \varepsilon_{t-s-j}\right)\right] = \\ &= \sigma^2 (\phi^j + \phi^{j+2} + \phi^{j+4} + \dots) = \left(\frac{\phi^j}{1 - \phi^2}\right) \sigma^2 \end{aligned}$$

► Autocorrelação:

$$\rho_j = \frac{\left(\frac{\phi^j}{1 - \phi^2}\right) \sigma^2}{\frac{\sigma^2}{1 - \phi^2}} = \phi^j, \quad j = 1, 2, \dots$$

Autocorrelação - AR(1)




Autorregressivo AR(1)


- ▶ Criar um script no R
- ▶ Digitar as seguintes linhas:
 - ▶ `y<- e <- rnorm(100,0,1)`
 - ▶ `y[0]=0`
 - ▶ `y[1]=0`
 - ▶ `for (t in 2:100) y[t] <- e[t]+0.1*y[t-1]`
 - ▶ `plot(y,type= "l")`
- ▶ Colocar a primeira linha como comentário “#” para usar diferentes coeficientes, mas com a mesma amostra aleatória.
- ▶ Salvar os valores: `y_ar1_0_4=y`
`y_ar1_0_8=y`

Autoregressivo AR(1)


$$y_t = \mu + \varepsilon_t$$




$$y_t = \mu + \varepsilon_t - 0.8y_{t-1}$$



$$y_t = \mu + \varepsilon_t + 0.4y_{t-1}$$




$$y_t = \mu + \varepsilon_t + 0.8y_{t-1}$$



Autorregressivo AR(1)

- ▶ Outra forma de criar um AR(1)
 - ▶ `x1<-arima.sim(model=list(ar=0.9),n=100)`
 - ▶ `plot(x1)`



Autorregressivo AR(1)

- ▶ Séries ficaram mais persistentes com a elevação do coeficiente do AR(1)
 - ▶ Coeficiente negativo têm maior influência das mudanças.
 - ▶ Dos dois gráfico à direita, tem-se a impressão de maior volatilidade do gráfico superior, no entanto, a volatilidade das séries é a mesma.
- ▶ Variância também aumenta:
 - ▶ A escala dos gráficos aumenta com o coeficiente do AR(1) - valor absoluto
- ▶ Autocorrelação aumenta com o valor maior de φ
 - ▶ O decaimento é lento quando o valor $|\varphi|$ é próximo de 1
 - ▶ Todo AR tem um decaimento infinito, pois é pode ser representado por um MA(∞)

Momentos do AR(2)

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t$$

► Média

$$E(y_t) = c + \phi_1 E(y_{t-1}) + \phi_2 E(y_{t-2}) + E(\varepsilon_t) \implies$$

$$E(y_t) \equiv \mu = \frac{c}{1 - \phi_1 - \phi_2}.$$

► Autocovariância:

Reescrevendo a equação (variável passando pela origem):

$$y_t - \mu = \phi_1 (y_{t-1} - \mu) + \phi_2 (y_{t-2} - \mu) + \varepsilon_t$$

Multiplicando ambos os lados por $(y_{t-j} - \mu)$ e tomando a esperança:

$$E(y_t - \mu)(y_{t-j} - \mu) = \phi_1 E(y_{t-1} - \mu)(y_{t-j} - \mu) + \phi_2 E(y_{t-2} - \mu)(y_{t-j} - \mu) + E[\varepsilon_t (y_{t-j} - \mu)].$$


Então:

$$\gamma_j = \phi_1 \gamma_{j-1} + \phi_2 \gamma_{j-2}, \quad j = 1, 2, \dots$$

Dividindo por γ_0

$$\rho_j = \phi_1 \rho_{j-1} + \phi_2 \rho_{j-2}, \quad j = 1, 2, \dots$$

Exemplo de AR(2) - Autocorrelação




Autorregressivo AR(2)


- ▶ Criar um script no R
- ▶ Digitar as seguintes linhas:
 - ▶ `y<- e <- rnorm(100,0,1)`
 - ▶ `y[0]=0`
 - ▶ `y[1]=0`
 - ▶ `for (t in 3:100) y[t] <- e[t]+0.7*y[t-1] +0.2*y[t-2]`
 - ▶ `plot(y,type= "l")`
- ▶ Colocar a primeira linha como comentário “#” para usar diferentes coeficientes, mas com a mesma amostra aleatória.
- ▶ Salvar os valores: `y_ar2_0_7_0_2=y`

Autorregressivo AR(2)

$$y_t = \varepsilon_t + 0.7y_{t-1} + 0.2y_{t-2}$$



$$y_t = \varepsilon_t + 0.3y_{t-1} - 0.1y_{t-2}$$



Autorregressivo - AR(p)

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \cdots + \phi_p y_{t-p} + \varepsilon_t = c + \sum_{j=1}^p \phi_j y_{t-j} + \varepsilon_t$$

- ▶ Raízes polinomiais:

$(1 - \phi_1 L - \phi_2 L^2 - \cdots - \phi_p L^p)$, estacionário se as raízes estiverem fora do círculo unitário

- ▶ Média




$$y_t = \mu + \psi(L) \varepsilon_t, \quad \mu = \frac{c}{1 - (\phi_1 + \phi_2 + \cdots + \phi_p)}$$

- ▶ Autocorrelação:

$$\rho_j = \phi_1 \rho_{j-1} + \phi_2 \rho_{j-2} + \cdots + \phi_p \rho_{j-p}, \quad j = 1, 2, \dots, p$$

Autocorrelação - Não se esqueça!

- MA - ela interrompe na última defasagem do MA;
- AR - declinante com as defasagens;
- Maior o coeficiente, mais lento o declínio da autocorrelação;
- Variância aumento com o coeficiente.



Processo ARMA(p,q)

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=0}^q \theta_j \varepsilon_{t-j}$$

- ▶ Invertibilidade e definição

$$y_t = \mu + \sum_{i=1}^p \phi_i (y_{t-i} - \mu) + \sum_{j=0}^q \theta_j \varepsilon_{t-j} = \mu + \psi(L) \varepsilon_t, \text{ onde } \psi(L) = \frac{1 + \sum_{j=1}^q \theta_j L^j}{1 - \sum_{i=1}^p \phi_i L^i}$$

- ▶ Média incondicional:

$$E(y_t) \equiv \mu = c + \sum_{i=1}^p \phi_i E(y_{t-i}) = \frac{c}{1 - \sum_{i=1}^p \phi_i}$$

- ▶ Autocovariância:

$$\gamma_h = \phi_1 \gamma_{h-1} + \phi_2 \gamma_{h-2} + \dots + \phi_p \gamma_{h-p}, \quad h = q+1, q+2, \dots$$

Covariância é declinante, como o AR(P)

ARMA(1,1) - Autocovariância

- ▶ Autocovariância declinante:

$$\begin{aligned}\gamma_0 &= \frac{1 + \theta_1^2 + 2\phi_1\theta_1}{1 - \phi_1^2} \sigma^2; \\ \gamma_1 &= \frac{(1 + \phi_1\theta_1)(\phi_1 + \theta_1)}{1 - \phi_1^2} \sigma^2; \\ \gamma_2 &= \phi_1\gamma_1; \\ &\vdots \\ \gamma_h &= \phi_1^{h-1}\gamma_1.\end{aligned}$$

ARIMA(p,d,q)

- ▶ A grande diferença entre o ARIMA e o ARMA é se a variável analisada é estacionária ou integrada de grau 1 ou superior.
 - ▶ Veremos essa discussão na aula 4, quando falarmos sobre séries não estacionárias;
- ▶ Se uma variável aleatória X_t segue um modelo ARIMA(p,d,q), então $\Delta^d X_t$ segue um modelo ARMA(p,q);
- ▶ O “I” está relacionado com a quantidade de vezes necessárias para tornar a variável estacionária.

Função de Autocorrelação - FAC

- ▶ É o gráfico de autocorrelação em relação a defasagem
- ▶ Permite identificar a ordem q de um processo MA
 - ▶ Lembre-se, a FAC do AR tem decaimento exponencial em relação às defasagens.
- ▶ Em grandes amostras, a variância das estimativas de um RB pode ser aproximada por ser dado por T^{-1}

Modelo	FAC
MA (q)	$\rho_j = \frac{\theta_j + \theta_{j+1}\theta_1 + \theta_{j+2}\theta_2 + \dots + \theta_q\theta_{q-j}}{\sum_{j=0}^q \theta_j^2}, j = 1, 2, \dots, q$
AR (1)	$\rho_j = \phi^j, j = 1, 2, \dots$
AR (p)	$\rho_j = \phi_1\rho_{j-1} + \phi_2\rho_{j-2} + \dots + \phi_p\rho_{j-p}, j = 1, 2, \dots$
ARMA (1, 1)	$\begin{cases} \rho_1 = \frac{(1+\phi_1\theta_1)(\phi_1+\theta_1)}{1+\theta_1^2+2\phi_1\theta_1} \\ \rho_j = \phi_1\rho_{j-1} = \phi_1^{j-1}\rho_1, j > 1. \end{cases}$

Estimando a FAC

- ▶ Obtenha a média amostral da série:

$$\bar{y} = \frac{\sum_{t=1}^T y_t}{T}$$

- ▶ Calcule a autocorrelação amostral:

$$\hat{\rho}_j : \hat{\rho}_j = \frac{\frac{\sum_{t=j+1}^T (y_t - \bar{y})(y_{t-j} - \bar{y})}{T}}{\frac{\sum_{t=1}^T (y_t - \bar{y})^2}{T}}, \quad j = 1, 2, \dots$$


- ▶ Trace o gráfico de $\hat{\rho}_j$ contra j .

FAC dos modelos simulados


- ▶ Instalando o “Linear and Nonlinear Mixed Effects Model”
 - ▶ `install.packages("nlme")`
- ▶ Deixando-o ativo:
 - ▶ `require(nlme)`
- ▶ Estimando as FAC
 - ▶ `acf(y_ar1_0_8)`
 - ▶ `acf(y_ma1_0_3)`
 - ▶ `acf(y_ma1_0_9)`
 - ▶ `acf(y_ar2_0_7_0_2)`

Resultado do FAC - modelos simulados


Series y_ma1_0_3




Series y_ma1_0_9



Series y_ar1_0_8



Series y_ar2_0_7_0_2



Função de Autocorrelação Parcial - FACP

- ▶ A FACP elimina as correlações implícitas entre a variável e suas defasagens, tornando possível estimar o coeficiente da defasagem.
- ▶ Como se faz? Elimina-se as correlações implícitas entre duas variáveis.
- ▶ Equação: $y_t = \phi_{j,1}y_{t-1} + \phi_{j,2}y_{t-2} + \dots + \phi_{j,j}y_{t-j} + e_t, \quad j = 1, 2, \dots,$
- ▶ Procedimento consiste em regredir y_t contra y_{t-1} e obter $\hat{\Phi}_{1,1}$, depois estima-se y_t contra y_{t-1} e y_{t-2} , obtendo $\hat{\Phi}_{2,1}$ e $\hat{\Phi}_{2,2}$. A FACP apresenta $\hat{\Phi}_{1,1}$ e $\hat{\Phi}_{2,2}$, descartando $\hat{\Phi}_{2,1}$.

	y_{t-1}	y_{t-2}	y_{t-3}	...	y_{t-p}
1	$\hat{\Phi}_{1,1}$	0	0	...	0
2	$\hat{\Phi}_{2,1}$	$\hat{\Phi}_{2,2}$	0	...	0
3	$\hat{\Phi}_{3,1}$	$\hat{\Phi}_{3,2}$	$\hat{\Phi}_{3,3}$...	0
...					
p	$\hat{\Phi}_{p,1}$	$\hat{\Phi}_{p,2}$	$\hat{\Phi}_{p,3}$...	$\hat{\Phi}_{p,p}$

- ▶ A FACP é formada pela diagonal principal!!!

Função de Autocorrelação Parcial - FACP


- ▶ A FACP determina a defasagem “p” do AR(p);
- ▶ Ou seja, espera-se que os coeficientes $\hat{\Phi}_{j,j}$ para $j \leq p$ são diferentes de zero, já para os coeficientes $j > p$, são nulos.
- ▶ Devido a condição de invertibilidade, o MA(q) pode se tornar um processo AR infinito. Assim, o coeficiente $\hat{\Phi}_{j,j}$ terá um decaimento exponencial.
- ▶ Qual é o total de parâmetros j para ser estimado?
 - ▶ Enders (2009) sugere calcular a FACP até $j=T/4$, em que T é o tamanho da amostra.

FAC dos modelos simulados


- ▶ Estimando as FACP
 - ▶ `pacf(y_ar1_0_8)`
 - ▶ `pacf(y_ma1_0_3)`
 - ▶ `pacf(y_ma1_0_9)`
 - ▶ `pacf(y_ar2_0_7_0_2)`

Resultado do FACP - modelos simulados


Series y_ma1_0_3




Series y_ma1_0_9



Series y_ar1_0_8



Series y_ar2_0_7_0_2



Função de Autocorrelação Parcial - FACP

- ▶ A FAC define a defasagem do MA(q). A FACP define defasagem do AR(p).
- ▶ No primeiro caso, a FAC decai com o aumento de defasagens, e a função de autocorrelação parcial é truncada a partir da defasagem p .
- ▶ No segundo caso, a função de autocorrelação é truncada na defasagem q , e a função de autocorrelação parcial decai.
- ▶ No caso de uma ARMA (p, q), ambas as funções decaem a partir da defasagem de truncagem.

Modelo	FAC	FACP
AR (p)	Decai	Truncada na defasagem p
MA (q)	Truncada na defasagem q	Decai
ARMA (p, q)	Decai se $j > q$	Decai se $j > p$

Teste de Ljung-Box

- ▶ Hipóteses:

$$H_0 : \rho_1 = \rho_2 = \dots = \rho_n = 0 \quad \text{para } n = 1, 2, \dots, J$$

$$H_1 : \exists \rho_j \neq 0 \text{ para algum } j = 1, 2, \dots, n$$

- ▶ Estatística:

$$Q = T(T+2) \sum_{j=1}^n \frac{\hat{\rho}_j^2}{T-j} \xrightarrow{d} \chi_n^2$$

- ▶ Se uma das autocorrelações for diferente de zero, há evidência de um modelo ARMA(p,q).
- ▶ Se após estimado o modelo, os resíduos não sugerirem alguma autocorrelação, o modelo estará bem estimado.
 - ▶ Resíduo é um Ruído Branco.
- ▶ Na prática: Identifica-se o modelo por meio da FAC e FACP; depois usa-se a estatística de Ljung-Box sobre os resíduos estimados.

Teste de Ljung-Box

- ▶ Instalando o pacote
 - ▶ `install.packages("stats")`
- ▶ `require(stats)`
- ▶ Escrevendo o texto:
 - ▶ Para defasagem 1:

```
Box.test(y,lag=1,type = "Ljung-Box")
```

```
Box-Ljung test
data: y
X-squared = 51.574, df = 1, p-value = 6.893e-13
```

- ▶ Para a defasagem 5:

```
Box.test(y,lag=5,type = "Ljung-Box")
```

```
Box-Ljung test
data: y
X-squared = 109.03, df = 5, p-value < 2.2e-16
```

FAC e FACP - solução única?

- ▶ As defasagens obtidas da FAC e FACP muitas vezes não são claras;
 - ▶ Difícil de identificar visualmente.
- ▶ É possível estimar mais de um modelo “correto”:
 - ▶ Resíduo do modelo é um ruído branco
- ▶ Como diferenciar?
 - ▶ Usar critérios de informação

Estimação e inferência

- ▶ A estimação se inicia com o método de máxima verossimilhança condicional.
- ▶ É um método que é assintoticamente equivalente ao da máxima verossimilhança exata.

Estimação e inferência - Exemplo AR(2)


- ▶ Baixando o pacote para estimação
 - ▶ `install.packages("FitARMA")`
 - ▶ `require(FitARMA)`
- ▶ Estimando a equação
 - ▶ `regarma1<-FitARMA(y_ar2_0_7_0_2,order = c(2,0,0),MeanMLEQ = TRUE)`
- ▶ Observando os coeficientes estimados:
 - ▶ `coef(regarma1)`

```
      -  
      MLE      sd      z-ratio  
phi(1) 0.5995806 0.0979807 6.11937488  
phi(2) 0.1999457 0.0979807 2.04066413  
mu     -1.3029027 54.9187532 -0.02372419
```

Estimação e inferência - Exemplo AR(2)

▶ erro1<-resid(regarma1)

▶ acf(erro1)




▶ Box.test(erro1,lag=3,type = "Ljung-Box")

Box-Ljung test

```
data: erro1  
X-squared = 1.6921, df = 3, p-value = 0.6387
```

pacf(erro1)



Box.test(erro1,lag=3,type = "Ljung-Box")

Box-Ljung test

```
data: erro1  
X-squared = 13.366, df = 10, p-value = 0.2039
```

Estimação e inferência - Exemplo ARMA(1,1)

- ▶ Estimando a equação

- ▶ `regarma2<-FitARMA(y_ar2_0_7_0_2,order = c(1,0,1),MeanMLEQ = TRUE)`

- ▶ Observando os coeficientes estimados:


- ▶ `coef(regarma2)`

	MLE	sd	Z-ratio
<code>phi(1)</code>	0.8930677	0.05734697	15.573058334
<code>theta(1)</code>	0.3624920	0.11879076	3.051517002
<code>mu</code>	-1.2894904	673.32939719	-0.001915096

Estimação e inferência - Exemplo ARMA(1,1)

▶ erro2<-resid(regarma2)

▶ acf(erro2)




▶ Box.test(erro2,lag=3,type = "Ljung-Box")

Box-Ljung test

```
data: erro2
X-squared = 1.7251, df = 3, p-value = 0.6314
```

pacf(erro2)



Box.test(erro2,lag=10,type = "Ljung-Box")

Box-Ljung test

```
data: erro2
X-squared = 12.653, df = 10, p-value = 0.2437
```

Estimação e inferência - Ljung-Box

- ▶ Ljung-box - outra forma de obter o resultado
- ▶ `regarma1$LjungBoxQ`

AR(2)

m	Qm	pvalue
1	0.04	0.83545072
2	1.12	0.29050079
3	1.69	0.19332334
4	2.67	0.26343070
5	3.29	0.34856619
6	3.86	0.42518886
7	3.87	0.56841120
8	12.57	0.05043674
9	12.98	0.07249434
10	13.37	0.09986736
11	15.93	0.06843426
12	16.11	0.09654949
13	16.67	0.11797004
14	17.06	0.14747951
15	18.62	0.13526711

`regarma2$LjungBoxQ`

ARMA(1,1)

m	Qm	pvalue
1	0.09	0.76608823
2	0.55	0.45900059
3	1.73	0.18903746
4	2.16	0.33875038
5	2.53	0.46950107
6	3.32	0.50580931
7	3.39	0.64077305
8	12.06	0.06069784
9	12.41	0.08779662
10	12.65	0.12436572
11	15.71	0.07320355
12	15.99	0.10003036
13	16.30	0.13038049
14	16.65	0.16317891
15	17.90	0.16130392

Estimação e inferência

- ▶ Exemplo interessante, aponta que há significância na FAC e FACP na oitava defasagem, mas é espúria!
- ▶ Olhar o sentido econômico. Faz sentido? Há sazonalidade no 8º mês ou trimestre?
 - ▶ Normalmente olhamos se há significância nas primeiras autocorrelações e para períodos semestrais ou anuais.
- ▶ Em modelos simulados, é possível ter divergência de diagnóstico, imagine em variáveis reais (amostra aleatória);
- ▶ Como decidir?
- ▶ Critério de informação...

Critério de informação

- ▶ Método alternativo de identificar um $ARMA(p,q)$.
 - ▶ Além disso, é comum dois ou mais modelos possíveis gerando resíduos cujos testes indiquem ser um ruído branco.
 - ▶ O melhor modelo será o mais parcimonioso. Por quê? O modelo com menor número de parâmetros deverá gerar menos imprecisão de estimativas.
- ▶ Ideia: balancear a redução dos erros e o aumento do número de regressores.
 - ▶ Normalmente, o aumento de regressores reduz a soma dos quadrados dos resíduos.
- ▶ O critério de informação associa uma penalidade ao aumento do número de regressores. Se a penalidade for menor do que a diminuição da soma de resíduos, o regressor adicional deve ser incorporado ao modelo.

Critério de informação

- ▶ A especificação geral:

$$C = \ln \hat{\sigma}^2 (T) + c_T \varphi (T)$$

- ▶ $\hat{\sigma}^2 (T) = T^{-1} \sum_{t=1}^T \hat{\varepsilon}_t^2$ é a variância estimada dos resíduos;
- ▶ c_T é o número de parâmetros estimados, $\varphi (T)$ é a função de penalização;
- ▶ O número total de observações T é invariante.
 - ▶ É necessário comparar séries com o mesmo número de observações.
- ▶ **OBJETIVO:** minimizar a função C

Critério de informação

- ▶ $n=p+q$ ou $n=p+q+1$ se houver constante. T é o total de observações.

- ▶ Estatística de Schwarz ou BIC- Bayesian Information Criterion;

$$BIC(p, q) = \ln \hat{\sigma}^2 + n \frac{\ln T}{T}$$

- ▶ Estatística de Akaike ou AIC - Akaike Information Criterion;

$$AIC(p, q) = \ln \hat{\sigma}^2 + n \frac{2}{T}$$

- ▶ Estatística de Hanna-Quinn, HQ;

$$HQ(p, q) = \ln \hat{\sigma}^2 + n \frac{2}{T} \ln \ln T$$

- ▶ BIC é consistente assintoticamente e o AIC para pequenas amostras;

- ▶ De forma geral, $T > 16$

$$\hat{P}_{BIC} \leq \hat{P}_{HQ} \leq \hat{P}_{AIC}$$

Critério de informação

- ▶ `summary(regarma1)`

```
ARIMA(2,0,0) with mean MLE.  
length of series = 100 , number of parameters = 3  
loglikelihood = 11.18 , aic = -16.4 , bic = -8.5
```

- ▶ `regarma2 <enter>`

```
ARIMA(1,0,1) with mean MLE.  
length of series = 100 , number of parameters = 3  
loglikelihood = 11.95 , aic = -17.9 , bic = -10.1
```

Revisão: processo de uma série ARMA(p,q)

1. Identificar as ordens p e q do modelo.
2. Estimá-lo.
3. Verificar se os resíduos estimados são um ruído branco.
 - ▶ Sim, próximo passo;
 - ▶ Não, volte ao passo 1.
4. Projetar!
 - ▶ Se uma série for considerada não estacionária, deve ser diferenciada.

Testes dos resíduos

- ▶ Erro de especificação
 - ▶ Teste Reset
- ▶ Teste para heterocedasticidade
 - ▶ LM ou Breusch-Pagan-Godfrey
- ▶ Autocorrelação dos resíduos
 - ▶ Teste Breusch-Godfrey
- ▶ Teste de normalidade
 - ▶ Jarque-Bera - verifica se os momentos da série estimada são semelhantes aos da normal (assimetria e curtose):
$$H_0 : E(\varepsilon_t^3) = 0 \wedge E(\varepsilon_t^4) = 3$$

×

$$H_1 : E(\varepsilon_t^3) \neq 0 \vee E(\varepsilon_t^4) \neq 3$$
 - ▶ Teorema do Limite Central - Quando o tamanho amostral é suficientemente grande, a distribuição da média é uma distribuição aproximadamente normal.

Testes dos resíduos - normalidade

- ▶ Instalando o pacote
 - ▶ `install.packages("tseries");`
 - ▶ `require(tseries);`
- ▶ Resultado do teste de normalidade
 - ▶ `jarque.bera.test(erro2)`


```
Jarque Bera Test  
data: x1  
X-squared = 0.82314, df = 2, p-value = 0.6626
```

Exemplo real - IBC-br


- ▶ Baixando os dados.
- ▶ `setwd("C:/diretorio/diretorio")`
- ▶ `list.files()`
- ▶ `X<-read.csv("aula2_dados.csv",sep=";", dec=".", head=TRUE)`
- ▶ `X$date<-as.Date(X$date,'%d/%b/%y')`
- ▶ `head(X)`

Exemplo real - IBC-br

acf(X\$ibcbr)



pacf(X\$ibcbr)



► Que modelo sugere?

Exemplo real - IBC-br

- ▶ Possíveis modelos:
 - ▶ ARMA(2,2)
 - ▶ AR(2)
 - ▶ MA(2)

Exemplo real - IBC-br - ARMA(2,2)

- ▶ Estimando o modelo

- ▶ `ibcbr_arma22<-FitARMA(X$ibcbr,order = c(2,0,2),MeanMLEQ = TRUE)a`

- ▶ `coef(ibcbr_arma22)`

	MLE	sd	Z-ratio
phi(1)	0.02791488	0.40722151	0.06854961
phi(2)	0.02681891	0.33437672	0.08020567
theta(1)	-0.17575284	0.40166412	-0.43756171
theta(2)	-0.20180264	0.28398058	-0.71062126
mu	0.19182657	0.07083413	2.70810931

Exemplo real - IBC-br - AR(2)

▶ Estimando o modelo


▶ `ibcbr_ar2<-FitARMA(X$ibcbr,order = c(2,0,0),MeanMLEQ = TRUE)`

▶ `coef(ibcbr_ar2)`


```
                MLE          sd   Z-ratio
phi(1) 0.1916543 0.07358821 2.6044153
phi(2) 0.1751424 0.07358821 2.3800335
mu      0.1926979 0.35278910 0.5462127
```

▶ `erro_ar2<-resid(ibcbr_ar2)`

`acf(erro_ar2)`



`pacf(erro_ar2)`



`ibcbr_ar2$LjungBoxQ`

m	Qm	pvalue
1	0.01	0.9305878
2	0.04	0.8363149
3	0.48	0.4872894
4	0.65	0.7236980
5	1.22	0.7484525
6	1.49	0.8283449
7	1.61	0.8999974
8	1.69	0.9461123
9	1.71	0.9739582
10	1.71	0.9885560
11	2.95	0.9664136
12	5.95	0.8191315
13	5.95	0.8764191
14	8.21	0.7682411
15	8.80	0.7875653

Exemplo real - IBC-br - MA(2)

▶ Estimando o modelo


▶ `ibcbr_ma2<-FitARMA(X$ibcbr,order = c(0,0,2),MeanMLEQ = TRUE)`

▶ `coef(ibcbr_ma2)`


	MLE	sd	Z-ratio
theta(1)	-0.2026664	0.07270271	-2.787605
theta(2)	-0.2320831	0.07270271	-3.192221
mu	0.1915622	0.05655121	3.387411

▶ `erro_ma2<-resid(ibcbr_ma2)`

`acf(erro_ma2)`



`pacf(erro_ma2)`



`ibcbr_ma2$LjungBoxQ`

m	Qm	pvalue
1	0.00	0.9683351
2	0.00	0.9647442
3	0.14	0.7086904
4	0.17	0.9173560
5	0.81	0.8462653
6	1.10	0.8935265
7	1.25	0.9396079
8	1.51	0.9587208
9	1.52	0.9817585
10	1.52	0.9922921
11	2.56	0.9793594
12	5.35	0.8667979
13	5.35	0.9128684
14	7.06	0.8536997
15	7.38	0.8817300

Exemplo real - IBC-br - AR(2)

- ▶ Critério de informação

- ▶ AR(2)

```
> ibcbr_ar2  
ARIMA(2,0,0) with mean MLE.  
length of series = 179 , number of parameters = 3  
loglikelihood = 49.26 , aic = -92.5 , bic = -83
```

- ▶ MA(2)

```
> ibcbr_ma2  
ARMA(0,2) with mean MLE.  
length of series = 179 , number of parameters = 3  
loglikelihood = 49.64 , aic = -93.3 , bic = -83.7
```

Introdução a previsão

- ▶ Horizonte de previsão que se deseja prever, h : período de tempo entre hoje, t , e h -passos à frente, $t + h$.
- ▶ Distinção: **previsões h -passos à frente** e **extrapolação h -passos à frente**.
 - ▶ Previsões de um ponto de futuro com dados até t : $t + h$, $t + 1 + h$.
 - ▶ Extrapolação: previsões consecutivas em $t + 1$, $t + 2$, . . . , $t + h$.
- ▶ Previsão dinâmica: não usa a informação adicional para realimentar as previsões. Isto é, para prever y_{T+2} , usa-se $E_t (y_{T+1})$.
- ▶ Previsão estática: usa na previsão de y_{T+h} a observação y_{T+h-1} . Também chamada de previsão 1-passo à frente.
- ▶ A previsão estática tende a ter um erro de previsão menor do que a a previsão dinâmica, haja vista que as informações são atualizadas a cada passo.
- ▶ A previsão dinâmica representa uma extrapolação H -passos a frente.

Previsão dinâmica: valor médio - AR(1)

$$y_{t+1} = c + \phi y_t + \varepsilon_{t+1}.$$

Logo:

$$E_t(y_{t+1}) = c + \phi y_t = y_{t+1} - \varepsilon_{t+1};$$

$$E_t(y_{t+2}) = c + \phi E_t(y_{t+1}) = c + \phi(c + \phi y_t);$$

\vdots

$$E_t(y_{t+h}) = c \sum_{i=1}^h \phi^{i-1} + \phi^h y_t.$$

Previsão dinâmica: Erro de previsão - AR(1)

O erro de previsão no período h , $e_t(h)$, é dado por:

$$e_t(1) = y_{t+1} - E_t(y_{t+1}) = \varepsilon_{t+1};$$

$$\begin{aligned} e_t(2) &= y_{t+2} - E_t(y_{t+2}) = c + \phi y_{t+1} + \varepsilon_{t+2} - c - \phi E_t(y_{t+1}) = \\ &= \phi \varepsilon_{t+1} + \varepsilon_{t+2}; \end{aligned}$$

$$\begin{aligned} e_t(3) &= y_{t+3} - E_t(y_{t+3}) = c + \phi y_{t+2} + \varepsilon_{t+3} - c - \phi E_t(y_{t+2}) = \\ &= \varepsilon_{t+3} + \phi \varepsilon_{t+2} + \phi^2 \varepsilon_{t+1}; \end{aligned}$$

⋮

$$\begin{aligned} e_t(h) &= y_{t+h} - E_t(y_{t+h}) = \\ &= \varepsilon_{t+h} + \phi \varepsilon_{t+h-1} + \phi^2 \varepsilon_{t+h-2} + \cdots + \phi^{h-1} \varepsilon_{t+1}. \end{aligned}$$

Tomando as esperanças dos erros de previsão, verifica-se que são iguais a zero.

Previsão dinâmica: Variância - AR(1)

$$\begin{aligned} \text{Var}(e_t(h)) &= \text{Var}(\varepsilon_{t+h} + \phi\varepsilon_{t+h-2} + \phi^2\varepsilon_{t+h-3} + \dots + \phi^{h-1}\varepsilon_{t+1}) = \\ &= \sigma^2(1 + \phi^2 + \phi^4 + \dots + \phi^{2(h-1)}). \end{aligned}$$

- ▶ A variância aumenta com o horizonte de previsão a taxas decrescentes. Quando $h \rightarrow \infty$, a variância de previsão converge à variância não condicional

$$\frac{\sigma^2}{1-\phi^2}$$

- ▶ O intervalo de confiança para resíduos normais é dado da seguinte forma:

$$c \sum_{i=1}^h \phi^{i-1} + \phi^h y_t \pm 2\sigma \left(1 + \phi^2 + \phi^4 + \dots + \phi^{2(h-1)}\right)^{\frac{1}{2}}$$

Previsão do modelo teórico

- ▶ Vamos selecionar as últimas 10 observações para projeção.
- ▶ Treinaremos o modelo com as 90 primeiras observações.
- ▶ Coeficientes estimados serão diferentes - número de observação é diferente.
- ▶ Projeção dinâmica!
- ▶ Regarma1 - ARMA(2,0)
 - ▶ `previsao1<-predict(arima(y_ar2_0_7_0_2[1:90], order = c(2,0,0)), n.ahead = 10)`
- ▶ Calculando o intervalo de projeção - baseado no desvio padrão.
 - ▶ Superior: `previsao1$pred+previsao1$se*1.96`
 - ▶ Inferior: `previsao1$pred-previsao1$se*1.96`


Previsão do modelo teórico - Gráfico

```
plot(y_ar2_0_7_0_2,type="l")
```

```
points(previsao1$pred,col="red")
```

```
points(previsao1$pred+previsao1$se*1.96,type="l",col="red")
```

```
points(previsao1$pred-previsao1$se*1.96,type="l",col="red")
```



Previsão do modelo teórico

- ▶ Regarma2 - ARMA(1,1)


- ▶ `previsao2<-predict(arima(y_ar2_0_7_0_2[1:90], order = c(1,0,1)), n.ahead = 10)`

- ▶ Gráfico:

```
plot(y_ar2_0_7_0_2,type="l")
```

```
points(previsao1$pred,type="l",col="red")
```

```
points(previsao2$pred,type="l",col="blue")
```



Avaliação da Previsão

- ▶ Divide-se a amostra:
 1. Estimação do modelo
 2. Treinamento das projeções
 3. Comparação das projeções com o restante da amostra - *pseudo out-of-sample*.
- ▶ Se a amostra for suficientemente grande, pode-se deixar de 1/4 a 1/3 fora da amostra por razões de previsão.
- ▶ Métodos:

$$MSE_{t,H} = \sqrt{\frac{\sum_{h=1}^H e_t^2(h)}{H}};$$

$$MAE_{t,H} = \frac{\sum_{h=1}^H |e_t(h)|}{H};$$

$$MAPE_{t,H} = \sum_{h=1}^H \left| \frac{e_t(h)}{Hy_{t+h}} \right|.$$

Função de Autocorrelação Parcial - FACP

► MSE

```
MSE1<- (mean((y_ar2_0_7_0_2[91:100] - previsao1$pred )^2))^0.5)
```

```
MSE2<- (mean((y_ar2_0_7_0_2[91:100] - previsao2$pred )^2))^0.5)
```

► MAE

```
MAE1<-mean(abs(y_ar2_0_7_0_2[91:100] - previsao1$pred ))
```

```
MAE2<-mean(abs(y_ar2_0_7_0_2[91:100] - previsao2$pred ))
```

Voltando ao exercício do IBC-br

► Projetando o modelo do AR(2)


```
previbcbr_ar2<-predict(arima(X$ibcbr[1:164], order = c(2,0,0)), n.ahead = 15)
```

```
plot(X$ibcbr,type="l")
```

```
points(previbcbr_ar2 $pred,col="red")
```

```
points(previbcbr_ar2$pred+ previbcbr_ar2$se*1.96,type="l",col="red")
```

```
points(previbcbr_ar2$pred- previbcbr_ar2$se*1.96,type="l",col="red")
```



Voltando ao exercício do IBC-br


- ▶ Projetando o modelo do MA(2)

```
previbcbr_ma2<-predict(arima(X$ibcbr[1:164], order = c(0,0,2)), n.ahead = 15)
```

- ▶ `plot(X$ibcbr,type="l")` #gráfico

```
points(previbcbr_ar2$pred,col="red")
```

```
points(previbcbr_ma2$pred,col="blue")
```



Voltando ao exercício do IBC-br

▶ MSE

```
MSE1ibcbr<- (mean((X$ibcbr[165:179] - previbcbr_ar2$pred )^2))^0.5
```

```
MSE2ibcbr<- (mean((X$ibcbr[165:179] - previbcbr_ma2$pred )^2))^0.5
```

▶ Conclusão:

- ▶ Os modelos AR(2) e MA(2) tiveram um bom ajuste no IBC-br
- ▶ Segundo o AIC e BIC, o modelo MA(2) minimizou os critérios
- ▶ No entanto, para a projeção, o modelo AR(2) teve o menor erro quadrático médio.

Exercício em aula

```
> head(x)
  data      varejo varejo_ampl      ibcbr      ipca
1 01/fev/03  2.364066  -3.611738  1.4439355  1.4918278
2 01/mar/03 -9.006928   0.234192  0.3533916  1.2039650
3 01/abr/03  4.060914   2.102804 -1.0760051  0.9450566
4 01/mai/03 -1.707317   4.347826 -1.4337981  0.9637544
5 01/jun/03 -3.722084  -5.701754  0.7223114  0.2512400
6 01/jul/03  6.958763   7.441860 -1.3844622  0.2701869
```

- ▶ Escolher alguma dessas variáveis e estimar pelo menos 2 modelos ARMA;
 - ▶ Baseando-se na FAC e FACP
- ▶ Apresentar o teste Ljung-Box e funções de autocorrelação do resíduo.
- ▶ Exibir o melhor modelo baseado no critério de informação.
- ▶ Projetar os dois modelos e mostrar qual tem o menor erro quadrático médio.