

4

Critérios de seleção e estimação do modelo

A primeira seção deste capítulo mostra os métodos para a seleção do modelo VAR. Na segunda, apresentamos o procedimento de estimação do modelo sujeito às restrições de curto-prazo e longo-prazo, por meio do algoritmo *switching*.

4.1

Critérios de seleção do modelo

Na seleção do modelo, utilizamos dois critérios de informação para identificar a ordem do VAR: o critério de seleção tradicional, $IC(p)$, e o critério informação modificado, $IC(p, s)$.

Caso se considere o critério de seleção $IC(p)$ na seleção da ordem p do modelo VAR, a estimação do modelo segue os passos abaixo:

1. Estimar p usando os critérios de informação usuais: Akaike (AIC), Schwarz (SC) e Hanna-Quinn (HQ). A ordem p escolhida é aquela que minimiza os critérios de informação.
2. Identificada a ordem p no passo 1, encontra-se o número de vetores de cointegração r por meio do teste de Johansen. As matrizes de coeficientes do termo de longo-prazo e o posto do espaço de cointegração são estimados mediante a utilização do procedimento FIML como mostrado em Johansen (1991).
3. Condicionado aos resultados da análise de cointegração, estima-se o VECM. Finalmente, calculamos os valores para vários horizontes de previsão.

Neste trabalho, investiga-se o desempenho de $IC(p)$ e $IC(p, s)$ quando as restrições de cointegração e do tipo WF são consideradas no modelo.

Vahid e Issler (2002) analisaram modelo VAR estacionário em covariância com restrições do tipo SCCF. Os autores mostraram que o uso do critério $IC(p, s)$ apresenta desempenho superior a $IC(p)$ na seleção da ordem p do

modelo VAR. Guillen et. al (2005) avaliaram modelo VAR não estacionário, com cointegração e restrições do tipo SCCF, e mostraram que usar $IC(p, s)$ representa desempenho superior a usar $IC(p)$ na seleção da ordem p do modelo VAR. Neste trabalho, relaxamos as restrições do tipo SCCF para WF para analisar o desempenho de $IC(p)$ e $IC(p, s)$ na seleção do modelo. Uma das questões relevantes a serem respondidas neste trabalho é se o desempenho de $IC(p, s)$ é superior ou não ao de $IC(p)$.

Os critérios de informação modificados $IC(p, s)$ são:

$$AIC(p, s) = \sum_{i=n-s+1}^T \ln(1 - \lambda_i^2(p)) + \frac{2}{T} \times [\text{número de parâmetros}] \quad (4-1)$$

$$HQ(p, s) = \sum_{i=n-s+1}^T \ln(1 - \lambda_i^2(p)) + \frac{2 \ln(\ln T)}{T} [\text{número de parâmetros}] \quad (4-2)$$

$$SC(p, s) = \sum_{i=n-s+1}^T \ln(1 - \lambda_i^2(p)) + \frac{\ln T}{T} [\text{número de parâmetros}] \quad (4-3)$$

$$\begin{aligned} & \text{número de parâmetros} \\ &= [n \times (n \times (p - 1)) + n \times r] - [s \times (n \times (p - 1)) + (n - s)] \end{aligned}$$

O número de parâmetros é calculado pela diferença do número total de parâmetros do VECM (i.e., $n^2 \times (p - 1) + nr$), para um dado r e p , e o número de restrições provenientes das características comuns impostas por $s \times (n \times (p - 1)) - s \times (n - s)$. Para cada p considerado, calculamos os autovalores λ_i .

A seguir, apresenta-se o procedimento de seleção dos valores p e s mediante a utilização do critério $IC(p, s)$:

1. Primeiro, assume-se que não existe restrição de cointegração, ou seja, $r = n$ (ver Hecq, 2006a). Fixamos os parâmetros p e s do modelo (3-10) (por exemplo, $p = 2$ e $s = 1$) e em seguida calculamos os autovalores λ_i $i = 1, 2, \dots, n$ por meio do programa $cancorr(\Delta y_t, X_{t-1} \mid y_{t-1})$.

2. Mantendo constante o parâmetro p escolhido em 1, considera-se outro valor para s (por exemplo, $s = 2$), repete-se o passo 1 para encontrar novos autovalores λ_i $i = 1, 2, \dots, n$. Portanto, a cada p fixo, encontra-se um conjunto de autovalores para cada novo valor s .

3. Para cada p e s escolhidos nos passos 1 e 2, obtém-se um conjunto de autovalores a ser usado nas equações (4-1) a (4-3). Finalmente, escolhemos os valores de p e s que minimizem $IC(p, s)$, dado pelas equações (4-1) a (4-3).

4. O próximo passo consiste em encontrar o número de vetores de cointegração r . Se o valor s escolhido no passo anterior é igual a n (i.e., $s = n$), usamos o programa *cancorr*($\Delta y_t, y_{t-1} \mid X_{t-1}$) para encontrar o número de vetores de cointegração¹. No caso em que $s < n$, adotamos a seguinte estratégia. O modelo de regressão de posto-reduzido é estimado:

$$u_0 = G u_1 + \varepsilon_t \quad (4-4)$$

em que u_0 e u_1 são os resíduos das regressões Δy_t e X_{t-1} em y_{t-1} respectivamente. Seja, $G = C\Theta$ em que $\Theta = (\Theta_1, \dots, \Theta_{p-1})$ é de dimensão $(n-s) \times n(p-1)$ e C uma matriz de dimensão $n \times (n-s)$. A regressão (4-4) é estimada por meio do procedimento de FIML como usado por Vahid e Issler (2002). Assim, os parâmetros estimados \hat{C} e $\hat{\Theta} = (\hat{\Theta}_1, \dots, \hat{\Theta}_{p-1})$ são obtidos.

Substituindo estes parâmetros em:

$$W_{t-1} = [\hat{\Theta}_1 \Delta y_{t-1}, \hat{\Theta}_2 \Delta y_{t-2}, \dots, \hat{\Theta}_{p-1} \Delta y_{t+p-1}]$$

é possível encontrar os autovalores λ_i por meio do programa *cancorr*($\Delta y_t, y_{t-1} \mid W_{t-1}$) para logo encontrar r usando a estatística do teste de Johansen como mostrado em (3-13).

5. Finalmente, tendo (p, s) , estima-se o modelo por meio do algoritmo *switching*, como mostrado no capítulo seguinte.

Note que ao adotar este procedimento, a seleção do número de vetores de cointegração r é realizada após a seleção dos parâmetros p e s . Portanto, estamos invertendo o procedimento seguido por Vahid e Engle na qual o primeiro procedimento era a seleção do número de relações de cointegração

¹Este é o procedimento clássico do teste de cointegração de Johansen.

r . Isto pode resultar numa vantagem especialmente quando os valores de r são sub-estimados.

Poucos autores dedicam-se a estudar como selecionar a ordem do modelo VAR quando este é sujeito às restrições de cointegração e de características cíclicas comuns. Como mencionado acima, Vahid e Issler (2002) sugerem o uso de $IC(p, s)$ para escolher simultaneamente os parâmetros p e s num modelo VAR estacionário em covariâncias sujeito à restrição de SCCF. Guillén, et. al (2005) aplicam o uso de $IC(p, s)$ num modelo VAR não estacionário com restrições de cointegração e SCCF. Como nenhum trabalho analisa a ordem do VAR com restrições de cointegração e do tipo WF, os resultados desta pesquisa tendem a contribuir de modo relevante à literatura.

4.2

Estimação do VECM com WF usando o algoritmo switching

Para estimar o modelo VAR sujeito às restrições de cointegração e do tipo WF, utiliza-se o algoritmo *switching* como considerado por Hecq (2006b).

Considere o VECM dado por:

$$\Delta y_t = \alpha \beta' y_{t-1} + \tilde{\beta}_\perp \Psi X_{t-1} + \varepsilon_t \quad (4-5)$$

A seguir, apresentamos a descrição do algoritmo *switching* em quatro passos:

Passo1 : Estimação dos vetores de cointegração β .

Usando o par ótimo (\bar{p}, \bar{s}) encontrado por meio do critério (4-1), (4-2) ou (4-3), estima-se β (e seu posto, $r = \bar{r}$) mediante o teste de cointegração de Johansen.

Passo2 : Estimação de $\tilde{\beta}_\perp$ e Ψ .

Tomando $\hat{\beta}$, contido no primeiro passo, os parâmetros $\tilde{\beta}_\perp$ e Ψ são estimados. Para tal, rodamos as regressões de Δy_t e X_{t-1} em $\hat{\beta}' y_{t-1}$. Os resíduos dessas regressões são chamados de u_0 e u_1 , respectivamente. Portanto, obtém-se a seguinte regressão de posto-reduzido:

$$u_0 = \tilde{\beta}_\perp \Psi u_1 + \varepsilon_t \quad (4-6)$$

em que a matriz Ψ , de dimensão $(n - \bar{s}) \times n(\bar{p} - 1)$, pode ser escrita como $\Psi = (C_1, \dots, C_{(\bar{p}-1)})$ e a matriz $\tilde{\beta}_\perp$, ortogonal a $\tilde{\beta}$, é de dimensão $n \times (n - \bar{s})$. A regressão (4-6) é estimada por FIML.

Passo3: Estimação da Função de Máxima Verossimilhança (MV).

Dados os parâmetros estimados nos passos 1 e 2, utiliza-se algoritmo recursivo para estimar a função de MV. Calculam-se os autovalores associados a $\hat{\Psi}$, $\hat{\lambda}_i^2$ $i = 1, \dots, \bar{s}$ e a matriz de resíduos $\sum_{\bar{r}, s=\bar{s}}^{\max}$. A função de MV é computada como:

$$L_{\max, \bar{r} < n, s = \bar{s}}^0 = -\frac{T}{2} \left[\ln \left| \sum_{\bar{r} < n, s = \bar{s}}^{\max} \right| - \sum_{i=1}^{\bar{s}} \ln (1 - \hat{\lambda}_i^2) \right] \quad (4-7)$$

se $\bar{r} = n$ ao invés de utilizar (4-7) usamos a função: $L_{\max, r=n, s=\bar{s}} = -\frac{T}{2} \ln \left| \sum_{\bar{r}=n, s=\bar{s}}^{\max} \right|$. Neste caso, o logaritmo do determinante da matriz de covariância, $\ln \left| \sum_{\bar{r}=n, s=\bar{s}}^{\max} \right|$, é calculado como:

$$\ln \left| \sum_{\bar{r}=n, s=\bar{s}}^{\max} \right| = \ln |m_{00} - m_{01}m_{11}^{-1}m_{10}| - \sum_{i=1}^{\bar{s}} \ln (1 - \hat{\lambda}_i^2)$$

em que m_{ij} se refere às matrizes de momentos cruzados obtidos por mínimos quadrados das regressões de Δy_t e X_{t-1} em y_{t-1} . Quando $\bar{r} = n$, não é necessário seguir um procedimento iterativo na estimação dos parâmetros tendo em vista que o espaço R^n é gerado pelos vetores de cointegração.

Passo4: Reestimação de β .

Para obter valores mais apropriados dos parâmetros, reestima-se a matriz β usando o programa *CanCorr* $[\Delta y_t, y_{t-1} | \hat{\Psi}' X_{t-1}]$. Como o novo $\hat{\beta}$, segue-se o passo 2 para reestimar $\tilde{\beta}_\perp$ e Ψ . Portanto, calcula-se novo valor para a função de MV é calculado adotando o passo 3. Desta forma, obtemos $L_{\max, r=\bar{r}, s=\bar{s}}^1$ para calcular $\Delta L = (L_{\max, r=\bar{r}, s=\bar{s}}^1 - L_{\max, r=\bar{r}, s=\bar{s}}^0)$.

Os passos 1 até 4 são repetidos até escolher os parâmetros apropriados $\tilde{\beta}_\perp$ e Ψ mediante a convergência da função de MV (i.e., $\Delta L < 10^{-7}$). Por

fim, obtemos os parâmetros ótimos \bar{p} , \bar{r} e \bar{s} elementos essenciais na previsão do modelo.