

4 NÃO LINEARIDADE NA MODELAGEM DE CARGA DE UMA DISTRIBUIDORA DE ENERGIA ELÉTRICA

4.1 Introdução

A capacidade de antecipar a quantidade de energia elétrica que será demandada pelos seus clientes é um dado fundamental para uma distribuidora de eletricidade: com essa informação é possível para a empresa otimizar a sua carteira de contratos de fornecimento de energia, de forma a maximizar o seu lucro sem correr o risco de não poder fazer face a futuros compromissos de fornecimento, reduzindo o desperdício de recursos não só escassos, mas também caros.

A literatura sobre previsão de carga é bem farta em trabalhos de previsão, embora em sua maioria estes sejam a respeito de previsões de prazo curto e médio (Kodogiannis, 2000; Teixeira e Zaverucha, 2002; Soares e Souza, 2006; Soares e Medeiros, 2008; Hinman e Hickey, 2009), sendo as previsões de mais longo prazo normalmente feitas para o planejamento estratégico de infraestrutura pelos governos.

Não obstante, alguns pesquisadores têm utilizado os métodos de séries temporais, abordagens reconhecidamente com foco na previsão de curto-prazo (Pindyck e Rubinfeld, 1998), para fazer previsões em prazos mais longos, utilizando modelos ARMA combinados com variáveis exógenas ligadas ao ambiente onde é observada a demanda, como temperatura e PIB, gerando os modelos conhecidos como ARMAX e outros parentes próximos (Weron, 2006). A escolha das variáveis exógenas sempre se centra em características demográficas e ambientais do local onde se observa o consumo de energia elétrica.

Estas são abordagens lineares, mas além destas, vários modelos não lineares já foram propostos para a para a modelagem de séries temporais, como o modelo bilinear (Granger e Andersen, 1978), o modelo TAR (*threshold auto-regressive*) auto-regressivo com limite (Tong, 1978), o modelo com dependência no estado (Priestley, 1980) e o modelo Markoviano de mudança de regime (Hamilton, 1994), mas apenas mais recentemente esse tipo de abordagem despertou interesse aumentado, em função de métodos computacionais mais avançados.

Dentre as diversas famílias apresentadas, vamos focar naquela dos modelos chamados TAR, ou auto-regressivos em torno de um limite, que, basicamente, pregam a existência de regimes auto-regressivos lineares em torno de um ou mais limites determinados.

Estes modelos podem ser considerados como derivados do conceito de cointegração introduzido por Granger em 1982 (Granger, 1986; Engle e Granger, 1987), o qual postula que variáveis não estacionárias à longo prazo podem observar um equilíbrio conjunto de longo prazo e, dessa forma, podem tender a moverem-se juntamente.

A grande contribuição para o desenvolvimento de modelos não lineares conhecidos como modelos de cointegração em torno de um limite (*threshold cointegration*) foi dada por Balke and Fomby (1997), em seu trabalho seminal, daqui em diante referido como B&F.

Neste artigo, os autores introduziram o conceito de cointegração em torno de um limite, o que permite levar em consideração as duas maiores críticas ao conceito de cointegração, que são (i) a pressuposição de ajustes instantâneos a cada período, e (ii) simetria no mecanismo de ajuste.

Inúmeras críticas ocorrem para um e outro caso, sendo que no primeiro, a simples presença de custos de transação já é suficiente para inibir os ajustes instantâneos a cada período, enquanto que vários outros argumentos podem contestar a segunda suposição, até mesmo efeitos de resto do mundo *versus* país pequeno (Stigler, 2012).

Embora o trabalho de B&F tenha por foco o desenvolvimento de um mecanismo de correção de erros a partir de limites, eles baseiam o seu

processo de ajuste em um modelo TAR que remetem a outros autores (Chan *et al.*, 1985; Chan e Tong, 1985; Brockwell *et al.*, 1992).

Simplificadamente, o modelo TAR particiona o espaço em múltiplos regimes, cada um deles seguindo um modelo linear próprio (Tsay, 1989), sendo o grande trunfo de um tal modelo a sua capacidade de capturar assimetrias no processo de geração dos dados, uma vez que cada regime conta uma parametrização própria.

Desta forma, fenômenos que dependem da complexa interação de vários elementos, cujo resultado final provavelmente não poderia ser aceitavelmente capturado por um modelo linear comum, podem ser modelados por tais modelos não lineares.

Ao longo dos últimos anos, tais modelos têm sido utilizados, ou seu uso justificado, em atividades relacionadas à modelagem de ativos financeiros (Clements *et al.*, 2004; Bec *et al.*, 2010) e reais (Moral-Carcedo e Vicéns-Otero, 2005; Misiorek *et al.*, 2006; Zhou *et al.*, 2009), variáveis econômicas como inflação (Arruda *et al.*, 2011) índices de produção industrial (Zhou, 2010) e desemprego (Panagiotidis, 2002), entre outros.

Uma preocupação sempre presente nestas modelagens é a justificativa do uso de uma modelagem não linear complexa. Esta justificativa exige que a série de dados seja submetida a algum tipo de teste de existência de não linearidade.

As especificações teóricas para a condução destes testes, bem como diversas formas em que estes podem ser apresentados, podem ser vistas em vários trabalhos citados na literatura, em particular no sumário apresentado por Panagiotidis (2002) e no procedimento usado por Terasvirta (1994).

Em geral, estes procedimentos procuram evidências estatísticas de que os resíduos de regressões lineares ainda apresentem alguma informação contida, que, admitindo-se que o procedimento linear tenha sido razoavelmente eficaz, indicarão a presença de não linearidades no processo de geração dos dados.

O principal objetivo do presente trabalho é verificar se a série de carga demandada a uma distribuidora nacional de energia elétrica encerra

processos não lineares na sua geração de dados, e se pode ser justificado o uso de modelos não-lineares do tipo TAR para sua regressão, ao invés de apenas modelos lineares.

O restante deste trabalho está organizado da seguinte forma: na seção 2 será descrita a metodologia utilizada, seguida da modelagem dos dados na seção 3, com a discussão dos resultados obtidos na seção 4 e, finalmente, a conclusão do trabalho na última seção.

4.2 Metodologia

Dentro desta seção discutiremos os aspectos relativos aos modelos não lineares auto-regressivos com mudança de regime, que serão utilizados nas modelagens aqui empreendidas.

Também discutiremos brevemente as características da série de cargas em mãos, e de como devemos nos preocupar em prepará-la para que possa ser modelada apropriadamente com os modelos pretendidos.

Em seguida falaremos sobre as propriedades desejadas e como se pode verificar sua existência na série em estudo, terminando por descrever como se aplicou o ajuste dos modelos descritos anteriormente.

4.2.1 Modelos Lineares e não lineares de regressão

Os modelos estocásticos puramente lineares são aqueles que obedecem a representação geral da equação (4-1) (Tsay, 2010):

$$x_t = \mu + \sum_{i=0}^{\infty} \phi_i \varepsilon_{t-i} \quad (4-1)$$

onde μ é uma constante,
 ϕ_i são constantes ($\phi_i \in \mathcal{R}$),
 $\phi_1 = 1$,
 ε_t é uma sequência de variáveis aleatórias *iid* e
função de distribuição bem definida

Mais especificamente, o modelo linear usado neste trabalho é um modelo auto-regressivo (AR) simples, que pode ser representado conforme a equação (4-2). Esta representação torna mais intuitiva a relação entre este modelo e aqueles não lineares com mudança de regime, que serão apresentados mais adiante.

$$x_t = \phi_0 + \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_m x_{(t-m)} + \varepsilon_t \quad (4-2)$$

onde $\phi_i, i = 0, \dots, m$ são constantes ($\phi_i \in \mathcal{R}$),
 m é a ordem (número de defasagens) do modelo linear,
 x_t é a variável x no momento t ,
 ε_t é uma sequência de variáveis aleatórias *iid* e função de distribuição bem definida.

Os modelos não lineares utilizados neste trabalho são aqueles conhecidos como modelos de mudança de regime e, basicamente, consistem de modelos lineares distintos em diferentes partições do espaço. Neste trabalho utilizaremos apenas modelos de dois regimes, isto é, um modelo auto-regressivo para o caso da variável limite ser inferior ao valor de limite, e outro para o caso desta variável ser-lhe superior.

Estes modelos atendem pela designação TAR (*threshold auto-regressive*), numa tradução livre significando modelos auto-regressivos em limite (com mudança de regime), e, conforme apontado acima, neste trabalho serão utilizados modelos com apenas dois regimes, superior S e inferior I , e uma variável limite z_t , sendo representados pela equação (4-3).

$$x_t = \begin{cases} \phi_{01} + \phi_{11}x_{t-1} + \phi_{21}x_{t-2} + \dots + \phi_{S1}x_{(t-S)} + \varepsilon_t, & \text{se } z_t > l \\ \phi_{02} + \phi_{12}x_{t-1} + \phi_{22}x_{t-2} + \dots + \phi_{I2}x_{(t-I)} + \varepsilon_t, & \text{se } z_t \leq l \end{cases} \quad (4-3)$$

onde $\phi_{ij}, i = 0, \dots, (S, I)$ são constantes ($\phi_i \in \mathcal{R}$),
 (1,2) referem-se, respectivamente, ao regime superior e inferior,
 (S, I) é a ordem (número de defasagens) do modelo linear,

x_t é a variável x no momento t ,
 ε_t é uma sequência de variáveis aleatórias iid e função de distribuição bem definida,
 z_t é a variável de limite,
 l é o valor limite.

Na situação genérica a variável de limite pode ser qualquer, a mudança de regime sendo, por exemplo, causada por uma variável exógena que se julga ser relevante ao processo.

No caso da variável de limite z_t ser a própria variável x_t , o modelo passa a ser chamado SETAR (*self-exciting threshold auto-regressive*), ou seja, modelo auto-regressivo com mudança de regime em limite auto-excitado. Neste tipo de modelo, a mudança de regime é determinada pelo valor da própria variável que se pretende regredir, naquele momento ou em alguma de suas defasagens (ou combinação linear destes), em comparação ao valor do limite.

A representação de tal modelo é feita conforme a equação (4-4). Na realidade este modelo com mudança de regime em limite, auto-excitado, é o que B&K chamam de TAR em seu trabalho citado anteriormente.

$$x_t = \begin{cases} \phi_{01} + \phi_{11}x_{t-1} + \phi_{21}x_{t-2} + \dots + \phi_{S1}x_{(t-S)} + \varepsilon_t, & \text{se } x_t > l \\ \phi_{02} + \phi_{12}x_{t-1} + \phi_{22}x_{t-2} + \dots + \phi_{I2}x_{(t-I)} + \varepsilon_t, & \text{se } z_t \leq l \end{cases} \quad (4-4)$$

onde $\phi_{ij}, i = 0, \dots, (S, I)$ são constantes ($\phi_i \in \mathcal{R}$),

(1,2) referem-se, respectivamente, ao regime superior e inferior,

(S, I) é a ordem (número de defasagens) do modelo linear,

x_t é a variável x no momento t ,

ε_t é uma sequência de variáveis aleatórias iid e função de distribuição bem definida.

z_t é a variável de limite,

l é o valor limite,

com z_t sendo um dos valores $\{x_t, x_{t-1}, x_{(t-(S,I))}\}$.

O último tipo de modelo não linear com mudança de regime em limite que empregaremos neste trabalho é o chamado LSTAR (*logarithmic smooth transition threshold auto-regressive*).

Este modelo pretende resolver a crítica ao modelo SETAR que condena o fato da equação da média condicional deste não ser contínua, sendo os valores de limite os pontos de descontinuidade da função da média condicional μ_t (Tsay, 2010).

Assim, a transição de valores em um modelo LSTAR não é instantânea ao ser atingido o limite, mas é suavizada por uma função logística de transição, no caso, logarítmica. Sempre lembrando que neste trabalho apenas foram utilizados modelos com dois regimes, podemos ver o modelo LSTAR representado pela equação (4-5).

$$x_t = (\phi_{01} + \phi_{11}x_{t-1} + \phi_{21}x_{t-2} + \dots + \phi_{I1}x_{t-(I)}) (G(z_t, \gamma, l)) + (\phi_{02} + \phi_{12}x_{t-1} + \phi_{22}x_{t-2} + \dots + \phi_{S2}x_{t-(S)}) (1 - G(z_t, \gamma, l)) + \varepsilon_t \quad (4-5)$$

onde $\phi_{ij}, i = 0, \dots, (S, I)$ são constantes ($\phi_i \in \mathcal{R}$),

(1,2) referem-se ao regime superior e inferior, respectivamente,

(S, I) é a ordem (número de defasagens) do modelo linear,

x_t é a variável x no momento t ,

ε_t é uma sequência de variáveis aleatórias *iid* e função de distribuição bem definida,

z_t é a variável limite,

l é o valor limite,

$G(\cdot)$ é a função de transição (suave),

γ é o fator de suavização da mudança de regime,

com z_t sendo um dos valores $\{x_t, x_{t-1}, x_{(t-(S,I))}\}$.

Todos os cálculos apresentados adiante foram feitos utilizando-se o programa *R version 2.15.2 (2012-10-26) -- "Trick or Treat" © The R Foundation for Statistical Computing*.

4.2.2 Dados de Carga e Análise Preliminar

Os dados utilizados são referentes à série de cargas demandadas de uma distribuidora nacional de energia elétrica, em frequência mensal, para o período de janeiro de 2003 até agosto de 2012. O aspecto da série de dados e suas estatísticas descritivas podem ser vistos na Figura 4-1 e Figura 4-2.

Como pode ser claramente observado, a série de cargas apresenta-se não estacionária - o que era esperado - e parece ter uma quebra estrutural em algum ponto no final de 2008 ou início de 2009.

Esta quebra estrutural pode ser facilmente constatada através de um teste de Chow, que apresenta estatística significativa para o mês de out/2008 (os limites de comparação para testes estatísticos usados neste trabalho consideraram um limite de significância de 1%, bastante utilizado em toda a literatura).

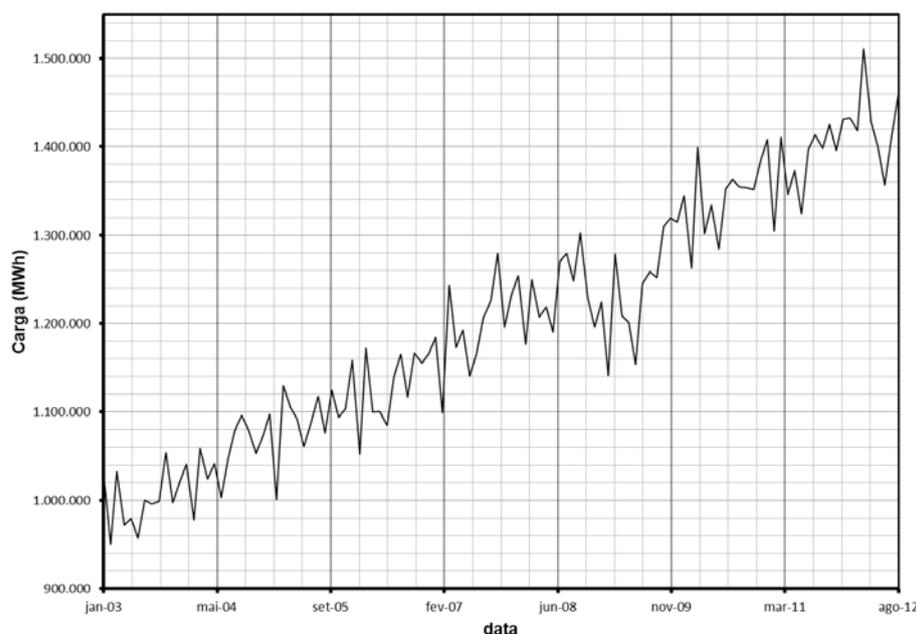


Figura 4-1 – Série de Cargas Demandadas

Um tratamento estatístico da série também permite que se determine se esta é uma série não estacionária com uma tendência, e a

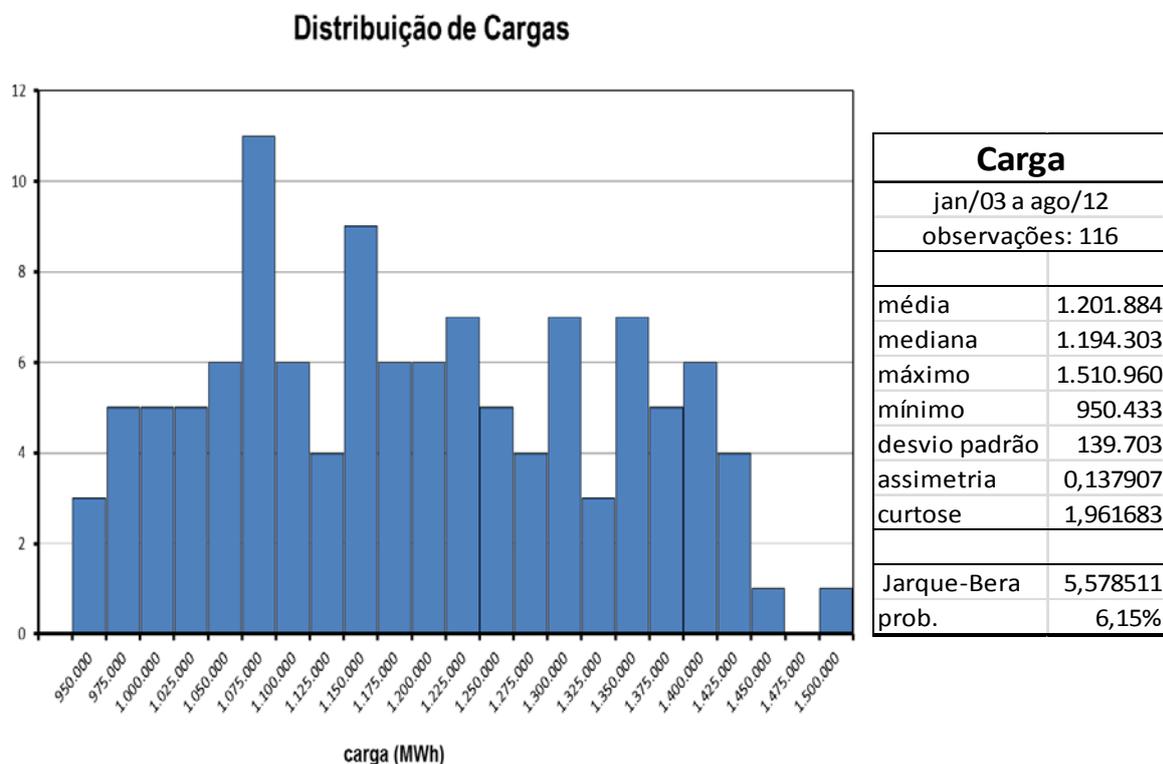


Figura 4-2 – Estatísticas Descritivas da Série de Cargas

forma de determinação destas particularidades foi feita através de uma sequência de testes ADF e KPSS que apresentamos abaixo:

teste ADF → hipótese nula de uma raiz unitária não é rejeitada;

teste KPSS → hipótese nula de estacionaridade por média fortemente rejeitada;

teste KPSS → hipótese nula de estacionaridade por tendência não é rejeitada.

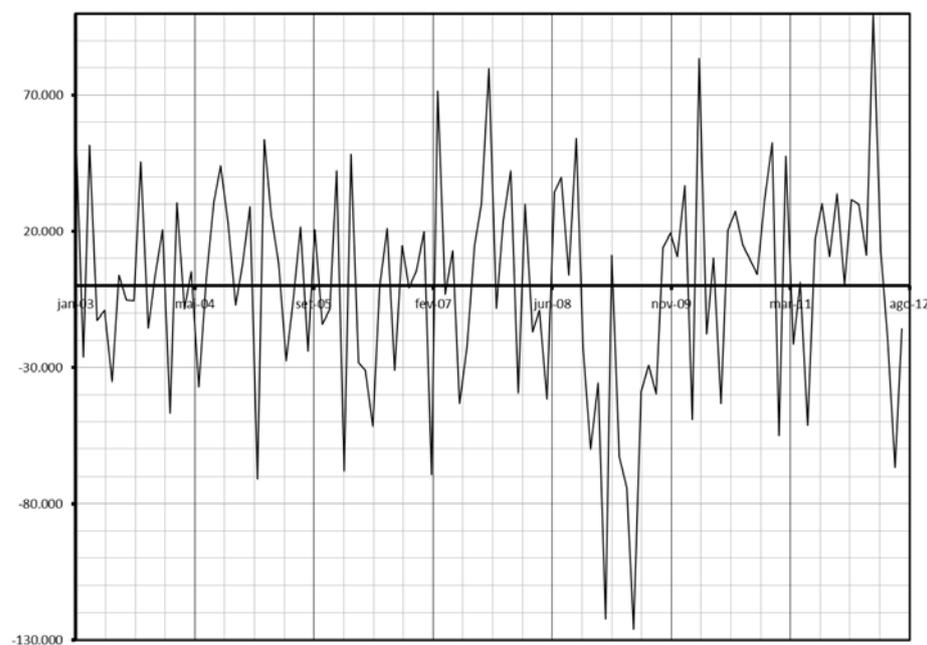


Figura 4-3 – Série de Cargas Demandadas expurgada a Tendência

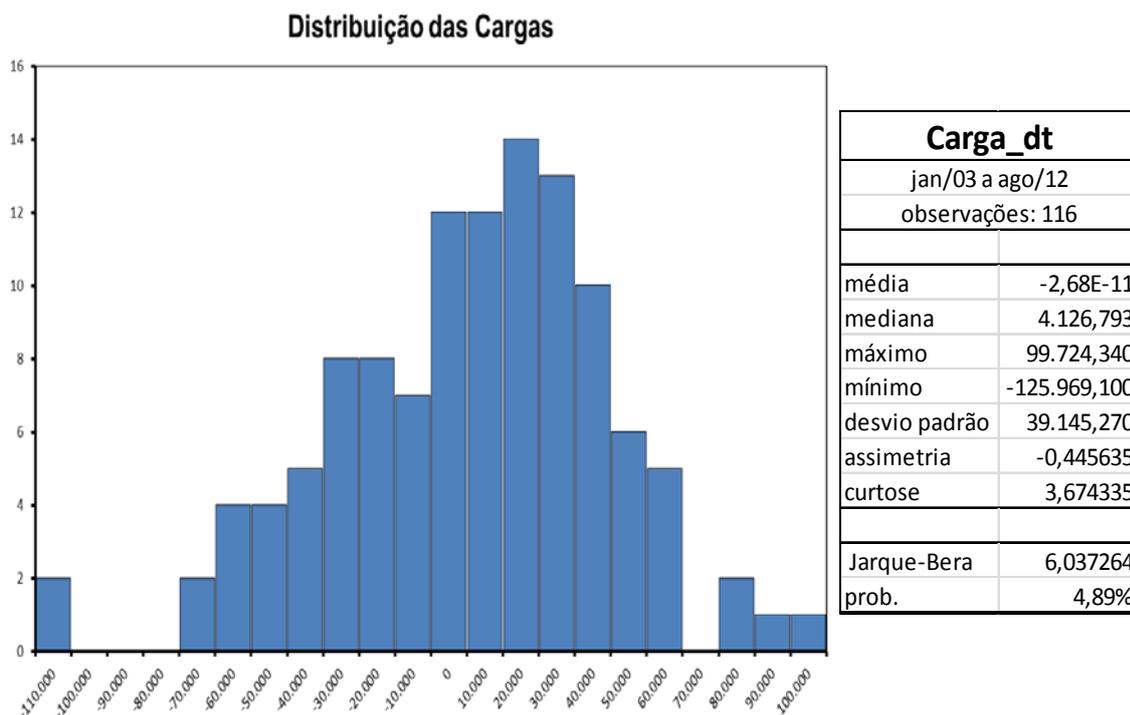


Figura 4-4 – Estatísticas Descritivas da Série de Cargas expurgada a Tendência

Como a série de cargas é indicada ser estacionária por tendência, mas ainda assim é necessário obter sua estacionaridade, o passo seguinte foi ajustar uma tendência linear a série original, sendo que os resíduos desta regressão passaram a formar a série de cargas “sem tendência”, sobre a qual as modelagens foram efetuadas.

A nova série de cargas “sem tendência” é testada para estacionaridade, usando ambos os testes ADF e KPSS: as estatísticas destes testes respectivamente rejeitam e acolhem as hipóteses nulas com grande significância, indicando a ausência de raiz unitária e a presença de estacionaridade. O aspecto desta série e suas estatísticas descritivas estão na Figura 4-3 e Figura 4-4.

Como pode ser observado na Figura 4-3, também nesta série expurgada a tendência, fica aparente a existência de uma quebra estrutural que, assim como no caso anterior, pode ser facilmente confirmada por um teste de Chow.

4.2.3 Teste para presença de não linearidade

Conforme mencionado anteriormente, antes de se proceder a qualquer trabalho como modelos não lineares, intrinsicamente mais complexos do que os lineares, é importante encontrar alguma evidência que demonstre a existência de não-linearidade nos dados.

Dentre várias alternativas encontradas na literatura, empregamos aquela que utiliza um teste BDS para testar o pressuposto de que, após a remoção de linearidade presente nos dados, qualquer estrutura ainda existente deve ser resultante de não-linearidade no processo de geração destes dados (Panagiotidis, 2002).

Assim, a remoção da linearidade é feita através do ajuste aos dados de um modelo linear AR ótimo. Neste caso a condição de otimização do ajuste do modelo AR foi conseguida através da minimização do critério de informação AIC para uma condição de defasagens máxima de 13 que, após observação do correlograma para a série em mãos, parece ser o tamanho apropriado.

O resultado para o modelo ajustado de acordo com as restrições acima foi aquele com as defasagens 1, 8, 11, 12 e 13, para um ajuste conforme mostrado na Tabela 4-1.

Tabela 4-1 – AR(p) “embranquecedor” da série de carga

AR(13). LS Fit. número de observações = 116 , número de parâmetros = 5 log-verossimilhança = -1178.008 , aic = 2366 , bic = 2379.8 , UBIC = 2394.1 média = -2.48581232226727e-12, rmse = 24084.7241351615, R ² = 62.145%
--

As estatísticas do teste BDS para os resíduos desta regressão rejeitam, porém não fortemente (isto é, a um nível de significância inferior a 1% em todas as dimensões estudadas) a hipótese nula de *iid*, o que indica a presença de não linearidade, porém não muita.

Outra forma de detectar não linearidade em uma série de dados é o chamado gráfico de auto-pares. Este gráfico regride os valores da variável contra diferentes defasagens suas, e serve para indicar possíveis situações em que a modelagem linear poderia não ser adequada. Um

exemplo de tal gráfico na Figura 4-5, para a regressão da defasagem 0 contra a defasagem 3, indica que um modelo linear pode não ser adequado para esta série.

Além disso, uma inspeção visual do gráfico da série de cargas, com a tendência expurgada, parece mostrar que há alguma assimetria entre os regimes de subida e descida da série, o que justificaria o uso de um modelo de dois regimes.

Por outro lado, há indicações de que modelos de dois regimes, do tipo TAR, são resistentes a distorções induzidas por pontos de quebras estruturais (Rapach e Wohar, 2008; Enders *et al.*, 2009); a tese seria de que um choque suficientemente grande para provocar uma quebra causaria a mudança de regimes no sistema.

4.2.4 Ajuste dos Modelos

O ajuste dos modelos não lineares de dois regimes, bem como o modelo linear de comparação, foi feito de modo que se pudesse comparar sua performance em previsões fora-da-amostra, isto é, a amostra total foi dividida em duas janelas, uma de estimação e outra de previsão.

A janela de estimação ficou com os valores de Janeiro de 2003 até Agosto de 2011, enquanto a janela de previsão, onde seriam feitas as comparações entre os modelos, ficou sendo de Setembro de 2011 até Agosto de 2012.

Tabela 4-2 – Modelo AR(p) ajustado dentro-da-amostra

AR(13). LS Fit.

número de observações = 104 , número de parâmetros = 5

log-verossimilhança = -1053.977 , aic = 2118 , bic = 2131.2 , UBIC = 2145.5

média = -1514.01880405951, rmse = 23296.800450465, R² = 64.323%

coeficientes	
phi(1)	5,152391e-01
phi(8)	-4,439902e-02
phi(11)	-2,200791e-01
phi(12)	6,933628e-01
phi(13)	5,617112e-01
mu	-1,514019e+03

Tabela 4-3 – Modelo SETAR

Regime Inferior – coeficientes:					
phi1.1	phi1.2	phi1.3	phi1.4	phi1.5	phiL.6
7,230376e-01	-9,593117e-01	3,453830e-01	-9,381861e-01	1,883873e-01	7,977415e-01
phi1.7					
9,589983e-01					
phi1.8	phi1.9	phi1.10	phi1.11	phi1.12	phi1.13
-1,287633e+00	4,262536e-01	-9,747817e-01	-7,223769e-02	1,270569e+00	-1,325833e+00
const1					
-2,394418e+04					
Regime Superior:					
phi1.1	phi1.2	phi1.3	phi1.4	phi1.5	phi1.6
5,253477e-01	-2,057116e-02	-1,831068e-02	5,431288e-02	-2,065432e-01	-1,411937e-01
phi1.7					
-2,138485e-03					
phi1.8	phi1.9	phi1.10	phi1.11	phi1.12	phi1.13
-2,090628e-03	2,074679e-01	1,224960e-01	-2,777654e-01	5,469536e-01	-4,649843e-01
const2					
-2,510720e+03					
Limite:					
Variável: $Z(t) = + (1) X(t)$					
Valor: -43330 (fixo)					
Proporção de pontos: regime inferior: 16,48% regime superior: 83,52%					

Dessa forma, a amostra foi separada em dois períodos que não só permitissem a comparação do desempenho preditivo dos vários modelos, mas também respeitassem a regra de bolso para previsão de modelos auto-regressivos, de que o tamanho do intervalo de previsão não

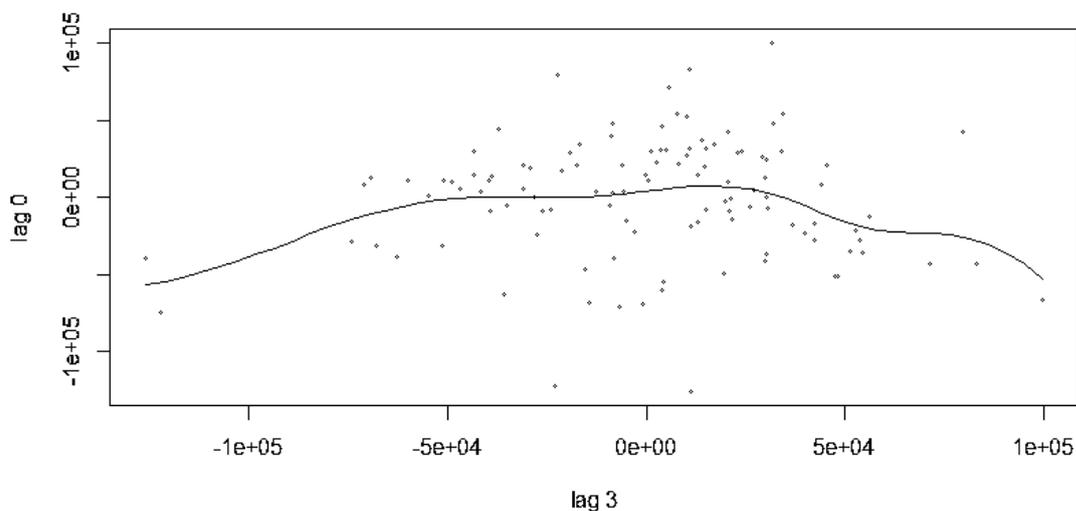


Figura 4-5 - Gráfico de auto-pares entre defasagem 0 e defasagem 3 da série de cargas

superasse o valor das defasagens (Pindyck e Rubinfeld, 1998).

Assim o primeiro modelo a ser ajustado foi o próprio modelo linear que serviu para testar a presença de não linearidades nos dados de carga, sendo que, desta vez, o ajuste do mesmo modelo, isto é, a mesma estrutura auto regressiva, foi feito levando-se em conta a metodologia dentro-da-amostra/fora-da-amostra, onde a estimação é feita em uma janela, e a previsão feita pelo modelo ajustado desta forma é comparada com os dados efetivamente observados na outra janela (Brooks, 2008).

O modelo linear ajustado à janela de estimação pode ser visto na Tabela 4-2. É de interesse notar que o ajuste para o mesmo modelo para as duas coleções de dados virtualmente idênticas, a não ser pelo fato de que o segundo é ajustado apenas para a janela fora-da-amostra, enquanto o primeiro o é para a amostra completa, são diferentes. A discussão desta observação será feita adiante.

Os modelos SETAR e LSTAR, com dois regimes, foram ajustados de acordo com a minimização do critério de informação AIC, para alternativas de número de defasagens dos regimes superior e inferior, defasagem do limite (*threshold delay*), e valores do limite.

Tabela 4-4 – Modelo LSTAR

Regime Inferior – coeficientes:					
const1	phi1.1	phi1.2	phi1.3	phi1.4	phi1.5
-1,971575e+04	8,093387e-01	-1,127860e+00	4,481354e-01	-1,015094e+00	
2,464603e-01					
phi1.6					
7,907542e-01					
phi1.7	phi1.8	phi1.9	phi1.10	phi1.11	phi1.12
1,129041e+00	-1,506867e+00	5,784957e-01	-9,921139e-01	-1,051117e-01	
1,302852e+00					
phi1.13					
-1,446193e+00					
Regime Superior – coeficientes:					
const2	phi2.1	phi2.2	phi2.3	phi2.4	phi2.5
16153,9603229	-0,2614325	1,1404924	-0,4702718	1,0503898	-0,4059780
phi2.6					
-0,9467919					
phi2.7	phi2.8	phi2.9	phi2.10	phi2.11	phi2.12
-1,1350848	1,5080019	-0,4152036	1,0900610	-0,1734193	-0,7418969
phi2.13					
1,0208059					
Parâmetro de suavização: gama = 100					
Limite:					
Variável: $Z(t) = + (1) X(t)$					
Valor: -39752					

Essa busca consumiu algum esforço na medida em que o processo computacionalmente automático necessita uma validação discricionária dos resultados, na medida em que a otimização de um parâmetro interfere com o valor obtido em outro.

Assim, como o modelo LSTAR é naturalmente mais complexo em termos do número de parâmetros a serem ajustados, a sua otimização pode chegar a resultados distintos do SETAR, mais simples.

Em particular, no caso modelo LSTAR, ao permitir que o valor do limite de transição entre regimes fosse calculado automaticamente, o algoritmo de busca e otimização convergia a um valor de limite para mudança de regimes diferente daquele encontrado para o modelo SETAR, em função da escolha do parâmetro de suavização da transição.

Embora isto não tenha alguma recomendação contrária, decidimos ajustar um modelo igual, apenas forçando o valor de limite para mudança de regimes a ser o mesmo que utilizado anteriormente.

Os ajustes obtidos podem ser vistos nas tabelas Tabela 4-3, Tabela 4-4 e Tabela 4-5, onde se pode ver o modelo chamado LSTAR mesmo limite (LSTAR_th=), que para efeito de nomenclatura, refere-se ao modelo

Tabela 4-5 – Modelo LSTAR mesmo limite

Regime Inferior - coeficientes:					
const1	phi1.1	phi1.2	phi1.3	phi1.4	phi1.5
-2,394418e+04	7,230376e-01	-9,593117e-01	3,453830e-01	-9,381861e-01	1,883873e-01
phi1.6					
7,977415e-01					
phi1.7	phi1.8	phi1.9	phi1.10	phi1.11	phi1.12
9,589983e-01	-1,287633e+00	4,262536e-01	-9,747817e-01	-7,223769e-02	
1,270569e+00					
phi1.13					
-1,325833e+00					
Regime Superior - coeficientes:					
const2	phi2.1	phi2.2	phi2.3	phi2.4	phi2.5
21433,4586187	-0,1976899	0,9387406	-0,3636937	0,9924989	-0,3949305
phi2.6					
-0,9389352					
phi2.7	phi2.8	phi2.9	phi2.10	phi2.11	phi2.12
-0,9611368	1,2855424	-0,2187857	1,0972777	-0,2055277	-0,7236155
phi2.13					
0,8608483					
Parâmetro de suavização: gama = 150					
Limite:					
Variável: $Z(t) = + (1) X(t)$					
Valor: -43330					

LSTAR ajustado de forma a que o valor do limite de transição seja o mesmo do que aquele utilizado para o ajuste do modelo SETAR.

Vale observar que pode ser facilmente visto nas tabelas respectivas, que o valor do parâmetro de suavização (gama) fica alterado entre os dois regimes LSTAR, justamente porque este parâmetro é ajustado automaticamente, por otimização. Como foi observado anteriormente, em algumas ocasiões pode tornar-se necessária uma intervenção manual, de forma que se possa proceder a um ajuste que se percebe como o melhor, do ponto de vista de comparação dos modelos.

Tabela 4-6 – Erros de Previsão MAPE

	Linear	setar	lstar	lstar_th=
set-11	53%	7%	4%	7%
out-11	95%	56%	62%	56%
nov-11	2588%	184%	701%	184%
dez-11	93%	81%	84%	81%
jan-12	3%	23%	18%	23%
fev-12	647%	695%	679%	695%
mar-12	65%	61%	62%	61%
abr-12	298%	252%	256%	252%
mai-12	151%	208%	196%	208%
jun-12	46%	57%	54%	57%
jul-12	195%	254%	189%	254%
ago-12	41%	38%	51%	38%
total	356%	160%	196%	160%

Tendo sido feito o ajuste dos modelos de interesse para a série de cargas disponível, procedemos a efetuar previsões com cada um deles, para o período da janela de previsão de forma a poder comparar os valores de erros MAPE de cada uma destes, entre si.

As previsões feitas pelos quatro modelos utilizados (linear, SETAR, LSTAR e LSTAR_th=) são apresentadas na Figura 4-6.

Os erros MAPE para estas previsões foram calculados e estão listados na Figura 4-7. Estes valores são apresentados na Tabela 4-6, juntamente com o valor total das previsões para 12 períodos, período considerado longo, porém de acordo com a regra de bolso apresentada anteriormente.

$$MAPE = \frac{100\%}{n} \times \sum_{i=1}^n \left| \frac{x_{o,i} - x_{p,i}}{x_{o,i}} \right| \quad (4-6)$$

onde n é o número de previsões/observações,

x é a variável sendo estudada,

os subscritos o e p referem-se a observado e previsto.

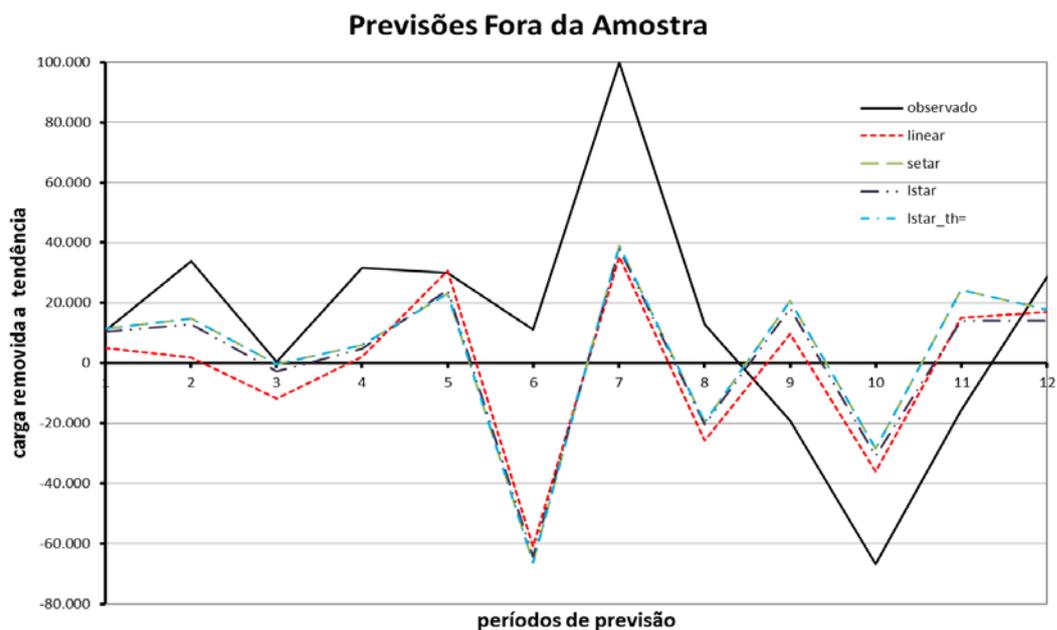


Figura 4-6 – Comparação de Previsões dos Modelos lineares e não lineares

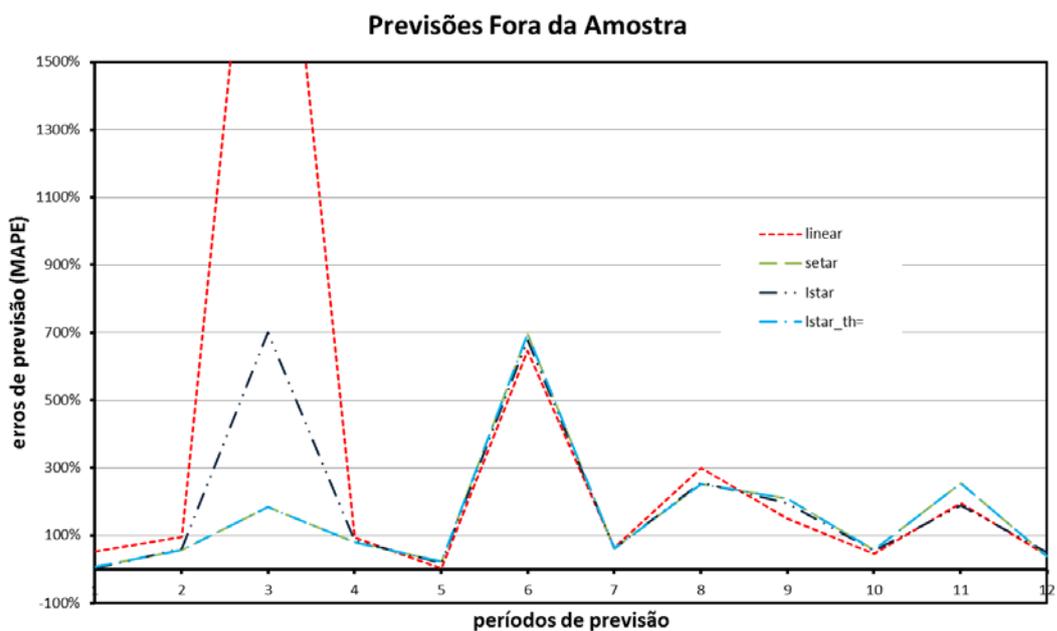


Figura 4-7 – Erros de Previsão MAPE

Os erros MAPE, ou Média dos Erros Percentuais, são calculados de acordo com a fórmula descrita na mesma equação (4-6).

4.3 Resultados e Discussão

Como se pode observar, os erros de previsão, para todos os modelos foram extremamente altos, principalmente se considerados os erros totais, para os doze meses.

De acordo com a literatura, este tipo de modelo, modelos auto-regressivos, não devem ser utilizados para previsões de muitos períodos, devendo ser usados, preferencialmente, para previsões de curto prazo.

Ainda assim, a performance preditiva dos modelos não lineares, conforme comparadas pelos erro de previsão MAPE, mostrou-se ser muito maior do que as previsões feitas pelo modelo linear: o erro observado para as previsões dos modelos não lineares foi, no mínimo cerca da metade do valor conseguido com a previsão linear.

Uma consideração a ser feita é sobre a possível influência da presença de quebras estruturais na série de cargas, certamente originadas a partir da crise financeira de 2008.

Tabela 4-7 – Estatísticas do Teste de Estabilidade Estrutural de Chow

Teste de Quebra Estrutural de Chow : 2008M11 (série de cargas sem tendência)			
Hipótese Nula: Não há quebras no ponto especificado			
Regressores Variáveis: todas as variáveis da equação			
Amostra da Equação: 2003M01 2012M08			
Estatística-F	7,272387	Prob. F(2,112)	0,0011
Teste de Quebra Estrutural de Chow: 2008M11 (série de cargas no regime superior)			
Hipótese Nula: Não há quebras no ponto especificado			
Regressores Variáveis: Todas variáveis da equação			
Amostra da Equação: 2003M01 2011M08			
Estatística-F	0,938173	Prob. F(1,87)	0,3354

Os modelos lineares, de forma geral, são afetados por quebras estruturais e os modelos de múltiplos regimes, como mencionado acima, são resistentes a este tipo de fenômeno. Neste último caso, possivelmente pelo fato de que um choque suficientemente grande para causar uma quebra forçaria a mudança de regime, em primeiro lugar. Veja ilustração do caso em mãos, através de estatísticas do teste de Chow, na Tabela 4-7.

Entretanto, o que de fato se pode observar neste caso é que, para os modelos incorporando transição de regimes, como no caso do SETAR e LSTAR aqui utilizados, a escolha de um ponto limite de transição leva a uma situação onde a quebra estrutural da série temporal é efetivamente eliminada quando do ajuste de dois modelos, um para cada regime acima e abaixo do limite.

Por exemplo, utilizando-se o limite de -43330, adotado em modelos SETAR e LSTAR acima, efetivamente retirá-amos da série do regime superior os possíveis pontos de quebras estruturais do final de 2008, como podemos observar na Figura 4-8.

Uma vantagem adicional do tratamento não linear é permitir uma possível melhora devido a incorporação de não linearidades intrínsecas ao processo de demanda de carga ao longo do tempo.

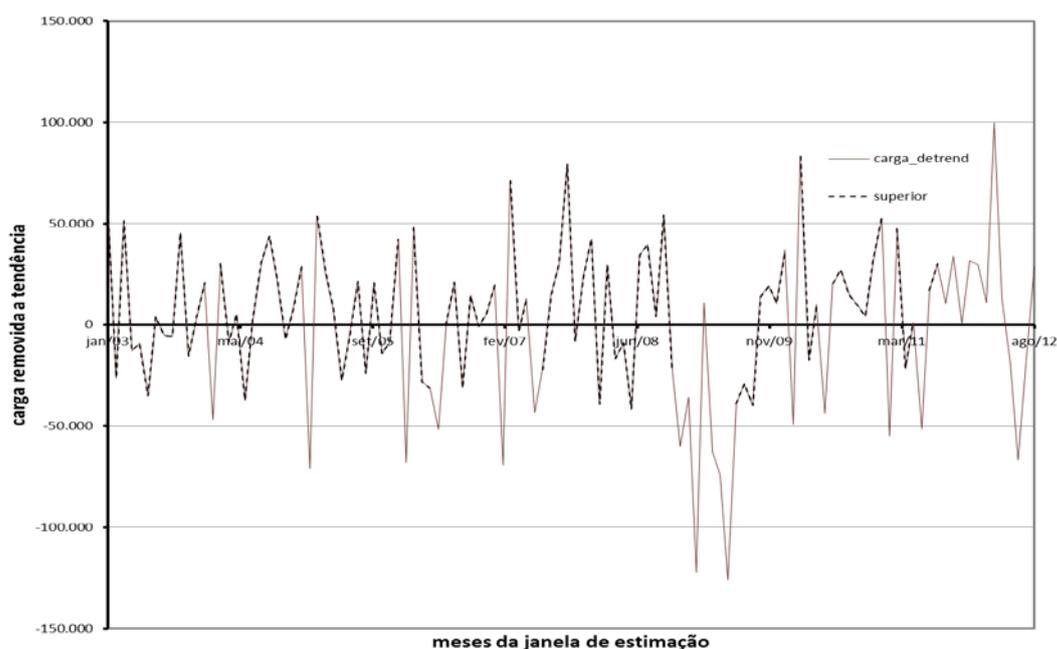


Figura 4-8 – Superposição da série completa de cargas e daquela do regime superior

Um desses fatores seria devido à assimetria de comportamento em dias frios e dias quentes (os chamados HDD e CDD), embora possamos debater que na situação observada não se pode esperar grande influência dos dias frios na temperatura uma vez que pouco se necessita de aquecimento elétrico na área da amostra observada (Rodrigues, 2012).

Também é interessante observar a performance preditiva dos modelos sendo afetada pela escolha do valor do limite de transição entre os dois regimes, no caso dos modelo não lineares SETAR e LSTAR.

A simples mudança do valor limite de transição dos regimes, no caso dos dados e da divisão de janelas ora estudada, tem considerável influência sobre o resultado dos erros de previsão aqui estudados neste trabalho.

Uma observação dos erros MAPE cumulativos para diferentes valores de limite de transição é feita na Tabela 4-8, para um modelo que tem variação apenas no limite de transição (th), sendo mantidos constantes os demais parâmetros.

É possível ver que, no caso da série estudada (e para a escolha de janelas de estimação e previsão feitas aqui!), os erros acumulados para um limite de transição igual àquele do modelo SETAR, e para os valores

Tabela 4-8 – Erros MAPE Cumulativos por períodos de previsão

Istar, dois regimes, mL=13, MH=13, gamma=100, limite (th) variável					
período	th = -43330	th = -39752	th = -36174	th = -32596	th = -29018
1	7%	4%	5%	39%	44%
2	32%	33%	28%	51%	51%
3	82%	255%	199%	287%	229%
4	82%	213%	170%	236%	191%
5	70%	174%	140%	192%	156%
6	174%	258%	230%	263%	232%
7	158%	230%	206%	234%	208%
8	170%	233%	215%	233%	214%
9	174%	229%	213%	232%	214%
10	162%	211%	197%	214%	198%
11	171%	209%	197%	214%	200%
12	160%	196%	184%	199%	186%

de limite de transição (*th*) e parâmetro de suavização (*gamma*) calculados automaticamente por mínimos quadrados “concentrados” (Leybourne *et al.*, 1998), o valor igual ao do SETAR ofereça melhores previsões.

Por outro lado isto pode ser, exatamente, um exemplo do que se referiu ser “manipulação da amostra”, como destacado no capítulo 3, seção 3.2.3, ou seja, o resultado de uma previsão melhor por determinado modelo pode ser atribuído à mera sorte.

Neste caso, o procedimento de “minerar” os dados disponíveis (*mining the data*) passaria exatamente pelo mesmo caminho mostrado acima, qual seja a “experimentação” de parâmetros de forma a maximizar o resultado pretendido, no caso em tela, um menor valor do MAPE total.

4.4 Conclusão

A partir do trabalho exposto acima podemos fazer tirar algumas conclusões sobre a utilidade dos modelos não lineares com mudança de regimes, do tipo conhecido como TAR, para a modelagem de séries de carga de energia elétrica.

Em primeiro lugar, estes modelos parecem ter uma real utilidade na modelagem deste tipo de variável que pode ser afetada assimetricamente por fatores que são ligados ao ambiente social e econômico, como o estado da economia, em geral, e do ambiente físico, como no caso da temperatura.

O fato destes modelos serem baseados no valor de limites arbitrários, determinantes da mudança entre múltiplos regimes, faz com que a capacidade de resposta assimétrica seja facilmente implementada.

Por outro lado, quando se adota modelos lineares, de fácil ajuste em cada um dos vários regimes, o seu uso pode tornar-se bastante conveniente e permitir grande versatilidade e experimentação com diversas variáveis.

Por outro lado, a resistência intrínseca destes modelos a quebras estruturais na série de valores observados permite que seu uso seja feito

para representar situações em que mudanças determinísticas são observadas: neste caso foi mostrado o uso deste tipo de modelo adaptado a uma série de demanda de cargas que mostra uma quebra estrutural em função de crise financeira de 2008.

Neste trabalho procuramos mostrar que a capacidade de previsão destes modelos pode ser bastante superior àquelas dos modelos auto-regressivos tradicionais, embora os modelos em cada regime, auto-regressivos e lineares cada um deles, ainda estejam sujeitos às limitações de uso no curto prazo e não sejam bem adaptados às previsões de múltiplos períodos.

Algumas recomendações também podem ser feitas a partir dos resultados observados aqui:

- mesmo em situações em que a não linearidade do comportamento da variável observada não seja grande ou óbvia, pode ser vantajoso o uso destes modelos;
- a dispensa do uso de variáveis exógenas pelos modelos do tipo TAR auto-excitados, mas ainda assim com capacidade de reagir bem a assimetrias de resposta é uma vantagem decisiva no seu uso;
- o uso deste tipo de modelos incorpora uma vantagem extra, através de sua resistência a quebras estruturais na série estudada.

Para trabalhos subsequentes, sugerimos que sejam feitos mais estudos a respeito da escolha do valor de um limite de transição e, considerando a escolha discricionária, em função de evidências ambientais, contra uma feita automaticamente, baseada em critérios numéricos – sempre lembrando dos critérios/testes de determinação de capacidade preditiva superior.