

## Macroeconometria 2

Mestrado em Economia Monetária e Financeira

Mestrado em Economia

ISCTE-IUL, Dep. de Economia

### MODELOS NÃO-LINEARES

Luís Filipe Martins

[luis.martins@iscte.pt](mailto:luis.martins@iscte.pt)

<http://iscte.pt/~lfsm>

Departamento de Métodos Quantitativos,

ISCTE-IUL, Escola de Gestão

Lisboa, Fevereiro de 2010

# 1 Motivação

- Evidência Empírica (*stylized facts*): Várias séries económicas e financeiras apresentem propriedades estatísticas (momentos e parâmetros) que se distinguem ao longo da amostra. A presença de quebras na estrutura das séries é mais a regra do que a excepção! Algumas séries temporais são mais bem descritas através de não-linearidades.

**Example 1**  $s_t = i_t^l - i_t^s$ , onde  $s_t$  é o spread relativamente às taxas de juro nominais de curto ( $i_t^s$ ) e longo prazo ( $i_t^l$ ). A persistência (nível de "correlação temporal") é diferente quando  $s_{t-1} \geq 0$  de  $s_{t-1} < 0$ .

**Example 2** Para a economia mexicana e no período  $t = 1978, \dots, 1985$  considere-se o rácio  $D_t/P_t$  onde  $D_t$  e  $P_t$  são, respectivamente, o volume de dinheiro em dolares e em pesos em contas bancárias. A série  $\log D_t - \log P_t$  flutua uniformemente em torno de  $-2$  até 1982 e devido a um choque estrutural subitito passa a variar regularmente em torno de  $-3.25$  após 1982. Como modelar esta série?

**Example 3** US real GNP: Two state

$$y_t - \mu_{s_t} = \phi_1 (y_{t-1} - \mu_{s_{t-1}}) + \dots + \phi_4 (y_{t-4} - \mu_{s_{t-4}}) + \varepsilon_t.$$

*Finding:*  $\hat{\mu}_1 = 1.16\%$ ;  $\hat{\mu}_2 = -0.36\%$ ;  $\hat{p}_{11} = 0.90$ ;  $\hat{p}_{22} = 0.75$ ; expansões duram em média 10 trimestres; depressões 4.

## 2 Modelos TAR (Threshold AR)

- A alteração de regime é determinada por uma variável observada.
- Simples caso (SETAR - self-exciting TAR -, de 1<sup>a</sup> ordem, com threshold igual a zero e identicos choques):

$$y_t = \begin{cases} \rho_1 y_{t-1} + \varepsilon_t & \text{se } y_{t-1} > 0 \\ \rho_2 y_{t-1} + \varepsilon_t & \text{se } y_{t-1} \leq 0 \end{cases}, \text{ onde } \rho_1 \neq \rho_2. \quad (1)$$

Os parametros  $\rho_1$  e  $\rho_2$  descrevem o diferente nivel de persistencia de  $y_t$  de  $y_{t-1} > 0$  em relação a  $y_{t-1} \leq 0$ . O valor de zero é interpretado como o sendo o nivel de equilibrio (longo-prazo).

- Estimaco de  $\rho_1, \rho_2$  e  $\sigma_\varepsilon$ : Neste caso, Minimos Quadrados porque este modelo é equivalente a

$$y_t = \rho_1 I_t y_{t-1} + \rho_2 (1 - I_t) y_{t-1} + \varepsilon_t, \text{ onde } I_t = 1 (y_{t-1} > 0), \quad (2)$$

funço indicador.

- Teste a AR:  $H_0 : \rho_1 = \rho_2$  Estatistica usual F (se o threshold é desconhecido ento a estatistica deve ser outra - no standard).
- Extenses:
  - TAR (no é "self-exciting")

$$y_t = \begin{cases} \rho_1 y_{t-1} + \varepsilon_t & \text{se } S_{t-1} > 0 \\ \rho_2 y_{t-1} + \varepsilon_t & \text{se } S_{t-1} \leq 0 \end{cases}, \quad (3)$$

em que  $S_{t-1}$  é a variável de estado.

- Threshold diferente de zero (conhecido *versus* desconhecido) e com constante

$$y_t = \begin{cases} \mu_1 + \rho_1 y_{t-1} + \varepsilon_t & \text{se } y_{t-1} > \tau \\ \mu_2 + \rho_2 y_{t-1} + \varepsilon_t & \text{se } y_{t-1} \leq \tau \end{cases} . \quad (4)$$

- Demeaned

$$y_t = \begin{cases} \mu + \rho_1 (y_{t-1} - \mu) + \varepsilon_t & \text{se } y_{t-1} > \mu \\ \mu + \rho_2 (y_{t-1} - \mu) + \varepsilon_t & \text{se } y_{t-1} \leq \mu \end{cases} . \quad (5)$$

- Ordem  $p$  de desfazamento na parte AR

$$y_t = \begin{cases} \rho_{11} y_{t-1} + \rho_{12} y_{t-2} + \dots + \rho_{1p} y_{t-p} + \varepsilon_t & \text{se } y_{t-1} > 0 \\ \rho_{21} y_{t-1} + \rho_{22} y_{t-2} + \dots + \rho_{2p} y_{t-p} + \varepsilon_t & \text{se } y_{t-1} \leq 0 \end{cases} . \quad (6)$$

- Ordem  $k$  de desfazamento na variável de estado

$$y_t = \begin{cases} \rho_1 y_{t-1} + \varepsilon_t & \text{se } y_{t-k} > 0 \\ \rho_2 y_{t-1} + \varepsilon_t & \text{se } y_{t-k} \leq 0 \end{cases} , \quad (7)$$

onde  $k$  é o numero de periodos de desfazamento com que a variavel de estado influencia o regime na variavel principal.

- Diferentes choques

$$y_t = \begin{cases} \rho_1 y_{t-1} + \varepsilon_{1t} & \text{se } y_{t-1} > 0 \\ \rho_2 y_{t-1} + \varepsilon_{2t} & \text{se } y_{t-1} \leq 0 \end{cases} , \text{ onde } V(\varepsilon_{1t}) \neq V(\varepsilon_{2t}) . \quad (8)$$

- Mais do que 2 regimes; Diferentes ordens de desfazamento entre regimes; Apenas parte dos parametros mudam com o regime; Especificação diferente do tipo AR (eg: STAR); A

variavel de estado é diferente em cada regime; ...

- Se o parametro de threshold é desconhecido, então a estimação de minimos quadrados é feita a dois passos (o  $\tau$  é escolhido com base numa grelha) = OLS não linear (ou MLE).
- Pode-se usar AIC para a selecção de modelos ( $p, k, \dots$ ).

## 3 Modelos MS (Markov-Switching)

### 3.1 Introdução e Markov Chains

- Retomemos o exemplo da série  $\log D_t - \log P_t \equiv y_t$ . Como modela-la? Uma hipótese é usando  $AR(1)$  (demeaned) para cada regime,  $\begin{cases} y_t - \mu_1 = \phi (y_{t-1} - \mu_1) + \varepsilon_t, & \text{se } t \leq t_0 \\ y_t - \mu_2 = \phi (y_{t-1} - \mu_2) + \varepsilon_t, & \text{se } t > t_0 \end{cases}$ ,  $\mu_2 < \mu_1$ . Questões:
  - (a) Como se estima  $t_0$ ? Corresponderá de facto a 1982? O que causou esta quebra abrupta?
  - (b) Como se estimam os parâmetros do modelo  $\mu_1, \mu_2$ ?
  - (c) Como se prevê esta série com base neste modelo?
  - (d) Qual é a lei probabilística (DGP) para  $\{y_t\}$ ?
- Modelo equivalente:

$$y_t - \mu_{s_t^*} = \phi \left( y_{t-1} - \mu_{s_{t-1}^*} \right) + \varepsilon_t, t = 1, \dots, T, \quad (9)$$

onde o estado ou regime  $s_t^* = 1$  se  $t = 1, 2, \dots, t_0$  e  $s_t^* = 2$  se  $t = t_0 + 1, t_0 + 2, \dots, T$ . No entanto, na prática,  $s_t$  não é observado e é aleatória a sua realização. Qual é a lei probabilística para  $\{s_t\}$ ? Por simplicidade, assumir que a time series, sendo uma sequência de v.a. discretas, é uma cadeia de Markov.

- $\{s_t\} \sim$  Cadeia de Markov com  $N$  regimes ( $\mathcal{S} = \{1, \dots, N\}$ ) e

probabilidades de transição  $\{p_{ij}\}_{i,j=1}^N : \sum_{j=1}^N p_{ij} = 1$ ,

$$P(s_t = j | s_{t-1} = i, s_{t-2} = k, \dots) = P(s_t = j | s_{t-1} = i) = p_{ij}, \quad (10)$$

$$\mathbf{P}_{N \times N} = [p_{ij}] = \begin{pmatrix} p_{11} & \dots & p_{N1} \\ \dots & & \dots \\ p_{1N} & \dots & p_{NN} \end{pmatrix}.$$

- Irreducible M.C.: Não há regime(s) absorvente(s) (c.f.  $\mathbf{P}$ ).
- Ergodic Irreducible M.C. para  $N = 2 : p_{11} < 1, p_{22} < 1, p_{11} + p_{22} > 0$ , onde  $\pi_1 = P(s_t = 1) = \frac{1-p_{22}}{2-p_{11}-p_{22}}, \pi_2 = 1 - \pi_1$ .

### 3.2 Modelo de Hamilton e Estimação, Previsão e Inferência

- Geral, linear,

$$y_t = \beta'_{s_t} x_t + \varepsilon_t, t = 1, \dots, T, \quad (11)$$

onde  $\varepsilon_t \sim N(0, \sigma_{s_t}^2)$  independente  $\forall t$  de  $s_t$  que é modelado como uma não observada  $N$ -state Markov chain.

#### Example 4

$$y_t = \mu_{s_t} + \phi_{s_t} y_{t-1} + \varepsilon_t, \varepsilon_t \sim i.i.d. N(0, \sigma^2), N = 2$$

$$\alpha = (\mu_1, \mu_2, \phi_1, \phi_2, \sigma^2)'; \theta = (\alpha', p_{11}, p_{22})'; j = 1, 2,$$

- Notas:

(a) Data  $\mathcal{Y}_t = (y_t, y_{t-1}, \dots, y_{-m}, x'_t, x'_{t-1}, \dots, x'_{-m})'$  continuous + Regimes  $s_t$  discrete *implica* uma MIXTURE Joint PDF.

(b) Parametros do modelo + Prob. associadas ao regime *implica* MLE com recurso a um processo iterativo na lógica do EM algoritm.

(c) Assume-se

$$f(y_t|x_t, \mathcal{Y}_{t-1}, s_t = j; \alpha) = f(y_t|x_t, \mathcal{Y}_{t-1}, s_t = j, s_{t-1} = i, \dots, ; \alpha) \quad (12)$$

(d) Assume-se que MC  $s_t$  é independente de  $\mathcal{Y}_{t-1}$  e  $x_t$  (além do erro  $\varepsilon_t$ ).

- Informação probabilística sobre qual o regime num dado periodo  $t$  dada a informação disponível até esse momento  $\mathcal{Y}_t$ :  $\widehat{\xi}_{t|t} = E(\xi_t|\mathcal{Y}_t) = (P(s_t = 1|\mathcal{Y}_t), \dots, P(s_t = N|\mathcal{Y}_t))'$  onde  $\xi_t = \mathbf{e}_i$  ( $i^{th}$  col. de  $I_N$ ) quando  $s_t = i$ . A sequência  $\{\widehat{\xi}_{t|t}\}$  é denominada por *Filtered prob.* (one-step state forecast given  $\mathcal{Y}_t$ ).
- Previsão optima a  $m$  passos:  $\widehat{\xi}_{t+m|t} = \mathbf{P}^m \widehat{\xi}_{t|t}$ .
- *Smoothed prob.* com base em toda a amostra:  $\widehat{\xi}_{t|T} = E(\xi_t|\mathcal{Y}_T)$ .
- Previsão para  $y_t$ ? Demonstra-se que  $E(y_{t+1}|\mathcal{Y}_t; \theta) = h_t' \widehat{\xi}_{t+1|t}$ , onde o  $(N \times 1)$  vector  $h_t$  tem como  $j^{th}$  elemento  $E(y_{t+1}|s_{t+1} = j, \mathcal{Y}_t; \theta) = \mu_j + \phi_j y_t$ , por exemplo.