

Macroeconometria - Séries de tempo

FAUSTO JOSÉ ARAÚJO VIEIRA

Aula 6

17 de abril a 22 de maio de 2018

RESUMO - VETOR AUTORREGRESSIVO (AULA ANTERIOR)

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.

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.

RESUMO DA AULA

The background features abstract, overlapping geometric shapes in various shades of green, ranging from light lime to dark forest green. These shapes are primarily located on the right side of the slide, creating a modern, layered effect. The text 'RESUMO DA AULA' is positioned on the left side of the slide, centered vertically, in a bold, green, sans-serif font.

SUMÁRIO DESTA AULA

- ▶ Função resposta ao impulso
- ▶ Intervalo de confiança
- ▶ Decomposição de variância
- ▶ Teste de causalidade
- ▶ VAR estrutural
 - ▶ Forma estrutural x Forma reduzida
- ▶ Decomposição Blanchard e Quah

VETOR AUTORREGRESSIVO (VAR) - CONTINUAÇÃO

Forma estrutural x Forma reduzida (lembrando)

Em matrizes:

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

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

A forma reduzida desse modelo simplificado é:

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

Função resposta ao impulso

- ▶ O modelo VAR não permite identificar todos os parâmetros da forma estrutural, a menos que se imponham restrições adicionais.
- ▶ Para ver isso, observe que no sistema restrito dado pela equação (2) conseguem-se estimar os seis parâmetros na equação da média, $Var(e_1)$, $Var(e_2)$ e $Cov(e_1, e_2)$. No sistema primitivo há dez parâmetros a calcular: além dos oito coeficientes estruturais, há ainda as variâncias de cada um dos choques.

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

$$X_t = \Phi_0 + \Phi_1 X_{t-1} + e_t; \quad (2)$$

Função resposta ao impulso

- ▶ Sims (1980) sugere um sistema recursivo para identificar o modelo. Trata-se de impor que alguns coeficientes sejam iguais a zero. Geralmente, usam-se argumentos econômicos para definir quais deles são iguais a zero.
- ▶ Sims impõe que o efeito *feedback* seja limitado. No caso mais simples, de um modelo bivariado, impor-se-ia, por exemplo, que $a_{12} = 0$:

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

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

Função resposta ao impulso - lembrar!

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:

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

Função resposta ao impulso

Essa restrição é importante porque torna os parâmetros estruturais restantes identificáveis, conforme se observa no exemplo bivariado:

$$\begin{aligned} A^{-1} &= \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \implies \begin{bmatrix} y_t \\ z_t \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} b_{10} \\ b_{20} \end{bmatrix} + \\ &\begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} \begin{bmatrix} y_{t-1} \\ z_{t-1} \end{bmatrix} + \\ &+ \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} \sigma_y & 0 \\ 0 & \sigma_z \end{bmatrix} \begin{bmatrix} \varepsilon_{yt} \\ \varepsilon_{zt} \end{bmatrix}. \end{aligned}$$

Sabendo-se ainda que $a_{12} = 0$, então os erros reduzidos ficam

$$\begin{bmatrix} e_{1t} \\ e_{2t} \end{bmatrix} = \begin{bmatrix} \sigma_y \varepsilon_{yt} \\ \sigma_z \varepsilon_{zt} - a_{21} \sigma_y \varepsilon_{yt} \end{bmatrix},$$

de modo que

$$\begin{aligned} \text{var}(e_1) &= \sigma_y^2; \\ \text{cov}(e_1, e_2) &= -a_{21} \sigma_y^2; \text{ e } \text{var}(e_2) = \sigma_z^2 + a_{21}^2 \sigma_y^2. \end{aligned}$$

Função resposta ao impulso

- ▶ Essas três equações combinam-se com as demais estimativas para identificar o modelo:

$$\begin{aligned}\phi_{10} &= b_{10}; & \phi_{20} &= b_{20} - b_{10}a_{21}; \\ \phi_{11} &= b_{11}; & \phi_{12} &= b_{12}; \\ \phi_{21} &= -a_{21}b_{11} + b_{21}; & \phi_{22} &= -a_{21}b_{12} + b_{22}.\end{aligned}$$

- ▶ A metodologia proposta por Sims pode ser generalizada para um vetor com n variáveis endógenas. Trata-se de uma maneira triangular de decompor os resíduos, chamada de decomposição de **Choleski**.
- ▶ No caso de n variáveis endógenas, a matriz de covariância é de dimensão $n \times n$. As condições de identificação requerem a imposição de $\frac{n^2-n}{2}$ restrições. O problema dessa imposição é definir a ordenação das variáveis, que é arbitrária, ainda que atribuída a razões econômicas. A ordenação das variáveis define a forma das restrições, de modo que diferentes ordenações geram diferentes restrições.

Função resposta ao impulso

- ▶ Se os autovalores da polinomial $(I - \sum_{i=1}^p \Phi_i L^i)$ estiverem fora do círculo unitário, pode-se escrever um VAR (p) como um vetor de médias móveis infinito VMA (∞):

$$X_t - \bar{X} = \sum_{i=0}^{\infty} \Phi_1^i e_{t-i} = \sum_{i=0}^{\infty} \frac{\Phi_1^i}{1 - a_{12}a_{21}} \begin{bmatrix} 1 & -a_{12} \\ -a_{21} & 1 \end{bmatrix} \begin{bmatrix} \sigma_y \varepsilon_{yt-i} \\ \sigma_z \varepsilon_{zt-i} \end{bmatrix},$$

em que $\bar{X} \equiv (I - \Phi_1)^{-1} \Phi_0$ é a média de longo prazo.

- ▶ Seja:

$$\Psi_i = \frac{\Phi_1^i}{1 - a_{12}a_{21}} \begin{bmatrix} 1 & -a_{12} \\ -a_{21} & 1 \end{bmatrix}.$$

- ▶ Desse modo:

$$\begin{aligned} X_t &= \bar{X} + \sum_{i=0}^{\infty} \Psi_i B \varepsilon_{t-i} = \\ &= \bar{X} + \sum_{i=0}^{\infty} \begin{bmatrix} \psi_{i,11} & \psi_{i,12} \\ \psi_{i,21} & \psi_{i,22} \end{bmatrix} \begin{bmatrix} \sigma_y \varepsilon_{yt-i} \\ \sigma_z \varepsilon_{zt-i} \end{bmatrix}. \end{aligned}$$

Função resposta ao impulso

- ▶ Os elementos da matriz Ψ_i são os multiplicadores de impacto de um choque sobre as variáveis endógenas. Assim, o impacto total de um choque de ε_{yt} sobre y_{t+h} é dado pela soma dos coeficientes $\psi_{i,11}$, $i = 0, 1, 2, \dots, h$.

Função resposta ao impulso - Exemplo simulado

Considere o modelo foi simulado da seguinte forma:

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

$$x_t = \delta y_t + v_t,$$

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:

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

VAR - exemplo simulado

- ▶ Carregando pacotes

```
require(tsDyn)
```

```
require(vars)
```

- ▶ Gerando as variáveis

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

```
set.seed(20);var_xy<-VAR.sim(B=B1,n=200,include="none")
```

- ▶ Estimando o VAR

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

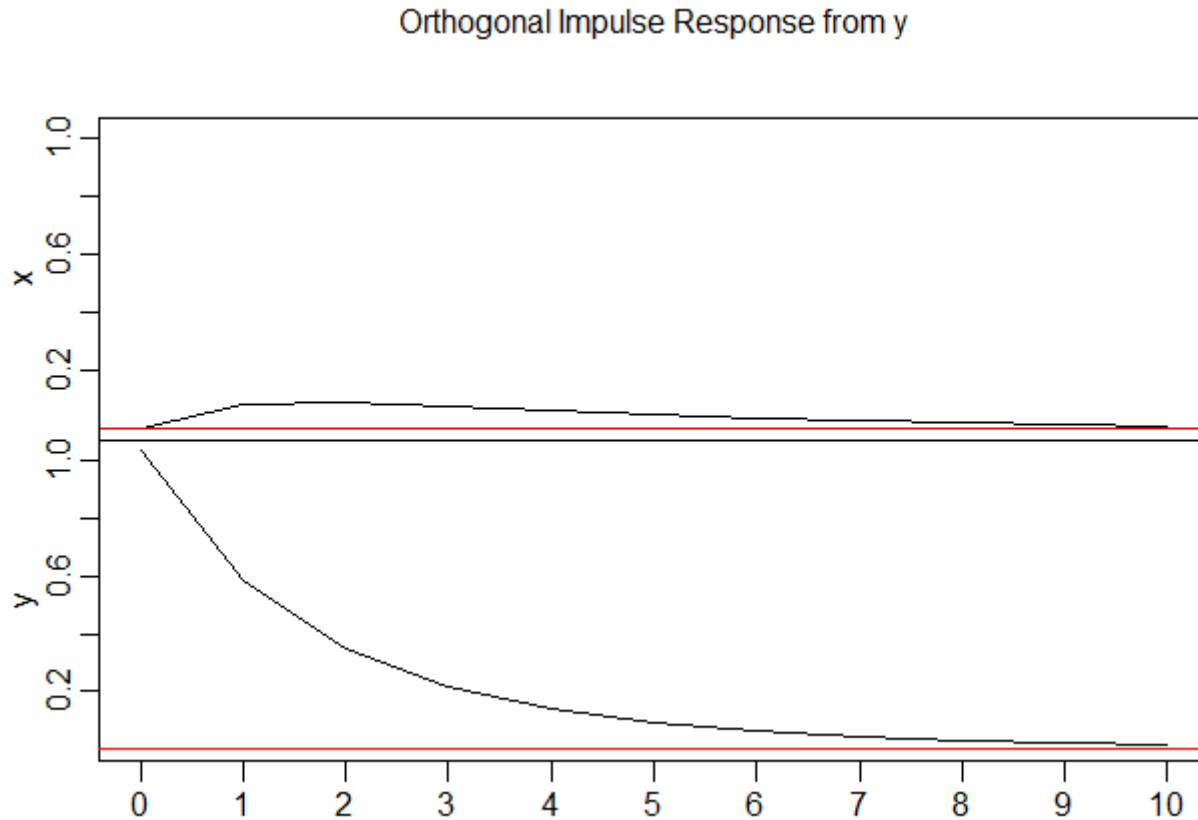
```
varxy_est<-VAR(var_xy,p = 1,type="none")
```

Função resposta ao impulso - Exemplo simulado

- ▶ Estimando o efeito de um choque de “y”

```
a<-irf(varxy_est, impulse = "y", response = c("x", "y"), boot = FALSE)
```

```
plot(a)
```



Intervalo de confiança

- ▶ A função resposta ao impulso é calculada mediante coeficientes estimados. Logo, é claro que há um intervalo de confiança a ser considerado nessas estimativas. Esse intervalo pode ser calculado de forma analítica ou por métodos de experimentos de Monte Carlo.
- ▶ O método analítico torna-se bem complicado quando se imagina um problema multivariado, em razão das covariâncias cruzadas.

Intervalo de confiança

- ▶ Estime o modelo multivariado e armazene os resíduos estimados, $\{\hat{e}_t\}$;
- ▶ Sorteie os resíduos armazenados com reposição e simule uma nova série usando as matrizes Φ estimadas no passo anterior. Por exemplo, no caso de um *VAR* (1):

$$\hat{X}_t = \hat{\Phi}_0 + \hat{\Phi}_1 \hat{X}_{t-1} + \hat{e}_t;$$

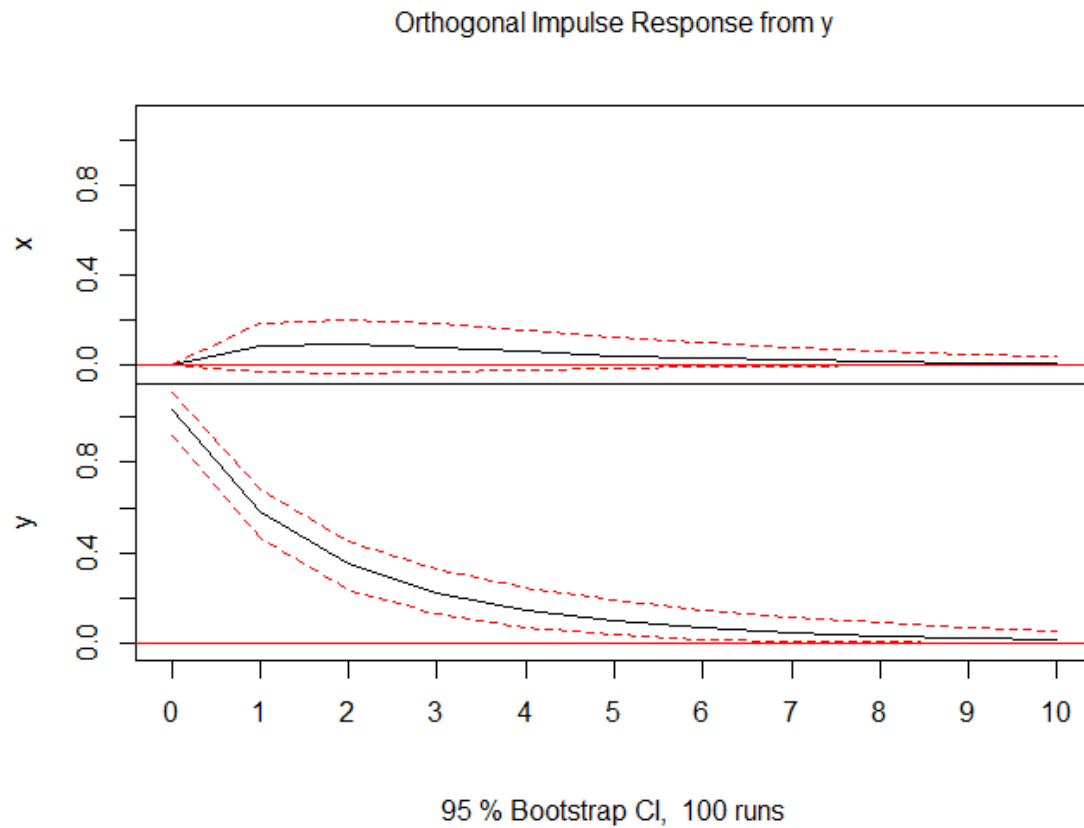
- ▶ Reestime o modelo e a nova função resposta ao impulso;
- ▶ Repita o processo milhares de vezes;
- ▶ Para construir um intervalo com 95% de confiança, exclua 2,5% das menores e maiores respostas.

Função resposta ao impulso

- ▶ Estimando o efeito de um choque da taxa de juros

```
a_interv<-irf(varxy_est, impulse = "y", response = c("x", "y"), boot = TRUE,ci=0.95)
```

```
plot(a_interv)
```

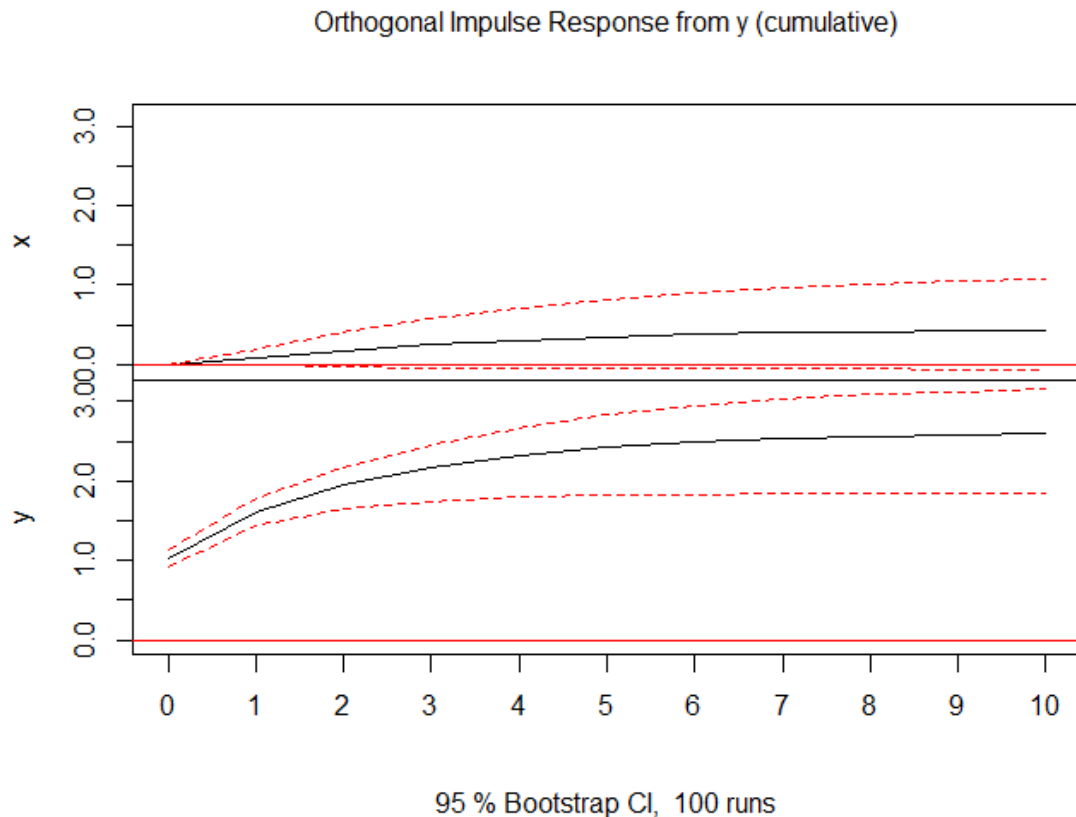


Função resposta ao impulso - acumulado

- ▶ Estimando o efeito de um choque da taxa de juros


```
a_cum<-irf(varxy_est, impulse = "y", response = c("x", "y"), boot = TRUE, ci=0.95,  
cumulative=TRUE)
```

```
plot(a_cum)
```



Função resposta ao impulso - VAR BCB trim

- ▶ Modelo trimestral estimado na aula anterior - exemplo
- ▶ Estimando o efeito de um choque da taxa de juros na indústria



Transformando um VAR(p) em VMA(∞)

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

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

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

- ▶ Transformando X_t num modelo de médias móveis infinito:

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

- ▶ Conseqüentemente, a previsão correspondente é dada por:

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

Decomposição da variância

Considere o exemplo das seções anteriores, VAR (1) com duas variáveis endógenas, y e z :

$$X_{t+h} = \bar{X} + \sum_{i=0}^{\infty} \Psi_i \varepsilon_{t+h-i}.$$

Calcule o erro de previsão:

$$X_{t+h} - E_t(X_{t+h}) = \sum_{i=0}^{h-1} \Psi_i \varepsilon_{t+h-i}.$$

Esmiuçando apenas y_{t+h} :

$$\begin{aligned} y_{t+h} - E_t(y_{t+h}) &= \psi_{0,11} \varepsilon_{yt+h} + \psi_{1,11} \varepsilon_{yt+h-1} + \cdots + \psi_{h-1,11} \varepsilon_{yt+1} + \\ &+ \psi_{0,12} \varepsilon_{zt+h} + \psi_{1,12} \varepsilon_{zt+h-1} + \cdots + \psi_{h-1,12} \varepsilon_{zt+1}. \end{aligned}$$

Logo:

$$\begin{aligned} \sigma_y^2(h) &= \sigma_y^2 (\psi_{0,11}^2 + \psi_{1,11}^2 + \cdots + \psi_{h-1,11}^2) + \\ &+ \sigma_z^2 (\psi_{0,12}^2 + \psi_{1,12}^2 + \cdots + \psi_{h-1,12}^2). \end{aligned}$$

Decomposição da variância

Agora, pode-se decompor a variância do erro de previsão em seus diversos elementos. Dividindo-se ambos os lados por $\sigma_y^2(h)$:

$$1 = \frac{\sigma_y^2 (\psi_{0,11}^2 + \psi_{1,11}^2 + \cdots + \psi_{h-1,11}^2)}{\sigma_y^2(h)} + \frac{\sigma_z^2 (\psi_{0,12}^2 + \psi_{1,12}^2 + \cdots + \psi_{h-1,12}^2)}{\sigma_y^2(h)}.$$

Decomposição da variância de $y_{t+h} - E_t(y_{t+h})$

h	$\sigma_y(h)$	$\frac{\sigma_y^2(\psi_{0,11}^2 + \psi_{1,11}^2 + \cdots + \psi_{h-1,11}^2)}{\sigma_y^2(h)}$	$\frac{\sigma_z^2(\psi_{0,12}^2 + \psi_{1,12}^2 + \cdots + \psi_{h-1,12}^2)}{\sigma_y^2(h)}$
1	0,956	100,00	0,00
2	1,063	94,53	5,47
3	1,116	88,09	11,91
4	1,152	83,24	16,76
5	1,176	80,03	19,97

Decomposição da variância

O mesmo é feito com a variável z_{t+h} :

Decomposição da variância de $z_{t+h} - E_t(z_{t+h})$

h	$\sigma_z(h)$	$\frac{\sigma_y^2(\psi_{0,21}^2 + \psi_{1,21}^2 + \dots + \psi_{h-1,21}^2)}{\sigma_z^2(h)}$	$\frac{\sigma_z^2(\psi_{0,22}^2 + \psi_{1,22}^2 + \dots + \psi_{h-1,22}^2)}{\sigma_z^2(h)}$
1	1,244	32,96	67,04
2	1,404	25,51	74,49
3	1,462	29,04	70,96
4	1,490	27,07	72,93
5	1,506	26,06	73,94

VAR simulado - decomposição da variância

- ▶ Estimando a decomposição da variância com 10 passos à frente:

```
a<-fevd(varxy_est,n.ahead = 10)
```


```
> a$x
```

	x	y
[1,]	1.0000000	0.000000000
[2,]	0.9942233	0.005776721
[3,]	0.9882005	0.011799481
[4,]	0.9841054	0.015894558
[5,]	0.9817490	0.018250959
[6,]	0.9805001	0.019499901
[7,]	0.9798668	0.020133233
[8,]	0.9795535	0.020446509
[9,]	0.9794007	0.020599271
[10,]	0.9793269	0.020673145

```
> a$y
```

	x	y
[1,]	0.001376104	0.9986239
[2,]	0.035219117	0.9647809
[3,]	0.070797377	0.9292026
[4,]	0.093985554	0.9060144
[5,]	0.106942035	0.8930580
[6,]	0.113699948	0.8863001
[7,]	0.117099844	0.8829002
[8,]	0.118775460	0.8812245
[9,]	0.119591236	0.8804088
[10,]	0.119985478	0.8800145

plot(a)



Teste de causalidade de Granger

- ▶ uma variável é capaz de prever outra? em que condições? Em outras palavras, a questão fundamental é saber se o escalar y ajuda a **prever** o escalar z . Se isso não acontece, então diz-se que y **não-Granger-causa** z .
- ▶ O teste tem o sentido de previsão, não de causalidade econômica, apesar do nome.
- ▶ A forma de responder a essa pergunta é usando um teste F convencional, válido quando os coeficientes de interesse puderem ser escritos de modo a multiplicar variáveis estacionárias.

Teste de causalidade de Granger

- ▶ O teste é feito da seguinte maneira:
- ▶ Estime $z_t = \phi_{20} + \sum_{i=1}^p \phi_{i,21} y_{t-i} + \sum_{i=1}^p \phi_{i,22} z_{t-i} + e_{2t}$;
- ▶ Teste se y não-Granger-causa z usando o teste de F , sob:

$$H_0 : \phi_{1,21} = \phi_{2,21} = \dots = \phi_{p,21} = 0 \times H_1 : \phi_{i,21} \neq 0, i = 1, 2, \dots, p,$$

em que a estatística do teste é dada por:

$$S_1 = \frac{\frac{(e_r^2 - e_u^2)}{p}}{\frac{e_u^2}{T-2p-1}} \xrightarrow{d} F(p, T - 2p - 1),$$

em que r representa restrito e u , não restrito. Se $S_1 > F^{5\%}$, rejeita-se a hipótese nula de que y não-Granger-causa z .

- ▶ Um teste equivalente é:

$$S_2 = \frac{T(e_r^2 - e_u^2)}{e_u^2} \xrightarrow{d} \chi_p^2.$$

Rejeita-se a nula se $S_2 > \chi_p^2(5\%)$.

Teste de causalidade de Granger

- ▶ Teste de causalidade de Granger não é a mesma coisa que teste de exogeneidade. Para que z_t seja exógeno a y_t , é preciso que z_t não seja afetado contemporaneamente por y_t . A forma reduzida do VAR não permite que se faça esse tipo de teste. O teste de causalidade de Granger inclui, pois, valores passados de y_t sobre z_t .
- ▶ Pode-se fazer o mesmo teste em contextos de mais variáveis, cujo nome é teste de bloco-exogeneidade. Estima-se o modelo com e sem restrição e utiliza-se o teste F , como visto anteriormente.

Teste de causalidade de Granger

- ▶ É importante observar que, em sistemas com $n > 2$, o teste de causalidade é mais complicado de ser feito, e a interpretação necessita de maiores cuidados. O problema que pode ocorrer ao não rejeitar a nula é não perceber a dinâmica mais complicada do modelo em que uma variável, apesar de não causar diretamente outra (por exemplo, y_{2t} não Granger-causa y_{1t}), pode causá-la indiretamente. Isso ocorrerá quando y_{2t} causar y_{3t} , que, por sua vez, causa y_{1t} . O teste de Granger-causalidade não foi desenvolvido para esse tipo de caso.

VAR simulado - estimação

- ▶ Estimando o modelo anterior:

```
causality(varxy_est,cause='x')
```

```
causality(varxy_est,cause='y')
```

VAR simulado - estimação

▶ Outro exemplo simulado

```
B2<-matrix(c(0.6, 0.0, 0.3, 0.3), 2)
```

```
set.seed(20);var2<-VAR.sim(B=B2,n=500,include="none")
```

```
colnames(var2)=c("x","y")
```

```
var2_est<-VAR(var2,p = 1,type="none")
```

```
coef(var2_est)
```

```
causality(var2_est,cause='x')
```

```
causality(var2_est,cause='y')
```

Exemplo prático - Taxa SELIC

- ▶ Se o Banco Central, de fato, determina a taxa Selic, então alterações na taxa efetiva praticada no mercado financeiro deveriam responder às alterações na meta definida pelo Banco Central.
- ▶ Por outro lado, não há razões para acreditar que alterações nas taxas de mercado afetem a meta definida pelo Banco Central.

Exemplo prático - Taxa SELIC

- ▶ Atualizando o arquivo:

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

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

- ▶ Raíz unitária

```
require(fUnitRoots)
```

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

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

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

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

- ▶ A taxa Selic meta e efetiva têm raiz unitária:

- ▶ Usa a primeira diferença!

Exemplo prático - Taxa SELIC

- ▶ Estimando o VAR

```
var_selic=cbind(X$meta_dif,X$efetiva_dif)
colnames(var_selic)=c("meta","efetiva")
varest_selic<-VAR(var_selic,lag.max = 20,ic="HQ")
varest_selic$p
```

- ▶ Defasagem de 20 - máximo

- ▶ Causalidade de Granger

```
causality(varest_selic,cause='meta')
causality(varest_selic,cause='efetiva')
```

Vetor Autorregressivo Estrutural (SVAR)

Lembrando do modelo 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:

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

VAR estrutural

- ▶ Existem outras formas de definir restrições sobre a matriz A , de modo a identificar os parâmetros estruturais. Usa-se a teoria econômica para definir as restrições da matriz A completamente, com risco de sobreidentificação.
- ▶ Para entender o procedimento, considere um VAR (1) com n variáveis:

$$AX_t = B_0 + B_1X_{t-1} + B\varepsilon_t.$$

- ▶ Quando se estima a forma reduzida, obtêm-se os resíduos \hat{e}_t , tal que:

$$\text{Forma estrutural } B\hat{e}_t = A\hat{e}_t. \text{ Forma reduzida}$$

- ▶ O problema é restringir o sistema, de forma a recuperar ε_t conforme a hipótese de que cada resíduo do sistema estrutural é independente um do outro.

VAR estrutural

- Considere a matriz de covariância dos erros da forma reduzida:

$$\Sigma = \begin{bmatrix} \sigma_{11} & \sigma_{12} & \cdots & \sigma_{1n} \\ \sigma_{21} & \sigma_{22} & \cdots & \sigma_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{n1} & \sigma_{n2} & \cdots & \sigma_{nn} \end{bmatrix},$$

$$\hat{\sigma}_{ij} = \frac{1}{T} \sum_{t=1}^T \hat{e}_{it} \hat{e}_{jt}.$$

- Σ é simétrica $\rightarrow \frac{n(n+1)}{2}$ elementos diferentes. Elementos da diagonal de A são unitários $\rightarrow (n^2 - n)$ elementos desconhecidos. Desconhecem-se as n variâncias de ε . Logo, há n^2 elementos desconhecidos e $\frac{n(n+1)}{2}$ conhecidos.

VAR estrutural

► Logo:

$$BB' = \text{Var}(Ae_t) = A\text{Var}(e_t)A'$$

► Suponha o seguinte sistema de equações, em que se admite conhecer a matriz de covariância de e_t :

$$\begin{bmatrix} \sigma_{\varepsilon_1}^2 & 0 \\ 0 & \sigma_{\varepsilon_2}^2 \end{bmatrix} = \begin{bmatrix} 1 & a_{12} \\ a_{21} & 1 \end{bmatrix} \begin{bmatrix} 0,5 & 0,4 \\ 0,4 & 0,6 \end{bmatrix} \begin{bmatrix} 1 & a_{21} \\ a_{12} & 1 \end{bmatrix} =$$
$$= \begin{bmatrix} 0,5 + 0,4a_{12} & 0,4 + 0,6a_{12} \\ 0,5a_{21} + 0,4 & 0,4a_{21} + 0,6 \end{bmatrix} \begin{bmatrix} 1 & a_{21} \\ a_{12} & 1 \end{bmatrix} =$$

$$\begin{bmatrix} 0,5 + 0,8a_{12} + 0,6a_{12}^2 & 0,5a_{21} + 0,4a_{12}a_{21} + 0,4 + 0,6a_{12} \\ 0,5a_{21} + 0,4 + 0,4a_{12}a_{21} + 0,6a_{12} & 0,5a_{21}^2 + 0,8a_{21} + 0,6 \end{bmatrix}$$

VARCOV $B\hat{\varepsilon}_t = A\hat{e}_t$

$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \end{bmatrix}$$

Erros estruturais não tem correlação

VAR estrutural - exemplo teórico

- ▶ Há três equações independentes com quatro incógnitas $(a_{12}, a_{21}, \sigma_{\varepsilon_1}^2, \sigma_{\varepsilon_2}^2)$:

$$\sigma_{\varepsilon_1}^2 = 0,5 + 0,8a_{12} + 0,6a_{12}^2;$$

$$0 = 0,5a_{21} + 0,4 + 0,4a_{12}a_{21} + 0,6a_{12};$$

$$\sigma_{\varepsilon_2}^2 = 0,5a_{21}^2 + 0,8a_{21} + 0,6.$$

- ▶ Impondo a restrição de Choleski, $a_{12} = 0$, calculam-se:

$$\sigma_{\varepsilon_1}^2 = 0,5;$$

$$0 = 0,5a_{21} + 0,4 \implies a_{21} = -0,8$$

$$\sigma_{\varepsilon_2}^2 = 0,5a_{21}^2 + 0,8a_{21} + 0,6 \implies \sigma_{\varepsilon_2}^2 = 0,28.$$

- ▶ A função resposta ao impulso. No caso de um VAR (1) bivariado, essa função é:

$$\Psi_i = \Phi_1^i \begin{bmatrix} 1 & 0 \\ -a_{21} & 1 \end{bmatrix}.$$

VAR estrutural - exemplo teórico

Outra restrição: uma inovação em ε_{2t} pode ter um efeito unitário em y_{1t}
→ $a_{12} = 1$:

$$\sigma_{\varepsilon_1}^2 = 1,9;$$

$$a_{21} = -\frac{10}{9};$$

$$\sigma_{\varepsilon_2}^2 = 0,5\frac{100}{81} - 0,8\frac{10}{9} + 0,6 = 0,328.$$

VAR estrutural - exemplo simulado

- ▶ Criando a matriz para identificação:

```
amat <- diag(2)
diag(amat) <- NA
amat[2, 1] <- NA
amat
```

- ▶ Estimação do modelo VAR

```
varxy_est <- VAR(var_xy, p = 1, type = "none")
summary(varxy_est)$covres
summary(varxy_est)$corres
```

- ▶ Matriz do modelo estrutural

```
SVAR(x = varxy_est, estmethod = "scoring", Amat = amat, max.iter = 100, maxls = 1000, conv.crit = 1.0e-8)
summary(varxy_svar)
```

$$\text{VARCOV } B\hat{\varepsilon}_t = A\hat{e}_t$$

$$\begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \end{bmatrix}$$

Erros estruturais não tem correlação

VAR estrutural - exemplo simulado

- ▶ Comandos para análise:

```
plot(fevd(varxy_svar,n.ahead=10))
```

```
plot(irf(varxy_svar, impulse = "x", response = c("x", "y"), boot = T,ci=0.95))
```

- ▶ Resultado idêntico a estimação do VAR, por que?
 - ▶ Decomposição cholesky

VAR estrutural - exemplo do Canadá

- ▶ Variáveis em ln:

e - emprego

prod - PIB

rw - salário real da indústria

U - taxa de desemprego

- ▶ Comandos iniciais e criando a matrix:

```
data(Canada)
```

```
amat <- diag(4)
```

```
diag(amat) <- NA
```

```
amat[2, 1] <- NA
```

```
amat[4, 1] <- NA
```

VAR estrutural - exemplo do Canadá

- ▶ Estimação do modelo VAR

```
var.2c <- VAR(Canada, p = 2, type = "const")  
summary(var.2c)
```

- ▶ Matriz do modelo estrutural

```
var.Sc<-SVAR(x = var.2c , estmethod = "scoring", Amat = amat, max.iter = 100, maxls = 1000, conv.crit =  
1.0e-8)  
summary(var.Sc)
```


VAR estrutural - exemplo do Canadá

► Decomposição da variância

```
dv_var<-fevd(var.2c,n.ahead=10)
```

```
dv_svar<-fevd(var.Sc,n.ahead=10)
```

```
> dv_var$U
      e      prod      rw      U
[1,] 0.4636211 0.003008244 0.002479203 0.5308915
[2,] 0.7068777 0.008843922 0.003513667 0.2807647
[3,] 0.7787875 0.037185141 0.020355796 0.1636716
[4,] 0.7596609 0.079197860 0.046371393 0.1147699
[5,] 0.6886156 0.128139114 0.076164201 0.1070811
[6,] 0.5954733 0.178008698 0.103964487 0.1225535
[7,] 0.5026125 0.224371197 0.125721703 0.1472946
[8,] 0.4229416 0.264861489 0.140012873 0.1721840
[9,] 0.3611743 0.298826925 0.147393857 0.1926049
[10,] 0.3168767 0.326625990 0.149367650 0.2071296
```

```
> dv_svar$U
      e      prod      rw      U
[1,] 0.4636211 0.000000000 0.000000000 0.5363789
[2,] 0.7018101 0.01272233 0.001039517 0.2844281
[3,] 0.7645473 0.04833070 0.018740151 0.1683818
[4,] 0.7340369 0.09755527 0.049279254 0.1191286
[5,] 0.6507349 0.15238546 0.085685843 0.1111938
[6,] 0.5482755 0.20544902 0.119856736 0.1264187
[7,] 0.4514850 0.25193355 0.146244651 0.1503368
[8,] 0.3729842 0.29013367 0.163169301 0.1737128
[9,] 0.3156508 0.32044814 0.171635930 0.1922651
[10,] 0.2771297 0.34415317 0.173732009 0.2049851
```

VAR estrutural - exemplo do Canadá

► Função impulso


```
imp_var<-irf(var.2c, impulse = "e", response = c("prod", "rw"), boot = TRUE,ci=0.95)
```

```
plot(imp_var)
```

```
imp_svar<-irf(var.Sc, impulse = "e", response = c("prod", "rw"), boot = TRUE,ci=0.95)
```


```
plot(imp_svar)
```

Orthogonal Impulse Response from e



95 % Bootstrap CI, 100 runs

SVAR Impulse Response from e



95 % Bootstrap CI, 100 runs

Decomposição de Blanchard e Quah

- ▶ Forma de identificação com base em restrições determinadas pela teoria econômica.
- ▶ Imposição de restrições a respeito do comportamento de longo prazo de uma variável a partir do choque estrutural em uma outra variável.
- ▶ Suponha um vetor $X_t = (\Delta y_t, u_t)'$, em que y_t representa o logaritmo do produto, e u_t , a taxa de desemprego.
- ▶ As variáveis respondem a um vetor de choques dado por $\varepsilon_t = (\varepsilon_{t,d}, \varepsilon_{t,s})$.
- ▶ O produto é afetado por choques de demanda, e o desemprego, por choques de oferta.
- ▶ Os choques entre oferta e demanda não são correlacionados.
- ▶ Os choques de demanda têm efeitos temporários; os choques de oferta têm efeitos permanentes.

Decomposição de Blanchard e Quah

Normalizando $B = I$, considere

$$AX_t = \sum_{j=1}^p B_j X_{t-j} + \varepsilon_t,$$

em que $\text{var}(\varepsilon_t) = I$.

O modelo na forma reduzida fica:

$$X_t = \sum_{j=1}^p A^{-1} B_j X_{t-j} + A^{-1} \varepsilon_t = \sum_{j=1}^p \Phi_j X_{t-j} + e_t,$$

em que

$$A^{-1} B_j \equiv \Phi_j;$$

$$Ae_t = \varepsilon_t.$$

Há duas representações equivalentes de X_t , dependendo de o modelo partir da forma reduzida ou estrutural.

Decomposição de Blanchard e Quah

Partindo da forma reduzida, pode-se escrevê-lo como:

$$\begin{aligned} \left(I - \sum_{j=1}^p \Phi_j L^j \right) X_t &= e_t \implies X_t = \left(I - \sum_{j=1}^p \Phi_j L^j \right)^{-1} e_t \implies \\ X_t &= \left(\sum_{j=0}^{\infty} C_j L^j \right) e_t, \end{aligned} \quad (3)$$

em que

$$C_0 \equiv I;$$

$$\left(I - \sum_{j=1}^p \Phi_j L^j \right)^{-1} \equiv \sum_{j=0}^{\infty} C_j L^j;$$

$$\text{var}(e_t) = \Sigma.$$

Decomposição de Blanchard e Quah

Partindo da forma estrutural, obtém-se:

$$\begin{aligned} \left(A - \sum_{j=1}^p B_j L^j \right) X_t &= \varepsilon_t \implies X_t = \left(A - \sum_{j=1}^p B_j L^j \right)^{-1} \varepsilon_t \implies \\ X_t &= \left(\sum_{j=0}^{\infty} A_j L^j \right) \varepsilon_t, \end{aligned} \quad (4)$$

em que $\left(A - \sum_{j=1}^p B_j L^j \right)^{-1} \equiv \sum_{j=0}^{\infty} A_j L^j$.

Decomposição de Blanchard e Quah

Dado que $C_0 = I$, das equações (4) e (3) resultam as seguintes relações:

$$\begin{aligned}A_0 \varepsilon_t &= e_t \implies A_0 \varepsilon_{t-j} = e_{t-j}; \\A_j \varepsilon_{t-j} &= C_j e_{t-j} \implies A_j \varepsilon_{t-j} = C_j A_0 \varepsilon_{t-j} \therefore \\A_j &= C_j A_0, \quad j > 0.\end{aligned}$$

Além disso,

$$A_0 \varepsilon_t = e_t \implies A_0 \varepsilon_t = A^{-1} \varepsilon_t \implies A_0 = A^{-1}.$$

Essa relação é importante porque vão ser impostas restrições à matriz A_0 .

$$X_t = \left(\sum_{j=0}^{\infty} C_j L^j \right) e_t \quad (3)$$

$$X_t = \left(\sum_{j=0}^{\infty} A_j L^j \right) \varepsilon_t \quad (4)$$

Decomposição de Blanchard e Quah

Esse sistema de equações resulta, como já foi visto, em $\frac{n(n+1)}{2}$ equações. No caso bivariado, são explicitamente dadas por:

$$\begin{aligned} a_{11,0}^2 + a_{12,0}^2 &= \text{var}(e_1); \\ a_{11,0}a_{21,0} + a_{12,0}a_{22,0} &= \text{cov}(e_1, e_2); \\ a_{21,0}^2 + a_{22,0}^2 &= \text{var}(e_2). \end{aligned}$$

Decomposição de Blanchard e Quah

Aqui introduzem-se as restrições de longo prazo. Considere a equação (4) no modelo bivariado:

$$X_t = \sum_{j=0}^{\infty} \begin{bmatrix} a_{11,j} & a_{12,j} \\ a_{21,j} & a_{22,j} \end{bmatrix} \varepsilon_{t-j}.$$

Para que o choque de demanda não tenha efeitos de longo prazo sobre o produto, impõe-se:

$$\sum_{j=0}^{\infty} a_{11,j} = 0.$$

Tendo-se A_0 e C_j , este obtido da estimação do modelo reduzido, e valendo a relação $A_j = C_j A_0$, pode-se obter A_j .

Decomposição de Blanchard e Quah

Para operacionalizar o procedimento:

- ▶ Estime o modelo $VAR(p)$ e obtenha as matrizes $\hat{\Phi}_j$;
- ▶ Obtenha as matrizes C_j resolvendo:

$$\left(\sum_{j=0}^{\infty} \hat{C}_j L^j \right) = \left(I - \sum_{j=1}^p \hat{\Phi}_j L^j \right)^{-1} ;$$

- ▶ Sabendo que $A_j = C_j A_0$, imponha a restrição de longo prazo;
- ▶ Resolva o sistema de equações e encontre os coeficientes de A_0 .

Impondo a restrição de longo prazo:

$$\sum_{j=0}^{\infty} a_{11,j} = 0 = a_{11,0} \sum_{j=0}^{\infty} c_{11,j} + a_{21,0} \sum_{j=0}^{\infty} c_{12,j}.$$

Decomposição de Blanchard e Quah

- ▶ Uma vez obtida a matriz A_0 , podem-se recuperar os erros estruturais da seguinte relação:

$$\varepsilon_t = A_0^{-1} e_t,$$

e, assim, encontrar a função resposta ao impulso e a decomposição da variância.

- ▶ Não se devem associar choques de demanda ao componente transitório do ciclo de negócios, e choques de oferta, ao componente permanente de tendência. O componente transitório pode ocorrer devido a uma combinação de choques na oferta e demanda, assim como choques de oferta afetarão simultaneamente os componentes cíclico e permanente da economia.

Decomposição de Blanchard e Quah - exemplo

▶ Exemplo do Canadá

BQ(var.2c)

```
> BQ(var.2c)
```

```
SVAR Estimation Results:
```

```
=====
```

```
Estimated contemporaneous impact matrix:
```

	e	prod	rw	U
e	-0.007644	-0.28470	0.07374	-0.21234
prod	0.543663	0.21658	-0.03379	-0.28652
rw	0.082112	0.28588	0.71874	0.06162
U	0.129451	0.05668	-0.01039	0.24111

```
Estimated identified long run impact matrix:
```

	e	prod	rw	U
e	104.37	0.0000	0.00	0.0000
prod	45.35	5.1971	0.00	0.0000
rw	168.41	-2.1145	10.72	0.0000
U	-19.26	-0.4562	1.41	0.5331

Exercício

- ▶ Atualizando o arquivo:

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

- ▶ Estime o VAR I com defasagem 2
- ▶ Calcule a função resposta ao impulso do choque do câmbio e juros no IPCA livres com intervalo de confiança
- ▶ Calculem a decomposição da variância para o IPCA livres e administrado
- ▶ Estimem a causalidade de Granger entre o IPCA livres e o câmbio
 - ▶ Sugestão: estimem um VAR com estas duas variáveis, depois façam o teste
- ▶ Estimem um var estrutural, com a seguinte matriz de impactos correntes:
 - ▶ Livres afetam os administrados
 - ▶ Câmbio afeta os preços livres e administrados
- ▶ Calculem a resposta ao impulso do câmbio a inflação de livres e administrados
- ▶ Estime a decomposição da variância dos preços livres