

Macroeconometria - Séries de tempo

FAUSTO JOSÉ ARAÚJO VIEIRA

Aula 5

17 de abril a 22 de maio de 2018

RESUMO - RAIZ UNITÁRIA (AULA ANTERIOR)

Motivação

- ▶ A série temporal não estacionária não pode ser estimada trivialmente.
- ▶ Problema: é impossível estimar todos os momentos da série e fazer inferências estatísticas.

A variância não condicional de um $AR(1)$ é:

$$\text{var}(y_t) = \frac{1}{1 - \phi^2}.$$

Se $\phi = 1$, o que caracteriza uma série não estacionária de raiz unitária, então a variância explode.

- ▶ Solução: diferenciar a série tantas vezes quantas sejam necessárias para estacionarizá-la.

Modelos não estacionários

- ▶ Tendência determinística

$$y_t = y_0 + \delta t + \psi(L) \varepsilon_t$$

- ▶ Tendência estocástica

$$y_t = y_0 + \delta t + \sum_{i=1}^t \varepsilon_i$$

- ▶ Passeio aleatório


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

- ▶ Média e variância dependem do tempo - explosivas
- ▶ Precisa fazer alterações na séries, mas depende da classificação do processo gerador dos dados.


Tendência estocástica e determinística

- Exercício feito na aula 2
- u_t é um ruído branco


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



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



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



Regressão Espúria

- ▶ A necessidade de teoria econômica para definir variável explicada e explicativa torna-se muito importante na presença de raiz unitária.
- ▶ Podem-se encontrar relações estatísticas entre duas ou mais variáveis econômicas sem qualquer relação de causalidade entre uma e outra por puro acaso.
- ▶ Por exemplo, a regressão de uma variável $I(1)$ com outra $I(1)$ obtida independentemente gera alto R^2 e significativo t -estatístico. Contudo, o resultado é sem significado econômico.

Teste para raiz unitária

- ▶ Dickey-Fuller

$$\Delta y_t = (\phi - 1) y_{t-1} + \varepsilon_t = \alpha y_{t-1} + \varepsilon_t$$

$$H_0 : \phi = 1$$

- ▶ Phillips-Perron

Faz uma correção na estimação na estatística do teste - diminui a média da série

- ▶ KPSS

$$y_t = x_t + u_t,$$

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

$$H_0 : \sigma_v^2 = 0 \times H_1 : \sigma_v^2 > 0$$

$$H_0 : y_t \sim I(0) \text{ contra } H_1 : y_t \sim I(1)$$

Quebra Estrutural

- ▶ Na presença de quebra estrutural, os testes são viesados na direção da não rejeição da hipótese de raiz unitária.
- ▶ Devem-se consultar os valores tabelados para teste com quebra estrutural por Perron, em que se assume uma **única** e **conhecida** quebra estrutural usando toda a amostra disponível.
- ▶ Considerando um passeio aleatório com *drift*, há três tipos de quebras estruturais possíveis. Uma mudança de nível da série, uma mudança de inclinação e ambas as mudanças.

Resumo

- ▶ A série é estacionária, possui tendência estacionária ou tendência estocástica?
- ▶ Teste para raiz unitária:
 1. Teste Dickey-Fuller
 2. Teste Phillip-Perron
 3. Teste KPSS - Hipótese nula é estacionariedade!
- ▶ Se aceitou a hipótese de raiz unitária - observar se há quebra estrutural
- ▶ Como estimar a série (estacionária)
 1. Tendência estocástica: i) diferenciação; ii) filtro HP; iii) filtro de Kalman e outros
 2. Tendência estacionária: i) regressão linear (c/ tendência) e ii) filtro HP

RESUMO DA AULA



SUMÁRIO DESTA AULA

- ▶ Forma estrutural
- ▶ Forma reduzida
- ▶ VAR(p)
- ▶ Identificação
- ▶ Modelo de inflação do BCB - VAR
- ▶ Estacionariedade

Vetor Autorregressivo (VAR)



Introdução

- ▶ O uso de modelos univariados é limitado para expressar modelos econômicos.
- ▶ O vetor autorregressivo permite que se expressem modelos econômicos completos e se estimem os parâmetros desse modelo.
- ▶ Os modelos em VAR definem restrições entre as equações do modelo. Estudar essas restrições e usá-las para identificar os parâmetros estruturais do VAR constitui um objetivo fundamental da metodologia.

Forma estrutural

- Pode-se expressar um modelo auto-regressivo de ordem p por um vetor com n variáveis endógenas, X_t , conectadas entre si por meio de uma matriz A :

$$AX_t = B_0 + \sum_{i=1}^p B_i X_{t-i} + B\varepsilon_t, \quad (1)$$

em que

A é uma matriz $n \times n$ que define as restrições contemporâneas entre as variáveis que constituem o vetor $n \times 1$, X_t ;

B_0 é um vetor de constantes $n \times 1$;

B_i são matrizes $n \times n$;

B é uma matriz diagonal $n \times n$ de desvios padrão;

ε_t é um vetor $n \times 1$ de perturbações aleatórias não correlacionadas entre si contemporânea ou temporalmente, isto é:

$$\varepsilon_t \sim i.i.d. (\mathbf{0}; I_n).$$

Forma reduzida

- ▶ A equação (1) expressa as relações entre as variáveis endógenas, a partir de um modelo econômico teoricamente estruturado: **forma estrutural**.
- ▶ Os choques ε_t são os choques estruturais porque afetam individualmente cada uma das variáveis endógenas.
- ▶ Os choques estruturais são considerados independentes entre si.
- ▶ Esse modelo é normalmente estimado em sua **forma reduzida**:

$$\begin{aligned} X_t &= A^{-1}B_0 + \sum_{i=1}^p A^{-1}B_i X_{t-i} + A^{-1}B\varepsilon_t = \\ &= \Phi_0 + \sum_{i=1}^p \Phi_i X_{t-i} + e_t, \end{aligned}$$

em que

$$\Phi_i \equiv A^{-1}B_i, \quad i = 0, 1, \dots, p$$

$$B\varepsilon_t \equiv Ae_t.$$

Forma estrutural - exemplo

- ▶ Seja um modelo bivariado de ordem 1:

$$y_t = b_{10} - a_{12}z_t + b_{11}y_{t-1} + b_{12}z_{t-1} + \sigma_y \varepsilon_{yt};$$

$$z_t = b_{20} - a_{21}y_t + b_{21}y_{t-1} + b_{22}z_{t-1} + \sigma_z \varepsilon_{zt}.$$

- ▶ Não pode ser estimado diretamente, já que as variáveis contemporâneas z_t e y_t são individualmente correlacionadas com os erros ε_{yt} ou ε_{zt} .
- ▶ O objetivo do VAR é desenvolver técnicas para evitar esse problema, visando-se a encontrar a trajetória da variável de interesse ante um choque estrutural.
- ▶ Hipóteses:

y_t e z_t são ambos estacionários;

$\varepsilon_{yt} \sim RB(0, 1)$ e $\varepsilon_{zt} \sim RB(0, 1)$;

$\varepsilon_{yt} \perp \varepsilon_{zt} \implies \text{Cov}(\varepsilon_{yt}, \varepsilon_{zt}) = 0.$

Forma estrutural - exemplo

Em matrizes:

$$\underbrace{\begin{bmatrix} 1 & a_{12} \\ a_{21} & 1 \end{bmatrix}}_{\equiv A} \underbrace{\begin{bmatrix} y_t \\ z_t \end{bmatrix}}_{\equiv X_t} = \underbrace{\begin{bmatrix} b_{10} \\ b_{20} \end{bmatrix}}_{\equiv B_0} +$$
$$\underbrace{\begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix}}_{\equiv B_1} \underbrace{\begin{bmatrix} y_{t-1} \\ z_{t-1} \end{bmatrix}}_{\equiv X_{t-1}} + \underbrace{\begin{bmatrix} \sigma_y & 0 \\ 0 & \sigma_z \end{bmatrix}}_{\equiv B} \underbrace{\begin{bmatrix} \varepsilon_{yt} \\ \varepsilon_{zt} \end{bmatrix}}_{\equiv \varepsilon_t} \Rightarrow$$

$$AX_t = B_0 + B_1 X_{t-1} + B \varepsilon_t.$$

A forma reduzida desse modelo simplificado é:

$$\begin{aligned} X_t &= \Phi_0 + \Phi_1 X_{t-1} + e_t; \\ \Phi_0 &\equiv A^{-1} B_0; \\ \Phi_1 &\equiv A^{-1} B_1; \\ A e_t &\equiv B \varepsilon_t. \end{aligned} \tag{2}$$

Simulação (sem intercepto)

- ▶ Instalando o pacote

```
install.packages("tsDyn")
```


```
require(tsDyn)
```

- ▶ Comandos:

```
B1<-matrix(c(0.4, 0.4, 0.1, 0.6), 2)
```

```
set.seed(123);var1<-VAR.sim(B=B1,n=200,include="none")
```


```
ts.plot(var1, type="l", col=c(1,2))
```



```
B2<-matrix(c(0.6, -0.3, 0, 0.6), 2)
```

```
set.seed(111); var2<-VAR.sim(B=B2,n=200,include="none")
```

```
ts.plot(var2, type="l", col=c(1,2))
```




Simulação (com intercepto)

► Comandos:

```
B3<-rbind(c(0.5, 0.7, 0.3), c(0, 0.3, 0.7))
```

```
set.seed(7);var3<-VAR.sim(B=B3,n=100, include="const")
```


```
ts.plot(var3, type="l", col=c(1,2))
```



```
B4<-rbind(c(0.5, 0.7, -0.3), c(0, -0.3, 0.7))
```

```
set.seed(2);var4<-VAR.sim(B=B4,n=100, include="const")
```

```
ts.plot(var4, type="l", col=c(1,2))
```



- Basta uma das séries ter drift, que as séries apresentam alguma tendência.

VAR(p)

- ▶ As séries y_t e z_t movimentam-se conjuntamente, mesmo na presença de raiz unitária.
- ▶ Concentramo-nos na discussão sobre o caso de variáveis estacionárias, porém Sims (1980) e Sims, Stock e Watson (1990) admitem a mistura de variáveis estacionárias e não estacionárias num modelo VAR. O VAR é uma metodologia interessada nas inter-relações entre as variáveis.
- ▶ Generalização:

$$X_t = \Phi_0 + \sum_{i=1}^p \Phi_i X_{t-i} + GZ_t + e_t,$$

em que

X_t é um vetor $n \times 1$ de variáveis endógenas, como anteriormente;

G é uma matriz de coeficientes $n \times g$;

Z_t é um vetor $g \times 1$ de variáveis exógenas que pode incluir variáveis determinísticas.

VAR(p)

- ▶ Diferentemente dos modelos univariados, o VAR busca responder qual a trajetória da série, dado um **choque estrutural**.
- ▶ Por trajetória, deseja-se conhecer o tempo que um choque afeta uma série, se ela muda de patamar ou não, para que patamar vai, entre outras informações.

VAR(p)

- ▶ O VAR resulta na estimação de uma infinidade de coeficientes. Um VAR (p), por exemplo, com n variáveis endógenas teria $n + n^2 p$ coeficientes a estimar, já que as matrizes Φ_i têm dimensão $n \times n$ e as n primeiras variáveis referem-se à constante, sem contar ainda os coeficientes de possíveis variáveis exógenas.
- ▶ Muitas vezes os coeficientes estimados serão estatisticamente insignificantes, até porque algumas variáveis são normalmente colineares, entretanto deve-se evitar impor restrições sobre os coeficientes, sob pena de perder informações relevantes, a menos que sejam restrições econômicas bem fundamentadas.

Identificação

- ▶ Como selecionar a ordem p de um modelo VAR ? Que critérios podem ser utilizados nessa tarefa?
- ▶ Usar tantas defasagens quantas forem necessárias para obter "resíduos brancos" em todas as variáveis endógenas.
- ▶ Critério de informação: considere um $VAR(m)$, em que $m = 0, 1, 2, \dots, p_{\max}$. O problema é escolher a ordem p que minimiza a seguinte fórmula geral do critério de informação:

$$Cr(m) = \ln |\hat{\Gamma}_0| + c_T \varphi(m),$$

em que

$$\hat{\Gamma}_0 = \frac{\sum_{t=1}^T \hat{e}_t \hat{e}_t'}{T};$$

c_T é uma seqüência que depende do tamanho da amostra;

$\varphi(m)$ é uma função que penaliza VAR de grandes ordens.

Identificação

- ▶ O tamanho amostral tem de ser mantido constante para tornar o critério de informação comparável. Logo, o tamanho da amostra, comum a todas as ordens, será $T - p_{\max}$.
- ▶ A versão multivariada dos critérios *AIC*, *BIC* e *HQ* é:

$$AIC(m) = \ln |\hat{\Gamma}_0(m)| + \frac{2}{T} mn^2;$$

$$BIC(m) = \ln |\hat{\Gamma}_0(m)| + \frac{\ln T}{T} mn^2;$$

$$HQ(m) = \ln |\hat{\Gamma}_0(m)| + \frac{\ln \ln T}{T} 2mn^2,$$

em que mn^2 é o número total de parâmetros estimados em todas as equações.

Identificação

- ▶ Outra maneira de escolher a ordem de defasagem, é aplicar testes seqüenciais para definir a ordem p do modelo VAR . Estabeleça o p_{\max} e considere $H_0 : \Phi_{p_{\max}} = \mathbf{0} \times H_1 : \Phi_{p_{\max}} \neq \mathbf{0}$. Se o teste não for rejeitado, repete-se o procedimento considerando $p_{\max} - 1$. Quando a nula for rejeitada, ter-se-á encontrada a ordem de defasagem do modelo.
- ▶ Problema: estabelecer p_{\max} . Se p_{\max} é muito pequeno, os resíduos estimados não serão um ruído branco. Contudo, se p_{\max} é muito grande, o impacto sobre a probabilidade de erros como um todo poderá ser severamente afetado, de modo que é difícil confiar nos intervalos de confiança gerados.

VAR - exemplo simulado

- ▶ Pacote para estimação do VAR

```
install.packages("ts")
```

```
require(ts)
```

- ▶ Pacote para estimação do VAR

```
install.packages("vars")
```

```
require(vars)
```

VAR - exemplo simulado

► Estimando o VAR

```
colnames(var1)=c("x","y")
```

```
var1_est<-VAR(var1,lag.max = 10,ic="SC",type="none")
```

```
var1_est$p
```

```
var1_est$varresult
```

B1

```
$x                                     > B1
Call:
lm(formula = y ~ -1 + ., data = datamat)  [1,] [2,]
Coefficients:                             [1,] 0.4 0.1
      x.l1      y.l1                       [2,] 0.4 0.6
0.38798 0.08119

$y
Call:
lm(formula = y ~ -1 + ., data = datamat)
Coefficients:
      x.l1      y.l1
0.4278 0.4368
```

► var1_est<-VAR(var1,lag.max = 10,ic="AIC",type="none")

```
var1_est$p
```

Teste de hipótese

- ▶ Testar hipóteses em modelos multivariados é semelhante ao caso univariado.
- ▶ Diferença: em vez de calcular a soma dos quadrados dos resíduos, calcula-se o determinante da matriz de covariância dos resíduos do modelo restrito e do não restrito.

Seja

$$X_t = \Phi_0 + \sum_{i=1}^p \Phi_i X_{t-i} + GZ_t + e_t.$$

Teste de hipótese

- ▶ Estima-se o modelo sem restrição e calcula-se a matriz de covariância dos resíduos, $\hat{\Sigma}_u$;
- ▶ Estima-se o modelo com restrição, excluindo $k \leq g$ variáveis exógenas e/ou m defasagens, e calcula-se $\hat{\Sigma}_r$;
- ▶ Calcula-se a razão de verossimilhança da seguinte forma:

$$LR = (T - c) \left(\log |\hat{\Sigma}_r| - \log |\hat{\Sigma}_u| \right) \rightarrow \chi_r^2,$$

em que

T é o número de observações utilizadas na regressão;

$c = 1 + g + np$ é o número de parâmetros estimados em *cada* equação do sistema não restrito, incluindo a constante e as variáveis exógenas ;

$r = mn^2 + kn$ é o número de restrições no sistema.

Teste de hipótese

- ▶ Suponha um sistema de n equações com número máximo de defasagens $p=6$
- ▶ Deseja-se testar se $p=4$
- ▶ Imaginando um sistema com constante e sem variáveis exógenas:

$$c=1+pn=1+6n$$

- ▶ O número de restrições é dado pela quantidade de parâmetros que se deixa de estimar no modelo restrito que é:

$$r=mn^2=2n^2$$

VAR - exemplo simulado

► Instalando o pacote

```
install.packages("VAR.etc")
```

```
require(VAR.etc)
```

► Estimando o VAR

```
data(dat)
```

► Defasagem 3

```
restrict="full"
```

```
restrict0 = rbind(c(3,1,1), c(3,1,2), c(3,1,3), c(3,2,1), c(3,2,2),c(3,2,3),c(3,3,1),c(3,3,2),c(3,3,3))
```

```
VAR.LR(dat,p=3,restrict0,restrict,type="const")
```

► Defasagem 2

```
restrict1 = rbind(c(2,1,1), c(2,1,2), c(2,1,3), c(2,2,1), c(2,2,2),c(2,2,3),c(2,3,1),c(2,3,2),c(2,3,3))
```

```
VAR.LR(dat,p=2,restrict1,restrict,type="const")
```

VAR - exemplo simulado

Considere o modelo foi simulado da seguinte forma:

$$\begin{aligned}y_t &= \phi y_{t-1} + \varepsilon_t; \\x_t &= \delta y_t + v_t,\end{aligned}$$

em que ε_t e v_t são ambos ruídos brancos independentes.
Pode-se reescrever esse modelo na forma matricial:

$$\begin{bmatrix} 1 & 0 \\ -\delta & 1 \end{bmatrix} \begin{bmatrix} y_t \\ x_t \end{bmatrix} = \begin{bmatrix} \phi & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} y_{t-1} \\ x_{t-1} \end{bmatrix} + \begin{bmatrix} \varepsilon_t \\ v_t \end{bmatrix}.$$

Reescrevendo o modelo na forma reduzida, tem-se:

$$\begin{bmatrix} y_t \\ x_t \end{bmatrix} = \begin{bmatrix} \phi & 0 \\ \delta\phi & 0 \end{bmatrix} \begin{bmatrix} y_{t-1} \\ x_{t-1} \end{bmatrix} + \begin{bmatrix} e_{yt} \\ e_{xt} \end{bmatrix}.$$

$$\begin{bmatrix} 1 & 0 \\ -\delta & 1 \end{bmatrix}^{-1} = \begin{bmatrix} 1 & 0 \\ \delta & 1 \end{bmatrix}$$

VAR estrutural - exemplo simulado

Ao estimar o modelo, a matriz Φ_1 conterá quatro coeficientes estimados. Espera-se que os coeficientes da coluna 2 sejam insignificantes e que os coeficientes da 1 satisfaçam aproximadamente a seguinte restrição:

$$\begin{aligned}\phi_{11,1} &= \phi; \\ \phi_{21,1} &= \delta\phi,\end{aligned}$$

em que δ e ϕ são valores usados na simulação. No caso da simulação, definiram-se $\delta = 0,1$ e $\phi = 0,8$.

Estimando-se o VAR (1), obtêm-se:

$$\begin{bmatrix} y_t \\ x_t \end{bmatrix} = \begin{bmatrix} 0,794 & 0,097 \\ (0,035) & (0,063) \\ 0,077 & -0,002 \\ (0,032) & (0,058) \end{bmatrix} \begin{bmatrix} y_{t-1} \\ x_{t-1} \end{bmatrix} + \begin{bmatrix} \hat{e}_{yt} \\ \hat{e}_{xt} \end{bmatrix}.$$

$$\phi_{11,1} \simeq 0,8;$$

$$\phi_{21,1} \simeq 0,1 \times 0,8 = 0,08.$$

VAR estrutural - exemplo simulado

► Gerando as variáveis

```
set.seed(5);y<-arima.sim(n = 100, list(ar = c(0.80)),sd = sqrt(1))
```

```
set.seed(5); x<-0.1*y+rnorm(100,0,1)
```

► Estimando o VAR

```
var_xy<-cbind(x,y)
```

```
colnames(var_xy)=c("x","y")
```

```
varxy_est<-VAR(var_xy,p = 1,type="none")
```

```
VAR Estimation Results:
```

```
=====
```

```
Estimated coefficients for equation x:
```

```
=====
```

```
Call:
```

```
x = x.l1 + y.l1
```

```
      x.l1      y.l1  
0.08562543 0.07629045
```

```
=====
```

```
Estimated coefficients for equation y:
```

```
=====
```

```
Call:
```

```
y = x.l1 + y.l1
```

```
      x.l1      y.l1  
0.1152122 0.7428224
```

VAR estrutural - exemplo simulado

- ▶ Gerando as variáveis

```
set.seed(5); y<-arima.sim(n = 1500, list(ar = c(0.80)),sd = sqrt(1))
```

```
set.seed(5); x<-0.1*y+rnorm(1500,0,1)
```

- ▶ Estimando o VAR

```
var_xy<-cbind(x,y)
```

```
colnames(var_xy)=c("x","y")
```

```
varxy_est<-VAR(var_xy,p = 1,type="none")
```

- ▶ Se reduzir o n, a imprecisão aumentará e

os coeficientes poderão ficar mais distantes

do valor simulado.

VAR Estimation Results:

=====

Estimated coefficients for equation x:

=====

Call:

x = x.l1 + y.l1

x.l1	y.l1
0.01875557	0.08164559

=====

Estimated coefficients for equation y:

=====

Call:

y = x.l1 + y.l1

x.l1	y.l1
0.03966199	0.79508475

VAR - Relatório de inflação (BCB)

- ▶ Revisão dos modelos de Vetores Autorregressivos com fundamentação econômica
- ▶ Relatório de Inflação - Setembro de 2012
- ▶ “Objetivo do boxe é revisar os grupos de modelos VAR atualmente usados pelo BCB”
- ▶ Número de defasagens foi feita utilizando-se HQ e o teste de autocorrelação dos resíduos (LM)

Tabela 2 – Modelos VAR econômicos novos

Modelo	Variáveis endógenas	Ajuste sazonal	Defasagens	Juros (deflator)	Variáveis exógenas
VAR I	Preços livres, preços administrados, câmbio, juros reais	não	2	<i>ex-post</i> (IGP-M)	-
VAR II	Preços livres, M4/B ^{1/} , câmbio, juros reais	sim	1	<i>ex-post</i> (IPCA)	-
VAR III	Preços livres, prod. industrial, juros reais	sim	3	<i>ex-post</i> (IGP-M)	-
VAR IV	Preços livres, M1, juros reais	não	1	<i>ex-post</i> (IGP-M)	-
BVAR II	Preços livres, câmbio, juros reais	sim	13	<i>ex-post</i> (IGP-M)	-
BVAR II (T) ^{2/}	Preços livres, PIB, juros nominais	sim	5	<i>ex-ante</i> (IGP-M)	<i>Dummy</i> 1

1/ M4/B é a razão entre o agregado monetário M4 e a base monetária B.

2/ (T) indica trimestral.

3/ *Dummy* 1 é uma variável *dummy* que captura mudança de tendência.

VAR - Relatório de inflação (BCB)

- Atualizando o arquivo:

```
setwd("C:/diretorio/diretorio")
```

```
list.files()
```

```
X<-read.csv("aula_varbcb.csv",sep=";", dec=".", head=TRUE)
```

VAR - Relatório de inflação (BCB)

- ▶ Verificando se há raiz unitária

```
require(fUnitRoots)
```

```
adfTest(X$ipca_livres,lags=2,type = "c")
```

```
adfTest(X$juros_reais,lags=2,type = "c")
```

```
adfTest(X$cambio,lags=2,type = "c")
```

- ▶ Filtro HP para produção industrial

```
require(mFilter)
```

```
hp_ip=hpfilter(X$ip_sa,type="lambda",freq = 1600)
```

```
hp_ip14=hpfilter(X$ip_sa,type="lambda",freq = 14400)
```

```
plot(hp_ip$cycle,type="l")
```

```
points(hp_ip14$cycle,type="l",col="red")
```

VAR - Relatório de inflação (BCB)

► VAR I

```
var1<-cbind(X$ipca_livres,X$ipca_adm,X$cambio_dif,X$juros_reais)
```

```
colnames(var1)=c("livres","adm","cambio","juros")
```

```
var1_est<-VAR(var1,lag.max = 4,ic="HQ")
```

```
coefic=coef(var1_est)
```

```
coefic$livres
```

VAR - Relatório de inflação (BCB)

▶ VAR II

```
var2<-cbind(X$ipca_livres,X$ip_sa_var,X$juros_reais)
```

```
colnames(var2)=c("livres","ip","juros")
```

```
var2_est<-VAR(var2,lag.max = 4,ic="HQ")
```

```
var2_est$p
```

```
var2_est<-VAR(var2,p= 3,type="const")
```

▶ VAR II

```
var2_hp<-cbind(X$ipca_livres,hp_ip14$cycle,X$juros_reais)
```

```
colnames(var2_hp)=c("livres","ip_hp","juros")
```

```
var2hp_est<-VAR(var2_hp,p = 3)
```


VAR - Estacionariedade

O modelo anterior é estacionário se os autovalores da polinomial $\sum_{i=1}^p \Phi_i L^i$ estiverem dentro do círculo unitário.

```
roots(var1_est,modulus=TRUE)
```

```
roots(var2_est,modulus=TRUE)
```

```
roots(var2hp_est,modulus=TRUE)
```



Verificação - teste de Ljung-Box

- Generalização dos testes de resíduos dos modelos univariados

$$H_0 : E(e_t e'_{t-j}) = \mathbf{0}, \text{ para todo } j = 1, 2, \dots, J > p.$$

versus

$$H_1 : E(e_t e'_{t-j}) \neq \mathbf{0}, \text{ para algum } j.$$

- A estatística do teste é parecida com a de Ljung-Box:

$$Q = T \sum_{j=1}^J \text{tr} \left(\hat{\Gamma}_j' \hat{\Gamma}_0^{-1} \hat{\Gamma}_j \hat{\Gamma}_0^{-1} \right) \xrightarrow{d} \chi_{n^2(J-p)}^2,$$

em que $\hat{\Gamma}_j = \frac{\sum_{t=j+1}^T \hat{e}_t \hat{e}'_{t-j}}{T}$ é a autocovariância na defasagem j .

Verificação - teste de Ljung box

- ▶ O teste Ljung Box é uma aplicação do teste Portmanteau - algum dos coeficientes é diferente de zero.
- ▶ Usa o mesmo pacote de estimação do VAR no R.

```
serial.test(var1_est,lags.pt=2,type = "PT.adjusted")  
serial.test(var1_est,lags.pt=5,type = "PT.adjusted")  
serial.test(var1_est,lags.pt=10,type = "PT.adjusted")
```
- ▶ df representa o número de graus de liberdade para a distribuição chi-quadrada.

Verificação - teste de Breusch-Godfrey

- ▶ O objetivo é testar se existe autocorrelação de resíduos no modelo:

$$\hat{e}_t = \Theta_1 \hat{e}_{t-1} + \Theta_2 \hat{e}_{t-2} + \cdots + \Theta_h \hat{e}_{t-h} + u_t$$

e verificar se:

$$H_0 : \Theta_1 = \Theta_2 = \cdots = \Theta_h = \mathbf{0} \times H_1 : \Theta_1 \neq \mathbf{0} \vee \Theta_2 \neq \mathbf{0} \vee \cdots \vee \Theta_h \neq \mathbf{0}$$

- ▶ Utiliza-se a regressão auxiliar:

$$\begin{aligned} \hat{e}_t = & \Phi_1 X_{t-1} + \Phi_2 X_{t-2} + \cdots + \Phi_p X_{t-p} + \\ & + \Theta_1 \hat{e}_{t-1} + \Theta_2 \hat{e}_{t-2} + \cdots + \Theta_h \hat{e}_{t-h} + u_t. \end{aligned}$$

Verificação - teste de Breusch-Godfrey

- ▶ Utiliza o mesmo comando do teste de Portmanteau, alterando para o BG.
- ▶ Pacote “vars” no R.

```
serial.test(var1_est,lags.bg=2,type = "BG")
```

```
serial.test(var1_est,lags.bg=5,type = "BG")
```

```
serial.test(var1_est,lags.bg=10,type = "BG")
```

Previsão

- ▶ Análoga aos processos univariados.
- ▶ Quando se conhece o processo gerador de dados, a previsão h passos à frente é dada por:

$$E(X_{t+h}|I_t) \equiv X_{t+h|t} = \Phi_1 X_{t+h-1|t} + \Phi_2 X_{t+h-2|t} + \cdots + \Phi_p X_{t+h-p|t},$$

em que $X_{t+j|t} = X_{t+j}$ para $j \leq 0$.

- ▶ Transformando X_t num modelo de médias móveis infinito:

$$X_{t+h} = \left(I - \sum_{j=1}^p \Phi_j L^j \right)^{-1} e_{t+h} = e_{t+h} + \Psi_1 e_{t+h-1} + \Psi_2 e_{t+h-2} + \cdots$$

- ▶ Conseqüentemente, a previsão correspondente é dada por:

$$X_{t+h|t} = \sum_{j=h}^{\infty} \Psi_j e_{t+h-j}.$$

Previsão

- ▶ Desse modo, o erro de previsão será obtido extraíndo-se de X_{t+h} o termo $X_{t+h|t}$:

$$X_{t+h} - X_{t+h|t} = \sum_{j=0}^{h-1} \Psi_j e_{t+h-j},$$

em que $\Psi_0 = I_n$.

- ▶ A expectativa de previsão dos erros é zero. O EQM é dado por:

$$\Sigma_x(h) = E(X_{t+h} - X_{t+h|t})(X_{t+h} - X_{t+h|t})' = \sum_{j=0}^{h-1} \Psi_j \Sigma \Psi_j'.$$

- ▶ No processo é estacionário, a incerteza da previsão é limitada. Os processos integrados têm erro de previsão indeterminado em horizontes longos, mas isso não exclui a possibilidade de que a previsão de alguns componentes de variáveis integradas tenha o erro de previsão limitado também.
- ▶ Na presença de variáveis exógenas, entre as quais algumas determinísticas, pode-se estender a fórmula anterior facilmente.

Previsão

- ▶ Projetando e fazendo o gráfico - modelo 1:

```
var1_proj<-predict(var1_est,n.ahead=12,ci=0.95)
```

```
var1_proj$fcst$livres
```

```
fanchart(var1_proj)
```

Previsão

- ▶ Projetando e fazendo o gráfico - modelo 2:

```
var2_proj<-predict(var2_est,n.ahead=12,ci=0.95)
```

```
fanchart(var2_proj)
```

- ▶ Comparando as projeções do modelo com variação da PIM e hiato

```
var2hp_proj<-predict(var2hp_est,n.ahead=12,ci=0.95)
```

```
plot(var2hp_proj$fcst$livres[,1],type="l")
```

```
points(var2_proj$fcst$livres[,1],type="l",col="red")
```

```
points(var1_proj$fcst$livres[,1],type="l",col="blue")
```

- ▶ O IPCA livres é maior no modelo com hiato, devido a recuperação mais rápida da atividade.

Vetor Autorregressivo (VAR) - aplicação com dados trimestrais

VAR - Modelo BCB trimestral

- ▶ Atualizando o arquivo com os dados trimestrais:

```
Z<-read.csv("aula_varbcb_trim.csv",sep=";", dec=".", head=TRUE)
```

```
Z$data<-as.Date(Z$data,'%d/%b/%y')
```

VAR - Modelo BCB trimestral

- Tornando as variáveis em séries temporais:

```
livres<-ts(Z$ipca_livres,start = c(2002,1),frequency=4)
```

```
adm<-ts(Z$ipca_adm,start = c(2002,1),frequency=4)
```

```
ip<-ts(Z$ip_sa,start = c(2002,1),frequency=4)
```

```
ip_var<-ts(Z$ip_var,start = c(2002,1),frequency=4)
```

```
cambio<-ts(Z$cambio,start = c(2002,1),frequency=4)
```

```
cambio_var<-ts(Z$cambio_dif,start = c(2002,1),frequency=4)
```

```
juros<-ts(Z$juros_reais,start = c(2002,1),frequency=4)
```

```
juros_dif<-ts(Z$dif_juros,start = c(2002,1),frequency=4)
```

VAR - Modelo BCB trimestral

- ▶ Verificar se há raízes unitárias:

```
adfTest(livres,lags=1,type = "c")
```

```
adfTest(adm,lags=1,type = "c")
```

```
adfTest(cambio,lags=2,type = "c")
```

```
adfTest(cambio_var,lags=1,type = "c")
```

```
adfTest(juros,lags=1,type = "c")
```

```
adfTest(juros_dif,lags=1,type = "c")
```

- ▶ Hiato da produção industrial

```
hp_ip=hpfilter(ip,type="lambda",freq = 14400)
```

VAR - Modelo BCB trimestral

- ▶ Criando o grupo

```
var_bcb<-cbind(livres,adm, hp_ip$cycle,cambio_var,juros_dif)
```

```
colnames(var_bcb)=c("livres", "admin", "ip_hiato", "cambio", "juros_dif")
```

- ▶ Inserindo *dummies* sazonais

```
require(uroot)
```

```
sd<-seasonal.dummies(livres)
```

VAR - Modelo BCB trimestral

► Estimando o VAR

```
varbcb_est<-VAR(var_bcb,lag.max = 4,ic="HQ",exogen = sd)
```

```
varbcb_est$p
```

```
varbcb_est$varresult ou coef(varbcb_est)
```

VAR - Modelo BCB trimestral

► Verificação:

Estacionariedade: Raízes dentro do círculo unitário

```
roots(varbcb_est)
```

VAR - Modelo BCB trimestral

► Projeção

```
sd_fc = matrix(0, 4, 4)
```

```
sd_fc[1,1]=1
```

```
sd_fc[2,2]=1
```

```
sd_fc[3,3]=1
```

```
sd_fc[4,4]=1
```

```
sd_fc<-ts(sd_fc,start = c(2018,1),frequency = 4)
```

```
colnames(sd_fc)=c("SD1", "SD2", "SD3", "SD4")
```

```
varbcb_proj<-predict(varbcb_est,n.ahead=4,ci=0.95,dumvar = sd_fc)
```

```
varbcb_proj$fcst
```

VAR - Modelo BCB trimestral (exercício)

- ▶ Estimar o segundo modelo do Banco Central com os dados trimestrais:
 - ▶ Verificar se as variáveis são estacionárias
 - ▶ Estimar o modelo - apresentar os coeficientes
 - ▶ Verificar se as raízes estão dentro do círculo unitário
 - ▶ Projetar!