

## Referências Bibliográficas

- [1] BOX, G.; JENKINS, G. ; REINSEL, G.. **Time Series Analysis, Forecasting and Control**. Prentice Hall, New Jersey, 1994.
- [2] BREIMAN, L.; FRIEDMAN, J.; OLSHEN, R. ; STONE, C. J.. **Classification and Regression Trees**. Belmont Wadsworth Int. Group, New York, 1984.
- [3] CHAN, K.; TONG, H.. **On estimating thresholds in autoregressive models**. Journal of Time Series Analysis, 7:179–190, 1986.
- [4] FAMA, E.. **Random walks in stock market prices**. Financial Analysts Journal, 51:75–80, 1965.
- [5] GREENE, W. H.. **Econometrics Analysis**. Macmillan Publishing Company, New York, 1993.
- [6] GRANGER, C.; TERÄSVIRTAL, T.. **Modelling Nonlinear Economic Relationships**. Oxford University Press, Oxford, 1993.
- [7] HAMILTON, J.. **Time Series Analysis**. Princeton University Press, Princeton, 1994.
- [8] CORRÊA DA ROSA, J.. **Modelos de Regressão com Transição Suave Estruturados por Árvores**. PhD thesis, PUC-Rio, Departamento de Engenharia Elétrica, Rio de Janeiro, 2005.
- [9] KUAN, C.-M.; LIM, T.. **Forecasting exchange rates using feedforward and recurrent neural networks**. Journal of Applied Econometrics, 10:347–364, 1994.
- [10] LJUNG, G.; BOX, G.. **On a measure of lack of fit in time series models**. Biometrika, 66:265–270, 1979.
- [11] LEVENBERG, K.. **A method for the solution of certain problems in last squares**. Quarterly of Applied Mathematics, 2:164–168, 1944.

- [12] LUUKKONEN, R.; SAIKKONEN, R. ; TERÄSVIRTA, T.. **Testing linearity against smooth transition autoregressive models.** *Biometrika*, 75:491–499, 1988.
- [13] MEDEIROS, M.; VEIGA, A.. **A flexible coefficient smooth transition time series model.** Working Paper Series in Economics and Finance, 360, 2000.
- [14] MARQUARDT, D.. **An algorithm for least-squares estimation of nonlinear parameters.** *SIAM Journal on Applied Mathematics*, 11:431–441, 1963.
- [15] TERÄSVIRTA, T.. **Specification, estimation, and evaluation of smooth transition autoregressive models.** *Journal of the American Statistical Association*, 89:208–218, 1994.
- [16] TONG, H.. **On a threshold model.** In: Chen, C. H., editor, *IN PATTERN RECOGNITION AND SIGNAL PROCESSING*, volumen 5. Sijhoff Noordhoff, Amsterdam, 1978.
- [17] TONG, H.; LIM, K.. **Threshold autoregression, limit cycles and cyclical data.** *Journal of the Royal Statistical Society, Series B, Methodological*, 42:245–292, 1980.
- [18] TONG, H.. **Threshold models in non-linear time series analysis.** In: Verlag, S., editor, *SPRINGER LECTURE NOTES IN STATISTICS*, volumen 21. Springer Verlag, 1983.
- [19] ZADEH, L.. **Fuzzy sets.** *Information and Control*, 8:338–353, 1965.
- [20] VAN DIJK, D.; T. TERÄSVIRTA ; FRANSES, P.. **Smooth transition autoregressive models.** Working Paper Series in Economic and Finance, 380, 2000.
- [21] VAN DIJK, D.; FRANSES, P.. **Modelling multiple regimes in the business cycle.** *Macroeconomic Dynamics*, 3:311–340, 1999.

## A

### Aproximação de Taylor para a Função Logística

Para resolver o problema de identificação ocorrido no teste ML, sugere-se a aproximação de Taylor de terceira ordem ao redor de  $\gamma = 0$  para a função logística usada

$$G(s_t, \gamma, c) = \frac{e^{-\gamma(s_t-c)}}{1 + e^{-\gamma(s_t-c)}}, \quad \gamma > 0 \quad (\text{A-1})$$

onde  $\gamma$  é o parâmetro que determina o grau de suavidade da transição e  $c$  é o limiar entre dois regimes.

A equação geral da aproximação pelo polinômio de Taylor de terceira ordem ao redor de um valor  $a$  é dada por

$$f(x) = f(a) + \left. \frac{df}{dx} \right|_{x=a} \cdot (x-a) + \frac{1}{2!} \left. \frac{d^2f}{dx^2} \right|_{x=a} \cdot (x-a)^2 + \frac{1}{3!} \left. \frac{d^3f}{dx^3} \right|_{x=a} \cdot (x-a)^3 + R_3(x) \quad (\text{A-2})$$

Considerando (A-1), a aproximação fica na forma a seguir

$$\begin{aligned} G(s_t, \gamma, c) &= G(s_t, \gamma, c) \Big|_{\gamma=0} + \left. \frac{dG}{d\gamma} \right|_{\gamma=0} (\gamma - 0) + \frac{1}{2!} \left. \frac{d^2G}{d\gamma^2} \right|_{\gamma=0} (\gamma - 0)^2 + \\ &\quad + \frac{1}{3!} \left. \frac{d^3G}{d\gamma^3} \right|_{\gamma=0} (\gamma - 0)^3 + R_3(\gamma) \quad (\text{A-3}) \\ &= \frac{1}{2} + \frac{1}{4} \gamma(-s_t + c) - \frac{1}{48} \gamma^3 (-s_t + c)^3 + R_3(\gamma) \end{aligned}$$

onde

$$\begin{aligned}
 \left. \frac{dG}{d\gamma} \right|_{\gamma=0} &= \left. \frac{(-s_t + c) e^{-\gamma(st-c)}}{1 + e^{-\gamma(st-c)}} \right|_{\gamma=0} - \left. \frac{(e^{-\gamma(st-c)})^2 (-s_t + c)}{(1 + e^{-\gamma(st-c)})^2} \right|_{\gamma=0} = \frac{1}{4}(-s_t + c) \\
 \left. \frac{d^2G}{d\gamma^2} \right|_{\gamma=0} &= \left. \frac{(-s_t + c)^2 e^{-\gamma(st-c)}}{1 + e^{-\gamma(st-c)}} \right|_{\gamma=0} - 3 \left. \frac{(-s_t + c)^2 (e^{-\gamma(st-c)})^2}{(1 + e^{-\gamma(st-c)})^2} \right|_{\gamma=0} + \\
 &\quad + 2 \left. \frac{(e^{-\gamma(st-c)})^3 (-s_t + c)^2}{(1 + e^{-\gamma(st-c)})^3} \right|_{\gamma=0} = 0 \\
 \left. \frac{d^3G}{d\gamma^3} \right|_{\gamma=0} &= \left. \frac{(-s_t + c)^3 e^{-\gamma(st-c)}}{1 + e^{-\gamma(st-c)}} \right|_{\gamma=0} - 7 \left. \frac{(-s_t + c)^3 (e^{-\gamma(st-c)})^2}{(1 + e^{-\gamma(st-c)})^2} \right|_{\gamma=0} + \\
 &\quad + 12 \left. \frac{(-s_t + c)^3 (e^{-\gamma(st-c)})^3}{(1 + e^{-\gamma(st-c)})^3} \right|_{\gamma=0} - 6 \left. \frac{(e^{-\gamma(st-c)})^4 (-s_t + c)^3}{(1 + e^{-\gamma(st-c)})^4} \right|_{\gamma=0} \\
 &= -\frac{1}{8} (-s_t + c)^3
 \end{aligned}
 \tag{A-4}$$

## B Algoritmo de Levenberg-Marquardt

O algoritmo de Levenberg-Marquardt [11] e [14], é um algoritmo de otimização não linear usado para o cálculo de minimização de funções. Este algoritmo é usado especialmente em problemas que requerem o uso de mínimos quadrados não lineares. A função a ser minimizada possui a forma

$$f(\boldsymbol{\theta}) = \frac{1}{2} \sum_{i=1}^n e_i^2(\boldsymbol{\theta}) \quad (\text{B-1})$$

onde  $\boldsymbol{\theta}$  é o vetor de parâmetros de interesse e  $\mathbf{e} = (e_1, e_2, \dots, e_n)'$  são os resíduos.

O algoritmo iterativo para a estimação da solução geral de (B-1) é da forma de (B-2) e é chamado de algoritmo do gradiente descendente, pois a rotina de procura pelo valor mínimo é feita com base na direção oposta ao gradiente da função.

$$\boldsymbol{\theta}_{i+1} = \boldsymbol{\theta}_i - \mu \nabla f, \quad i = 0, 1, \dots, i \quad (\text{B-2})$$

Na equação (B-2), parte-se de um valor inicial do vetor de parâmetros  $\boldsymbol{\theta}_0$  e, em cada interação  $i$ , decrementa-se o vetor  $\boldsymbol{\theta}_i$ , ponderado pelo escalar  $\mu, \mu > 0$ , na direção contrária ao gradiente.

Como no ponto de mínimo da soma dos erros quadráticos tem-se  $\nabla f(\boldsymbol{\theta}) = 0$  e fazendo uso da linearização resultante da aproximação de Taylor do gradiente ao redor do estado atual  $\boldsymbol{\theta}_0$  do algoritmo, chega-se a

$$\nabla f = \nabla f(\boldsymbol{\theta}_0) + (\boldsymbol{\theta} - \boldsymbol{\theta}_0)' \nabla^2 f(\boldsymbol{\theta}_0) = 0 \quad (\text{B-3})$$

Desenvolvendo (B-3), obtém-se a regra de atualização para o método de Newton.

$$\boldsymbol{\theta}_{i+1} = \boldsymbol{\theta}_i - (\nabla^2 f(\boldsymbol{\theta}_i)^{-1}) \nabla f(\boldsymbol{\theta}_i) \quad (\text{B-4})$$

Fazendo uso da aproximação dos resíduos por funções lineares e

considerando-os muito pequenos, pode-se chegar a

$$\nabla f(\boldsymbol{\theta}) = J(\boldsymbol{\theta})' \mathbf{e} \quad (\text{B-5})$$

$$\nabla^2 f(\boldsymbol{\theta}) = J(\boldsymbol{\theta})' J(\boldsymbol{\theta}) \quad (\text{B-6})$$

onde  $J(\boldsymbol{\theta})$  é o Jacobiano dos resíduos  $\mathbf{e}$  com relação aos parâmetros  $\boldsymbol{\theta}$ .

O algoritmo de Levenberg-Marquardt é derivado do algoritmo de Newton e apresenta a forma a seguir

$$\boldsymbol{\theta}_{i+1} = \boldsymbol{\theta}_i - (\mathbf{H} + \mu \text{diag}[\mathbf{H}])^{-1} \nabla f(\boldsymbol{\theta}_i) \quad (\text{B-7})$$

onde  $\mathbf{H}$  é a Hessiana aplicada ao ponto  $\boldsymbol{\theta}_i$ .

## C

### Testes de Diagnósticos

Este apêndice traz a descrição teórica dos testes de diagnósticos usados para validação do modelo STAR-Tree. Os testes abordados são:

- Resíduos descorrelatados (C.1)
- Não linearidade não remanescente (C.2)

#### C.1

##### Resíduos Descorrelatados

Suponha o modelo de regressão da equação (C-1) e o modelo STAR(1) (C-2)

$$\mathbf{y}_t = \mathbf{X}_t \boldsymbol{\theta} + \boldsymbol{\epsilon}_t \quad (\text{C-1})$$

$$y_t = (\alpha_1 + \beta_1 y_{t-1})G(s_t; \gamma, c) + (\alpha_2 + \beta_2 y_{t-1})(1 - G(s_t; \gamma, c)) + \epsilon_t \quad (\text{C-2})$$

Fazendo a associação entre as equações (C-1) e (C-2), chega-se a

$$\mathbf{X}_t = [G(s_t; \gamma, c) \quad y_{t-1}G(s_t; \gamma, c) \quad 1 - G(s_t; \gamma, c) \quad y_{t-1}(1 - G(s_t; \gamma, c))]$$

$$\boldsymbol{\theta} = \begin{bmatrix} \alpha_1 \\ \beta_1 \\ \alpha_2 \\ \beta_2 \end{bmatrix} \quad (\text{C-3})$$

O teste proposto para verificação de correlação serial dos resíduos do modelo foi sugerido por Ljung e Box [10]. O teste é do tipo Multiplicador

de Lagrange e a hipótese nula avalia a correlação dos resíduos até a ordem  $m$ .

$$\begin{aligned} H_0 : \rho(1) = \rho(2) = \dots = \rho(m) = 0 \\ H_1 : \rho(1) \neq 0 \text{ ou } \rho(2) \neq 0 \text{ ou } \dots \text{ ou } \rho(m) \neq 0 \end{aligned} \quad (\text{C-4})$$

A estatística de teste (C-5) é construída a partir da regressão de  $e_t$ , os resíduos do modelo estimado, em  $\mathbf{X}_t$  e, sob a hipótese nula, segue uma distribuição assintótica  $\chi^2$  com  $m$  graus de liberdade.

$$Q_{LB} = T(T + 2) \sum_{j=1}^m \frac{r_j^2}{T - j} \quad (\text{C-5})$$

onde  $T$  é o número de observações e  $r_j = \frac{\sum_{t=j+1}^T e_t e_{t-j}}{\sum_{t=1}^T e_t^2}$  é a  $j$ -ésima autocorrelação.

A escolha do valor de  $m$  apresenta um problema: caso a ordem escolhida seja pequena, o teste pode não detectar a correlação com ordens superiores, e caso a ordem seja grande, correlações relevantes podem ser diluídas por correlações insignificantes de outras ordens.

## C.2 Não linearidade não remanescente

O teste utilizado aqui, proposto por van Dijk e Franses [21], é do tipo Multiplicador de Lagrange e confronta a hipótese nula de um modelo LSTAR(C-6) contra um modelo MRSTAR(C-7).

$$y_t = \phi_1' x_t + (\phi_2 - \phi_1)' x_t G(s_t; \gamma, c) + \epsilon_t \quad (\text{C-6})$$

$$\begin{aligned} y_t = [\phi_1' x_t G_1(s_{1t}; \gamma_1, c_1) + \phi_2' x_t (1 - G_1(s_{1t}; \gamma_1, c_1))] G_2(s_{2t}; \gamma_2, c_2) + \\ + [\phi_3' x_t G_1(s_{1t}; \gamma_1, c_1) + \phi_4' x_t (1 - G_1(s_{1t}; \gamma_1, c_1))] (1 - G_2(s_{2t}; \gamma_2, c_2)) + \epsilon_t \end{aligned} \quad (\text{C-7})$$

A hipótese nula deste teste é definida como  $H_0 : \gamma_2 = 0$  ou  $H_0' : \phi_1 = \phi_3$  e  $\phi_2 = \phi_4$ . Com isso, deve-se recorrer à aproximação de Taylor de terceira ordem da função  $G_2(s_{2t}; \gamma_2, c_2)$  ao redor de  $\gamma_2 = 0$  para contornar o problema de identificação já exposto. A equação abaixo traz este resultado.



$$y_t = \theta'_1 x_t + \theta'_2 x_t G_1(s_{1t}; \gamma_1, c_1) + \beta'_1 x_t s_{2t} + \beta'_2 x_t s_{2t}^2 + \beta'_3 x_t s_{2t}^3 + (\beta'_4 x_t s_{2t} + \beta'_5 x_t s_{2t}^2 + \beta'_6 x_t s_{2t}^3) G_1(s_{1t}; \gamma_1, c_1) + e_t \quad (C-8)$$

onde  $\beta_i = (\beta_{i,1}, \dots, \beta_{i,p})'$ ,  $i = 1, \dots, 6$  é função de  $\phi_i$ ,  $i = 1, \dots, 4$ ,  $\gamma_2$  e  $c_2$ .

A nova hipótese nula passa a ser  $H''_0 : \beta_i = 0, i = 1, \dots, 6$ . Sob a hipótese nula, tem-se  $\theta_1 = \phi_1$ ,  $\theta_2 = \phi_2 - \phi_1$  e  $e_t = \epsilon_t$ . A estatística de teste é então obtida através das seguintes etapas:

1. Estimação do modelo LSTAR por mínimos quadrados não lineares e obtenção da soma dos quadrados dos resíduos,  $SSR_0 = \sum_{t=1}^T \hat{\epsilon}_t^2$  sob a hipótese nula.
2. Estimação dos resíduos  $e_t$  e obtenção da soma dos quadrados de  $\hat{e}_t$  como  $SSR_1 = \sum_{t=1}^T \hat{e}_t^2$ .
3. A estatística de teste sob a hipótese nula seguirá uma distribuição  $\chi^2$  com  $6(p+1)$  graus de liberdade e terá a forma

$$LM = \frac{T(SSR_0 - SSR_1)}{SSR_0} \quad (C-9)$$

O procedimento é similar para o caso de inclusão de regimes adicionais.