



ISSN 2175-6295 Rio de Janeiro- Brasil, 12 e 13 de agosto de 2010

## MODELO HPA PARA SÉRIES DE TEMPO: APLICAÇÃO À PREVISÃO HORÁRIA DE CARGA ELÉTRICA

**Schiane Nogueira Ouverney Barroso**

PUC - Rio - Departamento de Engenharia Elétrica  
Rua Marquês de São Vicente, 225, Gávea, Rio de Janeiro, RJ, 22453-900.  
schai.net@gmail.com

**Reinaldo Castro Souza**

PUC - Rio - Departamento de Engenharia Elétrica  
Rua Marquês de São Vicente, 225, Gávea, Rio de Janeiro, RJ, 22453-900.  
reinaldo@ele.puc-rio.br

### RESUMO

A fim de garantir a operação energética, diversas abordagens têm sido empregadas com vistas à previsão de carga de energia a curto prazo. Dentre elas, pode-se citar os modelos híbridos de Séries Temporais, Lógica Fuzzy e Redes Neurais e o Método de Holt-Winters com múltiplos ciclos que é a principal ferramenta utilizada atualmente. O HPA (Hierarchical Profiling Approach) é um modelo que decompõe a variabilidade dos dados de séries temporais em três componentes: determinística, estocástica e ruído. A metodologia é capaz de modelar observações únicas, periódicas e aperiódicas, e ao mesmo tempo, serve como uma técnica de pré-branqueamento. Este trabalho tem por objetivo implementar o HPA e testar as previsões de curto prazo geradas pelo modelo, utilizando dados de carga de energia de alta frequência, além verificar a adequação da metodologia a dados de energia brasileiros. Foram utilizados dados demanda de energia elétrica de 15 em 15 minutos para um estado da região Sudeste do Brasil. As previsões forneceram um MAPE de 5,46% o qual é bem inferior ao valor fornecido pelo modelo ingênuo usado para comparação (15,08%).

**Palavras-chave:** HPA, Hierarchical Profiling Approach, ARIMA, dados de alta frequência, previsão de carga.

### ABSTRACT

In order to ensure energy operation, different approaches have been employed in the load forecasting in the short term. For example, the hybrid models of Time Series, Fuzzy Logic and Neural Networks and Holt-Winters Method with multiple cycles which is the main tool used today. The HPA (Hierarchical Profiling Approach) is a model that decomposes the variability of time series data into three components: deterministic, stochastic and noise. The methodology is efficient to modeling single observations, periodic and aperiodic, and at the same time, it works as a technique of pre-whitening. This paper aims to set the HPA and test the short-term forecasts generated by the model using high-frequency energy data, and verify

the adequacy of the methodology to Brazilian energy data, since their predictive ability is still unknown front such time series. In this work were used electric power demand data of 15 to 15 minutes to a state of southeastern Brazil. The forecasts provided a MAPE of 5.46% while the naive model used for comparison provided a MAPE of 15.08%.

**Keywords:** HPA, Hierarchical Profiling Approach, ARIMA, high frequency data, load forecasting.

## 1. Introdução

A transmissão de energia elétrica entre as regiões de geração e consumo é um processo que envolve diversos fatores importantes como qualidade e confiabilidade. Por isso, um planejamento adequado é parte essencial do processo, no qual devem ser levadas em consideração necessidades futuras de distribuição, que podem ser projetadas através da utilização de técnicas de previsão.

A previsão de curto prazo, que envolve dados de alta frequência, é essencial para a confiabilidade e eficiência da operação do setor elétrico, fazendo com que a alocação da carga seja feita de forma eficiente, além de indicar possíveis distorções nos próximos períodos (dias, horas, ou frações de horas).

Sendo assim, é de suma importância produzir uma boa previsão para a variável “carga elétrica”, a qual depende exclusivamente do usuário e de fatores que interferem no cotidiano do mesmo, como o clima, a economia e o nível social. Com uma previsão de qualidade para valores futuros da carga elétrica, pode-se melhorar, em muito, procedimentos intrínsecos ao processo global de distribuição de energia, além, é claro, de corrigir possíveis problemas pré-existentes. Além disso, a previsão de carga de energia, evita fatos como o desperdício, a escassez, e a má alocação de recursos.

Com isso, a fim de garantir a operação energética no país, diversas abordagens têm sido empregadas com vistas à previsão de carga a curto prazo. Dentre elas os modelos híbridos de Séries Temporais, Lógica Fuzzy e Redes Neurais e o Método de Holt-Winters com múltiplos ciclos que é a principal ferramenta utilizada atualmente.

Em 2001, Hasan Al-Madfai desenvolveu o HPA (Hierarchical Profiling Approach), uma metodologia de modelagem que promete fornecer previsões superiores às abordagens tradicionais. O HPA decompõe a variabilidade dos dados de séries temporais em três componentes: determinística, estocástica e ruído. A identificação dos perfis de carga é, então, modelada através de funções contínuas acumuladas aditivamente na componente determinística. Assim, a componente estocástica pode ser modelada utilizando uma abordagem adequada, geralmente um modelo ARIMA, e o ruído é assumido como aleatório.

O HPA é capaz de modelar observações únicas, periódicas e aperiódicas, enquanto, ao mesmo tempo, serve como uma técnica de pré-branqueamento. Segundo alguns trabalhos já publicados, a aplicação desta técnica melhora significativamente a confiabilidade das previsões em termos das métricas MAPE e RMSE.

Este trabalho tem por objetivo implementar a metodologia e testar as previsões de curto prazo geradas pelo modelo HPA, utilizando dados de carga de energia de alta frequência, além verificar a adequação da metodologia a dados de energia brasileiros, visto que sua habilidade preditiva ainda é desconhecida frente a tais séries de tempo. Na seção 2 é apresentada uma breve descrição da metodologia Hierarchical Profiling Approach. Em seguida, na seção 3 são apresentados alguns resultados da análise estatística da série demanda de energia elétrica de 15 em 15 minutos para um estado da região Sudeste do Brasil. A aplicação da modelagem HPA aos dados considerados é mostrada na seção 4. A seção 5 apresenta uma comparação entre as previsões para uma semana à frente fornecidas pelo HPA e sua comparação via MAPE com o método ingênuo de previsão. Por fim, na seção 6 são apresentadas as principais conclusões do trabalho.



## 2. Metodologia

### Hierarchical Profiling Approach

Segundo Al-Madfai (2001) um perfil pode ser definido como uma mudança típica de comportamento de uma série temporal durante, ou em resposta a um evento conhecido. A metodologia HPA se baseia na criação e identificação de perfis pré-existentes nos dados para gerar previsões ou simplesmente explicar a dinâmica que rege seu comportamento.

A modelagem HPA decompõe a variabilidade da série temporal em componentes de caráter determinístico, estocástico e ruído para identificar os padrões e modelar os dados.

Os perfis identificados são tipicamente modelados utilizando funções contínuas acumuladas aditivamente na componente determinística, porém, outras abordagens alternativas podem ser utilizadas (Al-Madfai, 2009). A componente estocástica, resultado do ajuste da componente determinística, pode ser modelada utilizando uma abordagem adequada, geralmente um modelo ARIMA. O ruído é assumido como aleatório.

A forma geral do modelo HPA é:

$$y_t = f(t) + Z_t \quad (1)$$

onde  $y_t$  é a série observada,  $f(t)$  é a componente determinística que modela os perfis e  $Z_t$  é a componente estocástica a ser modelada.

A componente determinística visa, via procedimentos iterativos, perfilar os eventos atípicos junto com as outras componentes, incluindo tendência, sazonalidade e ciclos que a série pode conter. Tal componente contém os perfis da série e pode ser identificada através de análises quantitativas e qualitativas ou através da ajuda de especialistas (Al-Madfai, 2005). Os perfis identificados são acumulados aditivamente de forma a capturar o máximo de informação determinística proveniente da série.

O HPA combina, assim, diferentes níveis de perfis. O primeiro nível modela e corrige as variações dentro do ano. O segundo nível trata os comportamentos atípicos, tais como feriados e mudanças provocadas pelas estações do ano. O nível seguinte trata o comportamento geral da série durante o ano, incluindo tendência, sazonalidade e ciclos.

Este último perfil pode ser modelado através da aplicação de uma Regressão Harmônica com tendência polinomial cuja equação é:

$$y_t = a + bt + ct^2 + \dots + \sum_i^{N/2} \left( a_i \cos\left(\frac{2\pi i}{N} t\right) + b_i \text{sen}\left(\frac{2\pi i}{N} t\right) \right) \quad (2)$$

onde  $y_t$  são as observações obtidas após o nível 2,  $a$ ,  $b$ ,  $c$ ,  $a_i$  e  $b_i$  são parâmetros a serem estimados.

O objetivo principal da Regressão Harmônica na análise de séries temporais é aproximar uma função do tempo por uma combinação linear de harmônicos (senos e cossenos), os coeficientes dos quais são as transformadas de Fourier discretas da série (Bloomfield, 1976).

Dado o ajuste do perfil final via Regressão Harmônica, os perfis podem ser combinados.

O perfil geral é, então, composto pela agregação de todos os sub-perfis mencionados anteriormente:

$$f(t) = \sum f_i(t) \quad (3)$$

onde  $f_i(t)$  corresponde a cada perfil ajustado nas primeiras etapas. E os desvios entre a série original e o perfil geral são dados por:

$$y_t - f(t) = Z_t \quad (4)$$

$Z_t$  é a componente estocástica resultante da modelagem dos perfis. O último passo do HPA tem por objetivo a construção de um modelo de Box & Jenkins (1970) que consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA (p,d,q). Além do modelo ARIMA, outras abordagens como: Redes Neurais Artificiais, Método Holt-Winters e Amortecimento exponencial podem ser usados para modelar a componente estocástica.

Dadas as previsões para a componente estocástica, as previsões para a série original são obtidas pela agregação destas com as previsões da componente determinística construída a partir dos perfis.

A figura 1 apresenta o fluxograma que resume a modelagem HPA.

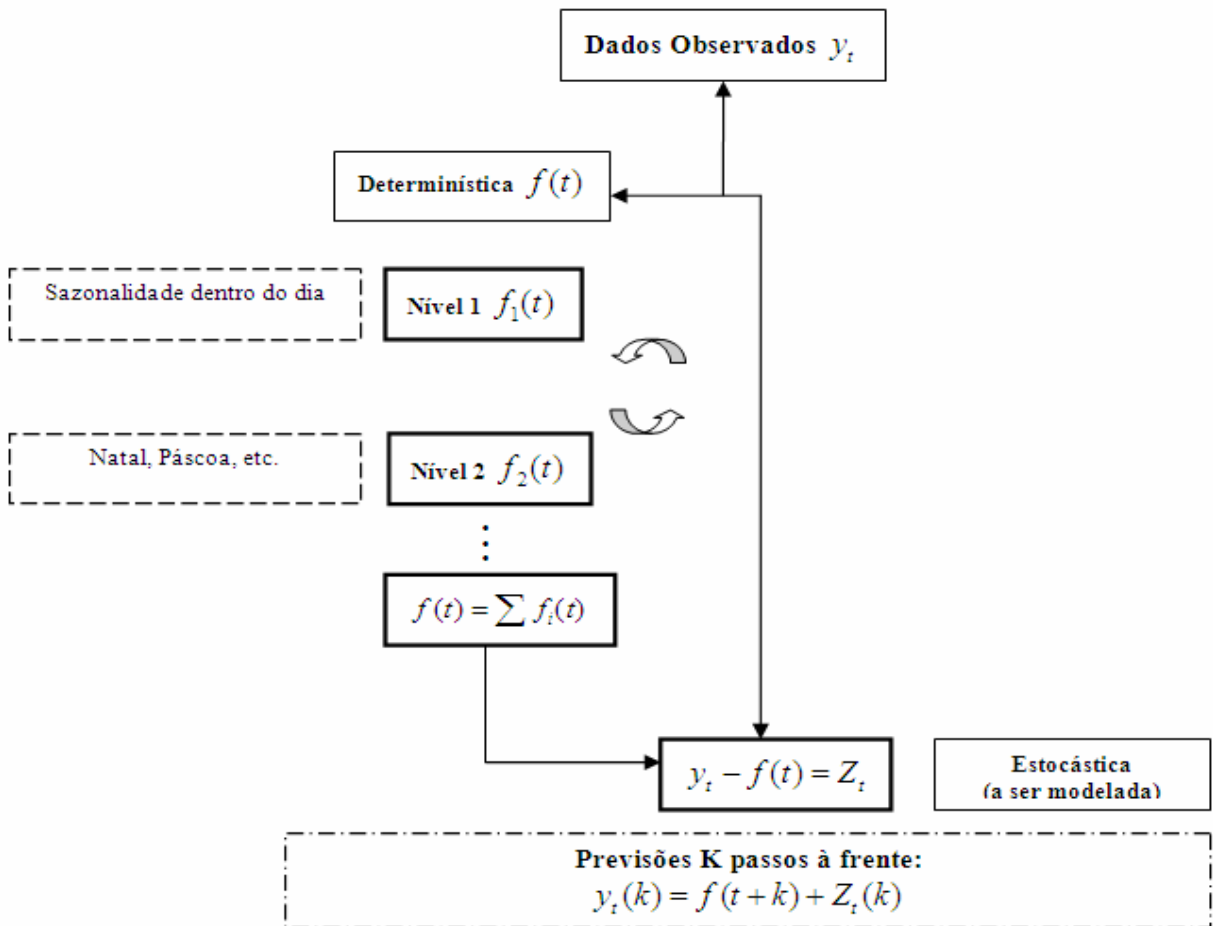


Figura 1 – Fluxograma que representa a modelagem HPA.

### 3. Descrição dos dados

Os dados utilizados no trabalho, fornecidos por uma concessionária de energia elétrica da região Sudeste do Brasil, referem-se à demanda de energia elétrica em MWh no período compreendido entre maio de 2002 a dezembro de 2006. Os dados são verificados a cada 15 minutos, fornecendo 96 observações diárias e 163.676 no total. O objetivo é fazer a previsão a cada 15 minutos para sete dias à frente, ou seja, a previsão será feita para 672 passos à frente.

A série pode ser observada na figura 2.




Figura 2 – Carga a cada quinze minutos de todo o histórico.

Apesar da grande quantidade de dados pode-se perceber, claramente, a presença de uma componente sazonal anual, através da presença de cinco blocos distintos de dados, e uma leve tendência crescente.

### 4. Aplicação da Metodologia

Para os dados de demanda de energia elétrica considerados foram identificados três níveis de perfis. No nível 1 foi tratado o padrão dentro do dia através da estimação de polinômios relativos aos dias em que não há a ocorrência de feriados.

Os polinômios foram ajustados via Mínimos Quadrados Ordinários e o grau do polinômio de melhor ajuste foi selecionado de acordo com dois critérios: a minimização do MAPE e maximização do Coeficiente de Correlação de Pearson.

Para cada dia da semana, à exceção das terças, quartas e quintas-feiras que foram agrupadas devido a seu comportamento semelhante, um polinômio foi estimado. Foram, então, ajustados cinco polinômios na primeira etapa.

O perfil ajustado no nível 1 é composto pela série sem o efeito destes padrões. A figura 3 apresenta a série obtida após a correção para o perfil de nível 1. Os picos negativos representam os feriados que não foram ajustados neste nível.




Figura 3 –  
Série obtida após  
o ajuste para o

perfil de nível 1.

O nível 2 do HPA consiste na modelagem de observações atípicas, como os feriados, e outros eventos discrepantes que possam prejudicar as previsões. Neste nível foram ajustados polinômios para os feriados bancários nacionais e estaduais.

Com a finalidade de retirar o efeito dos dias atípicos, a primeira etapa consiste em identificar o dia da semana de ocorrência do feriado e agrupar os dados segundo este critério. Feito isso, o procedimento de modelagem é idêntico ao adotado na modelagem dos dias úteis o nível 1 do modelo.

Um polinômio foi ajustado para o comportamento médio de cada dia da semana de feriado, totalizando sete polinômios.

Os graus dos polinômios foram escolhidos segundo os mesmos critérios adotados para a modelagem dos padrões dentro do dia.

Os feriados e Natal e Ano Novo apresentam comportamento distinto dos demais e, por isso, foram tratados por outra abordagem.

Antes de aplicar os polinômios de feriados para o dia da semana correspondente, estes feriados foram ajustados com a aplicação de fatores de correção calculados a partir do comportamento médio dos respectivos dias da semana do mês de ocorrência (dezembro para o Natal, e janeiro para o Ano Novo). Após a correção, os polinômios obtidos no nível 2 foram aplicados.

A série de nível 2, que pode ser vista na figura 4, é o ruído fornecido pelo ajuste da série original após a eliminação dos efeitos tratados nos níveis 1 e 2.

Nota-se que o nível da série oscila, agora, em torno de zero e que a tendência crescente nos dados é, agora, mais evidente.




Figura 4 –  
Série obtida após  
o ajuste para o  
perfil de nível 2.

O  
comportament  
o geral da série  
que inclui  
tendência,  
sazonalidade e  
outros  
distúrbios  
periódicos é  
tratado no  
nível 3.

Para a  
determinação

da frequência calculou-se um periodograma que apontou a presença de quatro componentes periódicas nos dados, correspondentes a oito horas, um dia, seis meses e um ano (figura 5).




Figura 5 – Periodograma resultante da série obtida no ajuste de nível 2.

Um perfil para esta componente foi criado e modelado segundo a equação 2 cujos parâmetros foram modelados via Mínimos Quadrados Ordinários. A série resultante após a aplicação da equação 4 pode ser observada na figura 6. Nota-se que a componente tendência praticamente retirada dos dados que, agora, comportam-se como um ruído em torno de zero.






Figura 6 – Série  $Z_t$  obtida após o ajuste para o perfil de nível 3

F

A

etapa final de modelagem consiste na estimação de um modelo ARIMA para a componente  $Z_t$ , para obter a previsão final do modelo HPA. As ordens  $p$ ,  $d$ , e  $q$  do modelo de Box & Jenkins e respectivos parâmetros serão estimados e, após a verificação da adequabilidade dos resíduos segundo as exigências de normalidade e ausência de autocorrelação, serão estimadas as previsões sete dias à frente (672 passos).

Tendo em vista tal procedimento, identificou-se um modelo ARIMA(2,0,2).

A equação de previsão do HPA é variante de acordo com o dia semana a ser previsto e se este dia é dia típico ou um feriado.

O valor previsto é fruto da combinação da previsão gerada pelo ARIMA, pela Regressão Harmônica com os parâmetros estimados no nível 3 e do polinômio estimado no nível 1 para dias comuns, ou no nível 2 para dias de feriado.

## 5. Comparação entre as previsões

A fim de verificar o poder preditivo do modelo HPA estimado, foi feita a comparação via critério MAPE com o método ingênuo de previsão. Neste último método a previsão para uma semana a frente é exatamente igual à última semana observada.

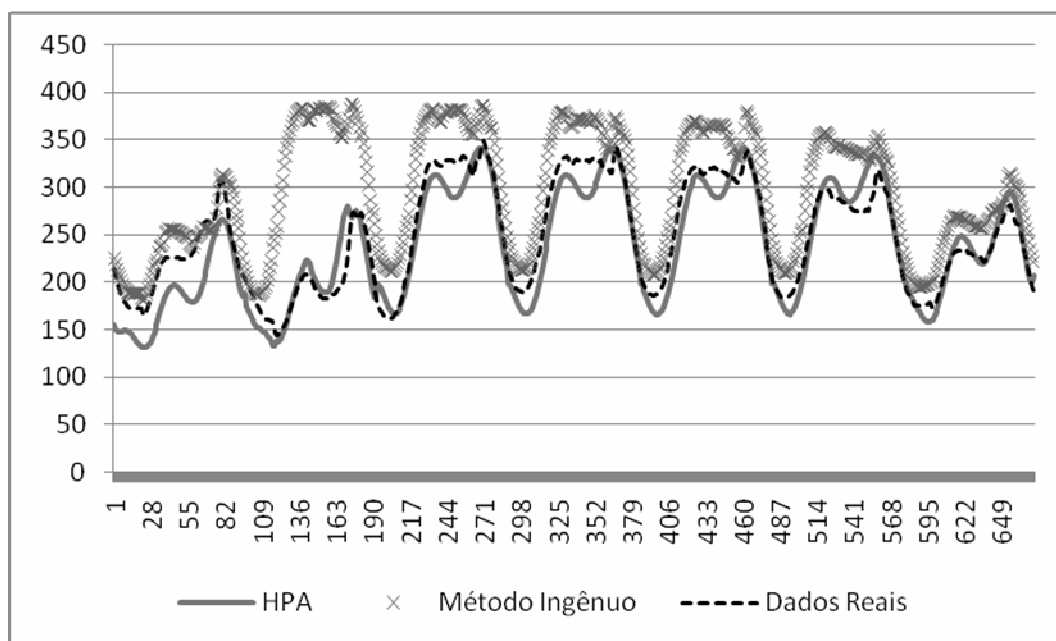
Escolheu-se a semana entre 24 e 30 de dezembro de 2006 para testar o modelo visto que ela compreende 6 dias comuns e 1 feriado para comparação dos modelos.

No método ingênuo as previsões correspondem aos valores observados para a semana compreendida entre 17 e 23 de dezembro de 2006.

As previsões obtidas pela aplicação do HPA forneceram um MAPE 5,46%. Para o modelo de comparação o MAPE observado é de 15,08%.

A comparação gráfica pode ser observada na figura 7. Nota-se que mesmo nos dias de não-feriado onde não há um comportamento tão específico quanto o dia de feriado, as previsões geradas pelo HPA se mostraram mais aderentes.

Figura 7 –  
Comparação



comparação entre as previsões geradas pelo HPA e pelo Método Ingênuo

## 6. Conclusões

O HPA, além de ser uma poderosa técnica de pré-branqueamento, proporciona uma melhor compreensão da dinâmica subjacente aos dados visto que a série é decomposta em níveis e suas componentes podem estudadas a fundo.

Esta metodologia pode, ainda, ser usada para prever em massa e tem a vantagem de poder ser implementada em softwares já existentes.

O HPA pode, ainda, ser visto como uma abordagem quantitativa para incorporar a opinião de especialistas na análise de séries temporais estocásticas.

Tendo em vista a aplicação da metodologia à série de demanda por energia elétrica com dados observados de 15 em 15 minutos, o HPA produziu excelentes previsões e mostrou ter poder preditivo superior ao do método ingênuo de previsão.

Novos trabalhos podem incluir a comparação entre o HPA e outras técnicas de previsão para dados com múltiplos ciclos, como o Método de Holt-Winters, além da inclusão de variáveis explicativas ao modelo como temperatura, etc.

## 7. Referências Bibliográficas

AL-MADFAI, H. Daily electricity demand forecasting: A hierarchical profiling approach. in ETK/NTTS. 2001.

AL-MADFAI, H. Hierarchical Profiling of daily Crime Time Series Data as a Precursor to Modelling. in ISF. 2005. San Antonio, Texas.

AL-MADFAI, H.; AMEEN, J.; RYLEY, A.; The hierarchical profiling approach to STLF of multi-year daily electricity demand in South Wales, University of Glamorgan. 2009.

AL-MADFAI, H.; IVAHA, C.; HIGGS, G.; WARE, A.; CORCORAN, A.; The Simple Spatial Disaggregation Approach to spatio-temporal crime forecasting. International Journal of Innovative Computing, Information and Control, Volume 3, Number 4, 2007.

- AL-MADFAI, H.; AKINWALE, A.; LAKIN, S.; THOMAS, S.; LLOYD, S.; Using HPA Forecasts of Multi-Year Half Hourly Electricity Consumption Data as a Tool in Energy Management, University of Glamorgan. 2009.
- AMARAL, E. Análise harmônica e previsão a longo prazo. In: REUNIÃO INTERNACIONAL DE BIOMETRIA, 1975, Piracicaba. Anais. Piracicaba : Fundação Cargill, 1975. p. 232-271
- ANEEL. Perguntas e respostas sobre tarifas das distribuidoras de energia elétrica/ Agência Nacional de Energia Elétrica. – Brasília 2007.
- BLOOMFIELD, Peter. Fourier analysis of time series: an introduction. New York: J. Wiley, 1976.
- BOX, G. E. P.; JENKINS, G. M. Time Series Analysis, Forecasting and control. San Francisco; Holden-Day, Inc., 1970.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL. Time Series Analysis: forecasting and control. New Jersey, Prentice Hall, 1994.
- BUNN, D. W., FARMER, E. D.. Comparative models for electrical load forecasting. Wiley, Belfast, 1985.
- IVAHA, C.; AL-MADFAI, H.; HIGGS, G.; WARE, A.; The Dynamic Spatial Disaggregation Approach: A Spatio-Temporal Modelling of Crime. Proceedings of the World Congress on Engineering 2007 Vol II. WCE 2007, July 2 - 4, 2007, London, U.K.
- MIRANDA, C. V.; SOUZA, R.C.. Previsão de dados de alta frequência para carga elétrica usando holt-winters com dois ciclos. Dissertação de mestrado, DEE, PUC-Rio, março 2007.
- MONTGOMERY, D.C., JOHNSON, L.A. Forecasting and Time Series Analysis, New York, McGraw-Hill Book Co., 2 ed., 1990.
- MORETTIN, Pedro A.; TOLOI, Cléia M. C. Análise de Séries Temporais. São Paulo: Edgard Blücher, 2006.
- MORETTIN, P. A. ; Mesquita, A.R. ; Rocha, J.G.C. Rainfall At Fortaleza In Brazil Revisited. In: Time Series Analysis and Forecasting, 1985, Toronto. . Amsterdam : North Holland, 1983. v. 6. p. 67-85.
- Souza, R.C., Camargo, M.E. Análise e previsão de séries temporais: os modelos ARIMA, Ijuí, SEDIGRAF, 2004.
- SOUZA, R. C., Métodos Automáticos de Amortecimento Exponencial para Previsão de Séries Temporais, Monografia GSM-10/83, maio 1983.
- SOUZA, R. C., Modelos Estruturais para Previsão de Séries Temporais: Abordagens Clássica e Bayesiana, 17º Colóquio Brasileiro de Matemática, IMPA, 1989.
- VAAGE, K. Detection of Outliers and Level Shifts in Time Series: An Evaluation of Two Alternative Procedures. Journal of Forecasting, No 19, p. 23-37, 2000.
- YOUNG, P. C.; PEDREGAL, D. J.; TYCH, W. Dynamic Harmonic Regression. Journal of Forecasting, 18, p.369-934, 1999.