

6 Previsão

6.1 Introdução

Considera-se importante a previsão pois serve aos usuários como guia de decisão. Neste capítulo, investiga-se o desempenho de previsão de três modelos, mediante a utilização de diferentes funções perda.

6.2 Modelos

Analisamos o desempenho dos seguintes três tipos de especificações:

- 1.- O modelo VAR com restrições de cointegração ou *VECM irrestrito*;
- 2.- O modelo VAR com restrições de cointegração e do tipo WF, denominado de *VECM restrito*; e
- 3.- O modelo VAR sem restrições ou *VAR em nível*.

Observe que o processo gerador de dados corresponde ao segundo modelo, ou seja, um modelo VAR com restrições de cointegração e do tipo WF, e que o primeiro e o terceiro modelos estão mal especificados.

6.3 Medidas do desempenho da previsão

A função erro quadrático médio de previsão (Mean Square Forecasting Error - MSFE) para um processo univariado y_t é definido como:

$$E \left(y_{t+h} - y_{t+h}^f \right)^2 = E \left(\varepsilon_{t+h}^2 \right) = \left\{ E \left(\varepsilon_{t+h} \right)^2 + var \left(\varepsilon_{t+h} \right) \right\}$$

em que y_{t+h}^f é a previsão h -passos à frente e $\varepsilon_{t+h} = y_{t+h} - y_{t+h}^f$ o erro de previsão. No contexto multivariado, a matriz de MSFE é:

$$MSFE = E(\varepsilon_{t+h}\varepsilon'_{t+h})$$

$\varepsilon_{t+h} = (\varepsilon_{t+h}^1, \dots, \varepsilon_{t+h}^n)'$ para n variáveis e previsões h -passos à frente.

A função MSFE é tradicionalmente usada¹ como medida do desempenho da previsão em vários horizontes. Alguns autores, como Clements e Hendry (1993), criticam esta medida haja vista não ser esta função invariante a transformações lineares do modelo.

Para comparar o desempenho de previsão, destacamos as três funções perda usadas²: i) o traço do erro quadrático médio de previsão – TMSFE; ii) o determinante do erro quadrático médio de previsão ($|MSFE|$); e iii) o segundo momento generalizado erro de previsão (*Generalized Forecast Error Second Moment* - GFESM).

1. *O traço do erro quadrático médio de previsão* - TMSFE A função perda TMSFE é a soma dos erros quadráticos médios de previsão de cada variável:

$$TMSFE = tr [E(\varepsilon_{t+h}\varepsilon'_{t+h})]$$

2. *O determinante do erro quadrático médio de previsão* ($|MSFE|$)

$$|MSFE| = |E(\varepsilon_{t+h}\varepsilon'_{t+h})|$$

3. *O segundo momento generalizado erro de previsão* (*Generalized Forecast Error Second Moment* - GFESM)

Clements e Hendry (1993) propuseram a função perda:

$$GFESM = |E(\varepsilon_H\varepsilon'_H)|$$

em que, $\varepsilon_H = (\varepsilon'_{t+1}, \varepsilon'_{t+2}, \dots, \varepsilon'_{t+H-1}, \varepsilon'_{t+H})'$ é o vetor de erros de previsão até H passos à frente. A vantagem do GFESM consiste em ser uma função invariante a transformações lineares.

¹Engle e Yoo (1987) e Brandner e Kunst (1990).

²Para maiores detalhes, veja Vahid e Issler (2002).

Uma forma de avaliar o desempenho de previsão dos modelos seria calcular, a cada realização, as funções perda e em seguida tomar a média sobre todas as realizações. No entanto, ao utilizar diferentes processos geradores de dados, existe uma complicação. O cálculo da média dos diferentes processos geradores de dados não é apropriado pois os erros de previsão dos processos geradores de dados não apresentam a mesma matriz variância covariância. Makridakis et al. (1982) e Thompson (1990) sugeriram o uso da função logaritmo da razão das funções perda de dois modelos diferentes nas formas abaixo:

$$1) \log \left(\frac{\text{trace}MSFE_{\text{modelo1}}}{\text{trace}MSFE_{\text{modelo2}}} \right);$$

$$2) \log \left(\frac{|MSFE_{\text{modelo1}}|}{|MSFE_{\text{modelo2}}|} \right);$$

$$3) \log \left(\frac{GFESM_{\text{modelo1}}}{GFESM_{\text{modelo2}}} \right).$$

Estas funções representam os ganhos percentuais na previsão de um modelo em relação a outro. O cálculo das funções (1) e (2) acima é feita a cada realização enquanto que calcula-se o logaritmo da função (3) após a avaliação da razão das funções perda em todas as realizações consideradas.