

Séries de Tempo

Aula 8 - Modelos vetoriais autorregressivos

Regis A. Ely

Departamento de Economia
Universidade Federal de Pelotas

04 de setembro de 2020

Conteúdo

Modelo VAR

Causalidade de Granger

Exemplo no R

- Estacionariedade

- Identificação

- Estimação

- Diagnóstico

- Causalidade de Granger

- Funções impulso-resposta

- Previsão

Modelo VAR

- Modelos do tipo ADL ou ECM apenas consideram relações unidirecionais entre as variáveis e dependem da hipótese de exogeneidade estrita
- Modelos VAR são modelos de equações simultâneas em que é possível uma relação de *feedback* entre as variáveis endógenas, sendo todas tratadas de maneira simétrica¹
- Um modelo VAR(p) bivariado é descrito como:

$$\begin{aligned} Y_t &= c_1 + \phi_{11} Y_{t-1} + \dots + \phi_{1p} Y_{t-p} + \gamma_{11} X_{t-1} + \dots + \gamma_{1p} X_{t-p} + \varepsilon_{1t} \\ X_t &= c_2 + \phi_{21} Y_{t-1} + \dots + \phi_{2p} Y_{t-p} + \gamma_{21} X_{t-1} + \dots + \gamma_{2p} X_{t-p} + \varepsilon_{2t} \end{aligned}$$

¹Também é possível incluir variáveis exógenas em um modelo VAR.

Modelo VAR

- No modelo VAR os resíduos das equações ε_{1t} e ε_{2t} são ruídos brancos que podem ser correlacionados contemporaneamente
- Se as séries forem todas estacionárias, podemos estimar um modelo VAR em nível
- Se as séries forem não-estacionárias, podemos tirar diferenças até torná-las estacionárias e então estimar o modelo VAR²

²Na próxima aula veremos o caso em que as séries são não-estacionárias mas cointegradas.

Modelo VAR

- Para construção dos modelos VAR utilizamos o mesmo ciclo de identificação, estimação, diagnóstico e previsão
- Entretanto, inicialmente devemos definir quais variáveis do modelo serão endógenas e fracamente exógenas, normalmente com base na teoria ou literatura
- A identificação da ordem p a ser estimada requer a utilização de critérios como Akaike, BIC e Hannan-Quin
- A estimação pode ser realizada por máxima verossimilhança condicional, que é equivalente ao estimador de OLS

Modelo VAR

- O diagnóstico dos modelos VAR requer a utilização de uma versão multivariada do teste de Ljung-Box, uma vez que os resíduos de todas as equações devem ser conjuntamente não autocorrelacionados
- Após estimado o modelo e realizado o diagnóstico, pode-se proceder a análise dos coeficientes e exercícios de simulação e previsão
- A previsão dos valores para cada equação é construída de maneira recursiva, semelhante a estrutura dos modelos AR
- Adicionalmente, pode-se fazer uma análise de simulação chamada de impulso-resposta, onde avaliamos como um choque em uma das variáveis do modelo se difunde ao longo do tempo em outras variáveis

Causalidade de Granger

- Granger definiu causalidade em séries de tempo em termos de previsibilidade
- A variável X causa Granger a variável Y , com respeito a um dado conjunto de informação, se o presente de Y pode ser previsto mais eficientemente usando valores passados de X do que não incluindo estes valores
- A eficiência na previsão é medida através do do erro quadrático médio de previsão (EQM)
- Note que para verificar se X_t causa Granger Y_t devemos testar a significância conjunta de todos os coeficientes passados³ de X_t na equação de Y_t

³Se tivermos mais do que duas equações no modelo VAR será necessário testar mais coeficientes conjuntamente para garantir causalidade.

Causalidade de Granger

Defina $\{A_t, t = 0, \pm 1, \pm 2, \dots\}$ o conjunto de toda a informação disponível até o instante t , e considere $\bar{A}_t = \{A_s : s < t\}$, $\bar{\bar{A}}_t = \{A_s : s \leq t\}$ e definições análogas para \bar{X}_t e \bar{Y}_t , então:

1. X_t causa Granger Y_t ($X_t \rightarrow Y_t$) se $EQM(Y_t | \bar{A}_t) < EQM(Y_t | \bar{A}_t - \bar{X}_t)$, ou seja, Y_t pode ser melhor previsto usando o passado de X_t
2. X_t causa Granger Y_t instantaneamente ($X_t \Rightarrow Y_t$)⁴ se $EQM(Y_t | \bar{A}_t, \bar{X}_t) < EQM(Y_t | \bar{A}_t)$, ou seja, Y_t pode ser melhor previsto utilizando o valor presente de X_t

Dizemos que há *feedback* se tanto X_t causa Granger Y_t quanto Y_t causa Granger X_t

⁴Se $(X_t \Rightarrow Y_t)$ então automaticamente $(Y_t \Rightarrow X_t)$.

Exemplo no R

Para estimação de modelos VAR vamos utilizar o pacote `vars` e a base de dados `uschange` do pacote `fpp2`, que contém dados macroeconômicos trimestrais dos Estados Unidos durante os anos de 1960 a 2016:

```
library(vars)
library(fpp2)
base <- uschange[, 1:2]
```

Iremos trabalhar apenas com as duas primeiras variáveis da base, a taxa de crescimento percentual do consumo agregado e da renda disponível

Exemplo no R

Vamos inicialmente visualizar as observações iniciais e o gráfico das duas séries:

```
head(base)
```

```
##           Consumption      Income
## 1970 Q1      0.6159862  0.9722610
## 1970 Q2      0.4603757  1.1690847
## 1970 Q3      0.8767914  1.5532705
## 1970 Q4     -0.2742451 -0.2552724
## 1971 Q1      1.8973708  1.9871536
## 1971 Q2      0.9119929  1.4473342
```

```
autoplot(base)
```

Exemplo no R



Estacionariedade

A primeira etapa antes de estimar as relações dinâmicas entre consumo e renda através do modelo VAR é checar a estacionariedade das séries. Para isso, utilizamos o teste ADF através da função `ur.df` em cada uma das séries:

```
adf_cons <- ur.df(  
  base[,1], type = "drift", lags = 5,  
  selectlags = "AIC"  
)  
summary(adf_cons)
```

Estacionariedade

```
...
## Coefficients:
##           Estimate Std. Error t value Pr(>|t|)
## (Intercept)  0.29125   0.07899   3.687 0.000302 ***
## z.lag.1      -0.39220   0.08796  -4.459 1.46e-05 ***
## z.diff.lag1 -0.35360   0.08814  -4.012 8.88e-05 ***
## z.diff.lag2 -0.20654   0.07190  -2.873 0.004569 **
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.586 on 177 degrees of freedom
## Multiple R-squared:  0.3709, Adjusted R-squared:  0.3603
## F-statistic: 34.79 on 3 and 177 DF,  p-value: < 2.2e-16
##
##
## Value of test-statistic is: -4.4591 9.9434
##
## Critical values for test statistics:
##           1pct  5pct 10pct
## tau2 -3.46 -2.88 -2.57
## phi1  6.52  4.63  3.81
...

```

Estacionariedade

```
...  
## Coefficients:  
##           Estimate Std. Error t value Pr(>|t|)  
## (Intercept)  0.70996   0.10458   6.788 1.63e-10 ***  
## z.lag.1      -1.01010   0.11028  -9.159 < 2e-16 ***  
## z.diff.lag  -0.08954   0.07408  -1.209   0.228  
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
##  
## Residual standard error: 0.9305 on 178 degrees of freedom  
## Multiple R-squared:  0.5589, Adjusted R-squared:  0.554  
## F-statistic: 112.8 on 2 and 178 DF,  p-value: < 2.2e-16  
##  
##  
## Value of test-statistic is: -9.1592 41.9531  
##  
## Critical values for test statistics:  
##           1pct  5pct 10pct  
## tau2 -3.46 -2.88 -2.57  
## phi1  6.52  4.63  3.81  
...
```

Estacionariedade

- Para as duas séries podemos rejeitar a hipótese nula de raíz unitária do teste ADF
- Assim, temos duas séries estacionárias e podemos proceder a estimação de um modelo VAR(p) bivariado
- Para a identificação da ordem do coeficiente p podemos utilizar os critérios de Akaike, Schwarz, Hannan-Quin, etc.

Identificação

A função `VARselect` indica o número de defasagens que minimiza os critérios de identificação:

```
VARselect(base, lag.max = 5)
```

```
## $selection
## AIC(n)  HQ(n)  SC(n) FPE(n)
##      5      1      1      5
##
## $criteria
##           1           2           3           4           5
## AIC(n) -1.3950537 -1.3933323 -1.430640 -1.4416669 -1.4505174
## HQ(n)  -1.3522342 -1.3219665 -1.330728 -1.3132084 -1.2935126
## SC(n)  -1.2894271 -1.2172880 -1.184178 -1.1247871 -1.0632198
## FPE(n)  0.2478212  0.2482536  0.239174  0.2365714  0.2345181
```


Estimação

Com o objetivo de parcimoniosidade neste exercício, vamos estimar um modelo VAR(1) bivariado, conforme o indicado pelo critério bayesiano de Schwarz

```
var_model <- vars::VAR(base, p = 1, type = "const")  
summary(var_model)
```

A função VAR do pacote vars estima o modelo considerando todas as variáveis da base como endógenas e no argumento type é possível incluir constantes ou tendências

Estimação

```
...
## Estimation results for equation Consumption:
## =====
## Consumption = Consumption.l1 + Income.l1 + const
##
##           Estimate Std. Error t value Pr(>|t|)
## Consumption.l1  0.29646    0.07485   3.961 0.000107 ***
## Income.l1      0.09434    0.05267   1.791 0.074908 .
## const          0.45811    0.06993   6.551 5.63e-10 ***
## ---
##
## Estimation results for equation Income:
## =====
## Income = Consumption.l1 + Income.l1 + const
##
##           Estimate Std. Error t value Pr(>|t|)
## Consumption.l1  0.51509    0.10728   4.801 3.27e-06 ***
## Income.l1      -0.25474    0.07549  -3.375 0.000903 ***
## const          0.51462    0.10024   5.134 7.21e-07 ***
## ---
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
...

```

Estimação

- O modelo indica que a renda passada tem algum potencial para prever o consumo, sendo significativa ao nível de 10%
- Já o consumo passado prevê fortemente a renda futura, devido ao fato que o aumento das vendas contribui para aumentar a renda da economia
- O consumo tem um componente autorregressivo significativo, indicando persistência nos hábitos de consumo
- Já a renda tem um coeficiente autorregressivo negativo, indicando uma tendência de reversão a média

Diagnóstico

- Para avaliar a qualidade da especificação do modelo devemos analisar os resíduos através de um teste de autocorrelação multivariado
- Este teste pode ser realizado através da função `serial.test` no R, sendo que a rejeição da hipótese nula indica autocorrelação residual
- Assim, aplicaremos o teste as defasagens 10 e 15

Diagnóstico

```
serial.test(var_model, lags.pt=10, type="PT.asymptotic")
```

```
##  
## Portmanteau Test (asymptotic)  
##  
## data: Residuals of VAR object var_model  
## Chi-squared = 49.102, df = 36, p-value = 0.07144
```

```
serial.test(var_model, lags.pt=15, type="PT.asymptotic")
```

```
##  
## Portmanteau Test (asymptotic)  
##  
## data: Residuals of VAR object var_model  
## Chi-squared = 56.858, df = 56, p-value = 0.4429
```

Diagnóstico

- Em geral, quando utilizamos um número maior de defasagens no teste os resíduos parecem não estar correlacionados
- Entretanto, o teste com apenas 10 defasagens rejeita a hipótese nula de não autocorrelação ao nível de 10%
- Para resolver essa possível autocorrelação residual em defasagens mais baixas podemos acrescentar mais defasagens no nosso modelo VAR
- Neste exemplo, ficaremos com o modelo VAR(1) com o objetivo de manter a parcimoniosidade

Causalidade de Granger

- Em um modelo VAR(1), o teste de causalidade de Granger é equivalente ao p-valor dos coeficientes das regressões do modelo VAR
- Entretanto, quando temos um número maior de defasagens, para avaliar a causalidade de Granger devemos realizar um teste conjunto de significância de todos os coeficientes
- Podemos realizar este teste através da função `causality` no 'R'
- Como temos duas variáveis endógenas no nosso modelo, devemos realizar dois teste, o primeiro com o consumo como variável causal e o segundo com a renda como variável causal

Causalidade de Granger

```
causality(var_model, cause = "Consumption")
```

```
## $Granger
##
## Granger causality H0: Consumption do not Granger-cause Income
##
## data: VAR object var_model
## F-Test = 23.053, df1 = 1, df2 = 366, p-value = 2.301e-06
##
##
## $Instant
##
## H0: No instantaneous causality between: Consumption and Income
##
## data: VAR object var_model
## Chi-squared = 24.227, df = 1, p-value = 8.561e-07
```


Causalidade de Granger

```
causality(var_model, cause = "Income")
```

```
## $Granger
##
## Granger causality H0: Income do not Granger-cause Consumption
##
## data: VAR object var_model
## F-Test = 3.2085, df1 = 1, df2 = 366, p-value = 0.07408
##
##
## $Instant
##
## H0: No instantaneous causality between: Income and Consumption
##
## data: VAR object var_model
## Chi-squared = 24.227, df = 1, p-value = 8.561e-07
```

Causalidade de Granger

- Assim como identificado nos resultados das regressões do modelo VAR, o consumo granger causa a renda com significância de 1%
- Entretanto, a renda granger causa o consumo apenas com significância de 10%
- Para visualizar a dinâmica deste efeitos causais entre as duas variáveis podemos plotar a função impulso-resposta
- Esta função simula um choque em uma das variáveis e calcula a resposta ao longo do tempo que este choque causa em outra variável

Funções impulso-resposta


No R podemos estimar a função de impulso-resposta através do comando `irf`, utilizando como argumento o modelo estimado, a variável impulso e a variável resposta:

```
impulse_cons <- irf(  
  var_model,  
  impulse = "Consumption",  
  response = "Income"  
)  
plot(impulse_cons)
```

Após estimar a função impulso-resposta do consumo na renda, podemos plotá-la utilizando a comando `plot`

Funções impulso-resposta

Orthogonal Impulse Response from Consumption



95 % Bootstrap CI, 100 runs


Funções impulso-resposta

De maneira semelhante, vamos calcular a função impulso-resposta da renda no consumo:

```
impulse_inc <- irf(  
  var_model,  
  impulse = "Income",  
  response = "Consumption"  
)  
plot(impulse_inc)
```

Funções impulso-resposta

Orthogonal Impulse Response from Income



95 % Bootstrap CI, 100 runs

Previsão

Por fim, podemos fazer a previsão das duas variáveis endógenas utilizando o modelo VAR estimado através da função `forecast`:

```
var_fc <- forecast(var_model, h = 4)
var_fc
```

E plotar o resultado final:

```
plot(var_fc)
```

Previsão

Consumption

##		Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
##	2016 Q4	0.7352263	-0.05100310	1.521456	-0.4672078	1.937660
##	2017 Q1	0.7445835	-0.09384705	1.583014	-0.5376854	2.026852
##	2017 Q2	0.7456724	-0.09982648	1.591171	-0.5474065	2.038751
##	2017 Q3	0.7468792	-0.09958950	1.593348	-0.5476829	2.041441
##						

Income

##		Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
##	2016 Q4	0.7261971	-0.4006792	1.853073	-0.9972115	2.449606
##	2017 Q1	0.7083358	-0.4859362	1.902608	-1.1181456	2.534817
##	2017 Q2	0.7177056	-0.4842089	1.919620	-1.1204640	2.555875
##	2017 Q3	0.7158796	-0.4869998	1.918759	-1.1237657	2.555525

Previsão

Forecasts from VAR(1)

