

Joel Maurício Corrêa da Rosa

## **Projeto de Pesquisa**

Departamento de Estatística  
Setor de Ciências Exatas  
Universidade Federal do Paraná

Curitiba  
2008

# Dinâmicas Não-Lineares em Climatologia e Finanças

Autor :Joel Maurício Corrêa da Rosa

Colaboradores : Ricardo Sandes Ehlers

Wanderson Rodrigo

Luiz Carlos Fernandes

Fábio Eiji Sudo

Departamento de Estatística

Universidade Federal do Paraná

2008

## Resumo

As mudanças climáticas têm recebido atenção de diversos ramos da ciência. Os impactos do aquecimento global, aumento do nível dos oceanos e eventos extremos como ciclones e tempestades afetam várias atividades humanas. Uma das atividades diretamente afetada é o mundo das finanças, em especial, ativos financeiros ligados à empresas do ramo agrícola e energético. Este projeto pretende, pela Análise de Séries Temporais, desenvolver modelagem de fenômenos, tipicamente não-lineares e complexos, em climatologia e finanças. Os procedimentos de modelagem estarão baseados em modelos que descrevem mudanças de regimes, em especial os da classe STAR (Smooth Transition AutoRegression) descritos em [5].

Palavras-Chave: séries temporais, climatologia, finanças

# 1 Introdução

As mudanças climáticas têm recebido, justificadamente, especial atenção por diversos ramos da ciência. Técnicas de Análise de Séries temporais têm sido aplicadas à séries de temperatura (ver [9]), pluviosidade, vazão de rios, dentre outras. Neste caso, há o interesse em revelar padrões estruturais e realizar previsões que auxiliem a adoção de políticas públicas de caráter preventivo.

O IPCC (Intergovernmental Panel on Climate Changes) define vulnerabilidade como o "grau ao qual um sistema é suscetível ou incapaz de lidar com efeitos adversos, mudanças climáticas, incluindo variabilidade do clima e eventos extremos". A projeção de cenários futuros para o clima, assim como séries financeiras, pode auxiliar a identificar vulnerabilidades e traçar estratégias de ação.

Muitas instituições financeiras aumentaram, recentemente, o suporte à iniciativas de desenvolvimento sustentável tais como: tecnologias de energia solar, energia eólica, biocombustíveis e neutralização da emissão de carbono.

Com estas atitudes, empresas poluidoras e, conseqüentemente suas ações, devem perder espaço para empresas que desenvolvam tecnologias em Mecanismos de Desenvolvimento Limpo(MDL).

Em paralelo, a Análise de Séries Temporais aplicada à finanças representa um grande desafio metodológico em função da falta de previsibilidade e da grande complexidade das dinâmicas não-lineares que explicam a evolução de variáveis ligadas à ativos financeiros. Em [10] encontra-se uma boa revisão sobre modelos lineares e alternativas não lineares aplicadas à séries econômicas.

Apesar de existir interseção entre os métodos de análise de séries temporais aplicados em climatologia e finanças, o estudo conjunto destes dois fenômenos tem recebido cada vez mais atenção. Isto é justificado pelo impacto de vários fenômenos climáticos em setores da economia, como por exemplo, a escassez de chuvas na dificuldade de geração de energia elétrica.

Em [8] é feito um estudo sobre o impacto do clima na Economia dos Estados Unidos que mostra evidência da relação de temperatura, precipitação, aumento do nível do mar e emissão de gás carbônico com indicadores do setor agrícola e energético.

## 2 Objetivos

### 2.1 Objetivo Geral

O objetivo geral deste trabalho é descrever dinâmicas não-lineares em séries de clima e finanças, quando possível encontrando relações entre estes dois fenômenos.

### 2.2 Objetivos Específicos

- verificar a significância de impactos climáticos na mudança de regimes em séries financeiras;
- quantificar o impacto climático no aumento da volatilidade de ativos financeiros;
- descrever a associação entre componentes estruturais encontrados em séries climáticas e financeiras.

## 3 Metodologia

### 3.1 Modelos Não-Lineares

Os últimos anos têm acompanhado o surgimento de diversas propostas de modelos não-lineares para séries temporais. Na Econometria clássica os modelos de múltiplos regimes têm recebido muita importância e na área de Aprendizado de Máquina as Redes Neurais Artificiais, métodos de particionamento recursivo como Árvores de Decisão e métodos de Regressão Nebulosa são frequentemente utilizados.

Dentre as metodologias estatísticas a serem utilizadas neste trabalho, grande parte está baseada nos modelos Auto-Regressivos Não Lineares cuja formulação geral está presente na Equação (1).

$$Z_t = h_t(Z_{t-1}, Z_{t-2}, \dots, Z_{t-p}) + \epsilon_t \quad (1)$$

Em 1,  $h_t(\cdot)$  é uma função não-linear de autoregressores que recebe diversas formulações. Muitas abordagens têm sido utilizadas na formulação de  $h_t(\cdot)$ , como por exemplo em [13], [3] e [6].

Além destes modelos, serão abordados modelos para volatilidade. Na sequência apresentamos com maiores detalhes os modelos da classe STAR.

### 3.2 Modelos STAR

Considerando uma das hipóteses de pesquisa deste projeto na qual informações sobre o clima geram mudanças de regime em séries financeiras, serão enfatizados os modelos da classe STAR(Smooth Transition AutoRegression) que são descritos em [5].

Em recente literatura econométrica, o modelo STAR surgiu como uma importante alternativa não linear para a modelagem de séries temporais. Este modelo, cuja origem pode ser vista no seminal trabalho em [1], é uma generalização dos modelos TAR e SETAR desenvolvidos em [11],[12] e [6].

Pode se dizer que a primeira inspiração veio dos modelos ARMA desenvolvidos em [2] cuja sólida fundamentação teórica inspirou inúmeras outras metodologias.

Nos modelos da classe STAR, a função  $h_t(\cdot)$  é representada por uma combinação de diferentes modelos autoregressivos que representam diferentes regimes na evolução da série. A definição destes regimes está associada a valores de uma variável endógena ou exógena que aqui é denotada por  $s_t$ .

$$h_t() = [a_0 + a_1 Z_{t-1} + a_2 Z_{t-2} + \dots + a_{p_1} Z_{t-p_1}] F(s_t; \gamma, c) + [b_0 + b_1 Z_{t-1} + b_2 Z_{t-2} + \dots + b_{p_2} Z_{t-p_2}] (1 - F(s_t; \gamma, c)) + \epsilon_t \quad (2)$$

Nas equações (3) e (4) mostramos um caso particular dos modelos da classe STAR, o LSTAR(1).

$$y_t = (\alpha_0 + \beta_0 y_{t-1}) F(s_t; \gamma, c) + (\alpha_1 + \beta_1 y_{t-1}) (1 - F(s_t; \gamma, c)) + \epsilon_t \quad (3)$$

$$F(y_{t-1}; \gamma, c) = \frac{e^{-\gamma(y_{t-1}-c)}}{1 + e^{-\gamma(y_{t-1}-c)}} \quad (4)$$

$$\gamma > 0, E[\varepsilon_t] = 0, E[\varepsilon_t^2] = \sigma^2$$

Os coeficientes dos modelos autoregressivos de primeira ordem em (3) são combinados ao longo do tempo com pesos fornecidos de acordo com a função logística em (4). Neste caso, assumimos que a transição é univariada e governada por  $s_t$ , uma variável exógena ou uma variável endógena defasada.

A distância de  $s_t$  para  $c$ , o parâmetro de locação, indica a identificação de  $y_t$  com um dos regimes. Por outro lado, se  $s_t = c$ ,  $y_t$  pertence a ambos os regimes com o mesmo grau de pertinência. A suavidade da transição entre os regimes depende de  $\gamma$  que não estabelecerá distinção entre os regimes quando estiver perto de zero e aproximará (4) por uma função degrau quando assume valores altos.

É comum classificar os parâmetros em (3) em duas categorias: lineares não lineares. A primeira contém todos os parâmetros autoregressivos e a segunda inclui os parâmetros da função logística e a variância do termo errático, embora este último termo é usualmente tratado como constante devido a estrutura da matriz de informação. Desta forma, são determinados dois vetores:  $\Theta = (\alpha_0, \alpha_1, \beta_0, \beta_1)$  e  $\Phi = (\gamma, c)$ , contendo os parâmetros lineares e não-lineares respectivamente.

Assumindo normalidade na componente aleatória  $\varepsilon_t$ , os estimadores de Mínimos Quadrados Não-Lineares (MQNL) e Máxima Verossimilhança (MV) são assintoticamente normais sobre algumas condições de regularidade (ver [7]). Maiores detalhes sobre as propriedades assintóticas destes estimadores podem ser encontradas em [16].

### 3.3 Modelo MRSTAR

Os modelos da classe STAR são generalizados para múltiplos regimes pelos modelos MRSTAR (Multiple Regime Smooth Transition AutoRegression) que pode ser visto em na descrição de diferentes regimes no ciclo de negócios associados as fases de expansão e contração da economia. Estes desenvolvimentos são discutidos em [15].

Estes generalizam o modelo LSTAR para que sejam abrigados mais do que 2 regimes. Um modelo com 4 regimes que é uma extensão de (3) é mostrado em (5).

$$\begin{aligned}
y_t = & [(\alpha_0 + \beta_0 y_{t-1})F_1(s_{1t}; \Theta_1) + (\alpha_1 + \beta_1 y_{t-1})(1 - F_1(s_{1t}; \Theta_1))]F_2(s_{2t}; \Theta_2) \\
& + [(\alpha_2 + \beta_2 y_{t-1})F_1(s_{1t}; \Theta_1) + (\alpha_3 + \beta_3 y_{t-1})(1 - F_1(s_{1t}; \Theta_1))](1 - F_2(s_{2t}; \Theta_2)) \\
& + \varepsilon_t.
\end{aligned} \tag{5}$$

Assumindo que as variáveis de transição  $s_{1t}$  e  $s_{2t}$  são conhecidas, note que os regimes em (5) são ponderados por uma composição de de funções logísticas. Deste ponto em diante, estas composições serão denominadas funções de pertinência . Esta nomenclatura é emprestada da literatura sobre lógica nebulosa.

Tabela 1: Parâmetros do Modelo MRSTAR

Regime	Parâmetros Lineares	Parâmetros Não-Lineares	Função de Pertinência
1	$(\alpha_0, \beta_0)$	$(\Theta_1, \Theta_2)$	$F_1(\cdot)F_2(\cdot)$
2	$(\alpha_1, \beta_1)$	$(\Theta_1, \Theta_2)$	$[1 - F_1(\cdot)]F_2(\cdot)$
3	$(\alpha_2, \beta_2)$	$(\Theta_1, \Theta_2)$	$F_1(\cdot)[1 - F_2(\cdot)]$
4	$(\alpha_3, \beta_3)$	$(\Theta_1, \Theta_2)$	$[1 - F_1(\cdot)][1 - F_2(\cdot)]$

A Tabela 1 contém todas as informações sobre os regimes que são criados pelo modelo MRSTAR através da formulação em (5). O modelo pode ser interpretado sob diferentes perspectivas. Uma delas é que os coeficientes mudam suavemente ao longo do tempo de acordo com o par de variáveis de transição  $s_{1t}$  e  $s_{2t}$ .

Para especificar o número de regimes, pode-se seguir uma seqüência de testes para verificar não-linearidade remanescente conforme os desenvolvimentos em [4] que testa, a cada passo, a inclusão de um regime adicional, ou então seguir a proposta em [14] que sempre duplica o número de regimes na hipótese alternativa.

### 3.4 Conjuntos de Dados

Os dados a serem utilizados neste trabalho serão obtidos, preferencialmente , em bases de dados públicas e incluirão : retornos de ativos financeiros, taxas de câmbio, séries meteorológicas: temperatura, precipitação, umidade, número de horas de sol, dentre outras, em diferentes localidades.

## 4 Cronograma de Atividades

Atividades	2008		Março		Abril		Maio		Junho		Julho	
	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2
Redação do Projeto	X	X										
Revisão de Literatura	X	X	X	X								
Coleta de Dados			X	X	X	X						
Implementação Computacional							X	X	X	X	X	X
Redação de Artigo Aplicado							X	X	X	X	X	X

Atividades	2008		Agosto		Setembro		Outubro		Novembro		Dezembro	
	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2
Redação de Artigo Aplicado	X	X										
Revisão do Projeto	X	X	X									
Atualização de Literatura	X	X	X	X								
Redação de Artigo de Metodologia							X	X	X	X	X	X

Atividades	2009		Março		Abril		Maio		Junho		Julho	
	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2	Q1	Q2
Redação de Artigo de Metodologia	X	X	X									
Submissão a Congresso(s)			X	X								
Redação de Relatório Final							X	X	X	X	X	X

Q1 - primeira quinzena

Q2 - segunda quinzena

## 5 Produção Científica do Projeto

Ao final da realização deste projeto são previstos os seguintes produtos:

- Inserção de alunos do Curso de Estatística da UFPR em programa de iniciação científica;



- realização de 4 seminários;
- redação de um artigo a ser submetido em periódico de estatística aplicada;
- redação de um artigo sobre desenvolvimento de metodologia estatística ligada ao tema;
- apresentação do trabalho em forma de poster em congresso científico;
- Apresentação do trabalho em forma de comunicação oral em congresso científico.

## Referências

- [1] D.W. Bacon and D.G. Watts. Estimating the transition between two intersecting straight lines. *Biometrika*, 58:525–534, 1971.
- [2] G.E.P Box and G.M. Jenkins. *Time Series Analysis, Forecasting and Control*. Holden-Day, New Jersey, 1976.
- [3] C. Dunis and J. Jalilov. Neural network regression and alternative forecasting techniques for predicting financial variables. *Neural Network World*, 2:113–139, 2002.
- [4] Ø. Eitrheim and T. Teräsvirta. Testing the adequacy of smooth transition autoregressive models. *Journal of Econometrics*, 74:59–75, 1996.
- [5] C.W.J. Granger and T. Teräsvirta. *Modelling Nonlinear Economic Relationships*. Oxford University Press., Oxford, 2006.
- [6] H.Tong. *Non-linear Time Series Analysis*. Oxford University Press, Oxford, 1990.
- [7] L.A. Klimko and P.L. Nelson. On conditional least squares estimation for stochastic processes. *The Annals of Statistics*, 6:629–642, 1978.
- [8] R. Mendelsohn and M. Schlesinger. Climate-response functions. *Ambio*, 28(4):362–366, 1999.
- [9] Seung-Ki Min, Daniel Simonis, and Andreas Hense. Probabilistic climate change predictions applying bayesian model averaging. *Philosophical Transactions of the Royal Society A.*, 365:2103–2116, 2007.

- [10] van Dijk D. Teräsvirta, T. and M. Medeiros. Linear models, smooth transition autoregressions, and neural networks for forecasting macroeconomic time series. *International Journal of Forecasting*, 21:755–783, 2005. with discussion and reply.
- [11] H. Tong. On a threshold model. In C H. Chen, editor, *In Pattern Recognition and Signal Processing*, pages 575–586. Sijthoff and Noordhoff, Amsterdam, 1978.
- [12] H. Tong. Threshold models in non-linear time series analysis. In Springer Verlag, editor, *Springer Lecture Notes in Statistics*, volume 21. Springer Verlag, 1983.
- [13] A. Trapletti, F. Leisch, and K. Hornik. Stationary and integrated autoregressive neural network processes. *Neural Computation*, 12:2427–2450, 2000.
- [14] D. van Dijk. *Smooth Transition Models: Extensions and Outlier Robust Inference*. PhD thesis, Tinbergen Institute, Amsterdam, 1999.
- [15] Dick van Dijk. *Modelling multiple regimes in the business cycle*, 1997.
- [16] J.M. Wooldridge. Estimation and inference for dependent process. In R.F. Engle and D.L. McFadden, editors, *Handbook of Econometrics*, pages 2639–2738. Elsevier Science, Berlin, 1994.