

# **Markov Switching Models**

**Profa. Airlane Alencar**

**Depto de Estatística - IME-USP**

**[www.ime.usp.br/~lane](http://www.ime.usp.br/~lane)**

**Ref: Kim e Nelson (1999) e Hamilton (1990)**

## Objetivo

Mudança nos parâmetros de um modelo de regressão definindo diferentes regimes.

- Datas conhecidas - Teste de Chow (1960);
- Quandt (1972): Regimes independentes;
- Goldfeld e Quandt (1973) - Regimes Markovianos;
- Hamilton (1989) - Mudança Markoviana no modelo AR(p).

## Modelo com mudança de regime

$$y_t = x_t \beta_{S_t} + e_t, \quad (1)$$

em que:

1.  $x_t$  é um vetor de variáveis exógenas  $1 \times k$ ;
2.  $S_t$  define o regime;
3.  $e_t$  iid  $\sim N(\mathbf{0}, \sigma_{S_t}^2)$ .

Consideremos dois regimes  $S_t = 0, 1$ .

1.  $\beta_{S_t} = \beta_0(1 - S_t) + \beta_1 S_t$ ;
2.  $\sigma_{S_t}^2 = \sigma_0^2(1 - S_t) + \sigma_1^2 S_t$ .

A função log-verossimilhança é

$$\begin{aligned}
\ln L &= \sum_{t=1}^T \ln f(y_t | \tilde{y}_{t-1}) \\
&= \sum_{t=1}^T \ln \left[ \sum_{S_t=0}^1 f(y_t | S_t, \tilde{y}_{t-1}) P(S_t | \tilde{y}_{t-1}) \right]
\end{aligned}$$

## Regimes independentes

Probabilidades de cada regime dependentes de  $Z$  usando a função de ligação logística:

$$P(S_t = 1 | \tilde{y}_{t-1}) = p_t = \frac{\exp(\gamma_0 + Z_t \gamma_1)}{1 + \exp(\gamma_0 + Z_t \gamma_1)}$$
$$P(S_t = 0 | \tilde{y}_{t-1}) = 1 - p_t = \frac{1}{1 + \exp(\gamma_0 + Z_t \gamma_1)}$$

ou usando alguma outra função de ligação, como por exemplo a probit, que facilita a obtenção da posteriori usando inferência bayesiana.

## Transição Markoviana

$$P(S_t = 1 | S_{t-1} = 1, \tilde{y}_{t-1}) = p_t = \frac{\exp(\gamma_0 + Z_t \gamma_1)}{1 + \exp(\gamma_0 + Z_t \gamma_1)}$$

$$P(S_t = 1 | S_{t-1} = 0, \tilde{y}_{t-1}) = q_t = \frac{\exp(\delta_0 + Z_t \delta_1)}{1 + \exp(\delta_0 + Z_t \delta_1)}$$

## Filtro de Probabilidades

Passo 1

$$P(S_t = j | \tilde{y}_{t-1}) = \sum_{i=0}^1 P(S_t = j | S_{t-1} = i) P(S_{t-1} = i | \tilde{y}_{t-1})$$

Passo 2 - Atualização

$$\begin{aligned} P(S_t = j | \tilde{y}_t) &= \frac{f(S_t = j, y_t | \tilde{y}_{t-1})}{f(y_t | \tilde{y}_{t-1})} = \\ &= \frac{f(y_t | S_t = j, \tilde{y}_{t-1}) P(S_t = j | \tilde{y}_{t-1})}{\sum_{j=0}^1 f(y_t | S_t = j, \tilde{y}_{t-1}) P(S_t = j | \tilde{y}_{t-1})} \end{aligned}$$

Para iniciar o filtro tem que inicializar  $P(S_0 | \tilde{y}_0)$ , por exemplo usando a probabilidade invariante no caso de cadeia estacionária.

## Exemplo - AR(1)

$$y_t - \mu_{S_t} = \phi(y_{t-1} - \mu_{S_{t-1}}) + e_t, t = 1, \dots, T$$

$$e_t \sim N(0, \sigma_{S_t}^2)$$

$$S_t = 1, \dots, M.$$

Agora a densidade de  $y_t$  depende de  $S_t$  e  $S_{t-1}$

$$f(y_t | \tilde{y}_{t-1}, S_t, S_{t-1}) = \frac{1}{\sqrt{2\pi\sigma_{S_t}^2}} \exp \left[ -\frac{(y_t - \mu_{S_t} - \phi(y_{t-1} - \mu_{S_{t-1}}))^2}{2\sigma_{S_t}^2} \right]$$

e

$$\begin{aligned}\ln L &= \sum_{t=1}^T \ln f(y_t | \tilde{y}_{t-1}) \\ &= \sum_{t=1}^T \ln \left[ \sum_{S_t=1}^M \sum_{S_{t-1}=1}^M f(y_t | S_t, S_{t-1}, \tilde{y}_{t-1}) P(S_t, S_{t-1} | \tilde{y}_{t-1}) \right]\end{aligned}$$

## Filtro de Probabilidades

Passo 1

$$P(S_t = j, S_{t-1} = i | \tilde{y}_{t-1}) = P(S_t = j | S_{t-1} = i)P(S_{t-1} = i | \tilde{y}_{t-1})$$

Passo 2 - Atualização

$$\begin{aligned} P(S_t = j, S_{t-1} = i | \tilde{y}_t) &= \\ &= \frac{f(S_t=j, S_{t-1}=i, y_t | \tilde{y}_{t-1})}{f(y_t | \tilde{y}_{t-1})} = \\ &= \frac{f(y_t | S_t=j, S_{t-1}=i, \tilde{y}_{t-1})P(S_t=j, S_{t-1}=i | \tilde{y}_{t-1})}{\sum_{i=1}^M \sum_{j=1}^M f(y_t | S_t=j, S_{t-1}=i, \tilde{y}_{t-1})P(S_t=j, S_{t-1}=i | \tilde{y}_{t-1})} \end{aligned}$$

Para iniciar o filtro tem que inicializar  $P(S_0 | \tilde{y}_0)$ .

## Suavização e EM

A variância assintótica dos estimadores de máxima verossimilhança podem ser obtidos utilizando-se o inverso da matriz informação de Fisher (estimada usando a matriz hessiana no ponto de máximo).


O algoritmo de suavização proposto por Kim permite obter uma aproximação para  $P(S_t = j | \tilde{y}_T)$ .

Pode ser utilizado o algoritmo EM para realizar a estimação, escrevendo-se a log-verossimilhança completa, ou seja, usando a densidade das observações e as variáveis não observadas que nesse caso são os regimes.

## **Hamilton - GDP**

Hamilton (1989) modelou o crescimento do PIB real como um modelo AR(4) com dois regimes para a média. A seguir,  $y_t$  é o log do PIB real.

## $\Delta \text{ Log do PIB real}$



## Modelo

$$\begin{aligned}(\Delta y_t - \mu_{S_t}) &= \phi_1(\Delta y_{t-1} - \mu_{S_{t-1}}) + \dots + \phi_4(\Delta y_{t-4} - \mu_{S_{t-4}}) + e_t \\e_t &\sim N(0, \sigma^2) \\\mu_{S_t} &= \mu_0(1 - S_t) + \mu_1 S_t\end{aligned}$$

$$P(S_t = 1 | S_{t-1} = 1) = p, \quad P(S_t = 0 | S_{t-1} = 0) = q$$


Modelo estacionário, sujeito a  $\phi(B) = (1 - \phi_1 B - \dots - \phi L^4) = 0$   
com raízes fora do círculo unitário.

É possível distinguir dois regimes: recessão e expansão (média negativa e positiva para o crescimento do PIB real)

Maximum likelihood estimates of the Hamilton model (real GDP; 1952:II–1984:IV; 1952:II–1995:III)

	1952:II-1984:IV		1952:II-1995:III	
	(No dummy variable)		(With a dummy variable)	
$p$	0.9008	(0.0443)	0.9113	(0.0363)
$q$	0.7606	(0.1206)	0.7658	(0.0857)
$\phi_1$	0.0898	(0.1981)	0.0496	(0.1347)
$\phi_2$	-0.0186	(0.2082)	-0.0495	(0.1295)
$\phi_3$	-0.1743	(0.1381)	-0.2112	(0.1129)
$\phi_4$	-0.0839	(0.1248)	-0.0953	(0.1140)
$\sigma$	0.7962	(0.0858)	0.6902	(0.0505)
$\mu_0$	-0.2132	(0.2613)	-0.2996	(0.1892)
$\mu_1$	1.1283	(0.1596)	1.1479	(0.0768)
$\mu_0^*$	—		0.4516	(0.3209)
$\mu_1^*$	—		-0.3346	(0.1340)
Log likelihood	-175.24		-212.17	-212.99

Note: Standard errors are in parentheses.




**Figure 4.2**  
Filtered probability of a recession (GDP: 1952:II–1984:IV)

Quando Kim e Nelson incluíram os dados de 1985 a 1995, o modelo não consegue detectar dois regimes. Por isso, foi proposto o modelo para as médias:

$$\mu_{S_t} = (\mu_0 + \mu_0^* S_t)(1 - D_t) + (\mu_1 + \mu_1^* D_t)S_t,$$

com  $D_t$  igual a 1 no período 1983:I-1995:III e zero no período anterior.



**Figure 4.4**

Filtered probability of a recession (GDP: 1952:II–1995:III; model with dummy variables)

## Modelo Threshold Auto-regressivo

TAR

$$y_t = \begin{cases} \mu_1 + \phi_1 y_{t-1} + u_{1t}, & \text{se } s_{t-k} < r \\ \mu_2 + \phi_2 y_{t-1} + u_{2t}, & \text{se } s_{t-k} \geq r \end{cases}$$

SETAR = Self-exciting TAR


$$y_t = \begin{cases} \mu_1 + \phi_1 y_{t-1} + u_{1t}, & \text{se } y_{t-k} < r \\ \mu_2 + \phi_2 y_{t-1} + u_{2t}, & \text{se } y_{t-k} \geq r \end{cases}$$

Tem que estimar  $\mu_1, \mu_2, \phi_1, \phi_2, k, r$  e as variâncias de  $u_{it}$ .

- Estimação: máxima verossimilhança e r, k estimados por grid search.
- Pode ter mais que dois regimes e diferentes variáveis para definir os regimes.
- Pode ser usado algum critério tipo AIC para escolher o melhor modelo.


Dados simulados de

$$y_t = \begin{cases} 0, 2y_{t-1} + 0,5e_t, & \text{se } y_{t-1} > 0,5 \\ 0,8y_{t-1} + e_t, & \text{se } y_{t-1} \leq 0,5 \end{cases}$$



Valores verdadeiros e estimativas obtidas pelo método de Máxima Verossimilhança

parâmetros	verdadeiro	estimativa
$\phi_1$	0.20	0.35
$\phi_q$	0.80	0.82
$\sigma_1^2$	0.50	0.51
$\sigma_2^2$	1.00	1.01
r	0.50	0.52



# Referências

- [1] Kim, C. J. e Nelson, C. R. (1999). State-space models with regime switching. MIT Press.
- [2] Hamilton, J. D. (1994). *Time series analysis*. Princeton, N.J.: Princeton University Press.
- [3] Tong, H. (1990). Non-Linear Time Series: A Dynamical System Approach. New York: Oxford University Press.