

SISTEMA FUZZY E AUTOCORRELAÇÃO ESTENDIDA APLICADO A PREDIÇÃO DA DEMANDA DE ENERGIA ELÉTRICA EM RONDÔNIA

PAULO DE TARSO CARVALHO DE OLIVEIRA *, CARLOS TAVARES COSTA JR.*

* Programa de Pós-Graduação, Depto. de Engenharia Elétrica
Universidade Federal do Pará
Rua Augusto Corrêa, 1 - Guamá, 66075-110 Belém, Pará, Brasil

Emails: paulo@unir.br, cartave@ufpa.br

Abstract— The electric power demand planning applied to the forecast is a fundamental factor for an effective business management, these forecasts are based on a process of verification of electric, daily, weekly, monthly and yearly electricity consumption. Current legislation and official control bodies define a projection of demand for strategic planning in the energy segment in Brazil. This paper presents a methodology for the segment of forecasting electricity demand in the short and medium term. The proposed methodology is the implementation of the Model, *Fuzzy* Identification and Extended Autocorrelation applied to Self-Regulating Average Series of Mobile Average, in time series of Electric energy. The data used were authorized by the Concessionaire of Energy of the State of Rondônia. The results, simulated, obtained presented efficient measures in relation to the already consolidated models, demonstrating that the present work is a valid option for electric power management.

Keywords— Fuzzy Systems, Electric Power Demand, Time Series, Extended Autocorrelation Function.

Resumo— O Planejamento de demanda de energia elétrica aplicado a previsão, é fator fundamental para uma gestão efetiva empresariais, estas previsões atentam para um processo de verificações a horárias de consumo de energia elétrica, diárias, semanais, mensais e anuais. A legislação vigente e os órgãos oficiais de controle definem uma projeção de demanda para um planejamento estratégico no segmento de energia no Brasil. Este trabalho apresenta uma metodologia para o segmento de previsão de demanda de energia elétrica, a curto e médio prazo. A metodologia proposta é a implementação do Modelo, Identificação *Fuzzy* e Autocorrelação Estendida aplicado a Séries Sazonais Autorregressivos de Média Móvel, em séries temporais de energia Elétrica. Os dados utilizados foram autorizados pela Concessionária de Energia do Estado de Rondônia. Os resultados, simulados, obtidos apresentaram medidas eficientes em relação aos modelos já consolidados, demonstrando que o presente trabalho é uma opção válida para gestão de energia elétrica.

Palavras-chave— Sistemas *Fuzzy*, Demanda de Energia Elétrica, Séries Temporais, Função Autocorrelação Estendida.

1 Introdução

Em planejamento de energia elétrica, a demanda e o processo de predição, são fatores fundamentais para a contratação de energia elétrica em leilões no Brasil. As concessionárias de energia elétrica definem o Plano Mensal da Operação (PMO), onde seguem regras para garantir uma margem de erro afim de garantir a integridade dos valores a serem contratados evitando-se multas contratuais segundo a Câmara de Comercialização de Energia Elétrica (CCEE). A legislação brasileira aponta os caminhos para este processo, através de pesquisa, melhorando o índice de confiança a ser usado em processos da demanda a contratar, de acordo com BRASIL (2004). As séries temporais podem ser aplicados como modelos construídos sob a estrutura da autocorrelação, modelos combinados autorregressivos e médias móveis, onde séries com números de parâmetros razoáveis, e que caracterizam séries de curto prazo Pollock (1993), e aplicando-se um integrador para composição o modelo obtemos o autorregressivo integrador média móvel para processos não estacionários BOX et al. (1994). Séries que tem característica de sazonalidade estocástica, com múltiplos períodos são ajustadas, formando o modelo sazonal autorregressivo integrado de média móvel Morettin

and Toloi (2006). O estudo de caso de séries temporais de energia elétrica a curto prazo, são de relevantes para o consumo e previsão de demanda a contratar, e está relacionado a hora do dia, dia da semana, feriados, sábados e domingos, compondo séries de ciclos médios Rodrigues (2002). A implementação do conhecimento especialista na lógica *fuzzy*, Zadeh (1965), introduz uma concepção da inteligência artificial, que é implementada na demanda de energia elétrica a curto prazo, sendo implementado por Andrade (2010). O uso de combinações matemáticas para previsão de demanda e predição são apresentado por Darbellay and Slama (2000).

2 Propósito

Distribuidoras de energia planejam suas operações sobre a demanda de energia a contratar, sendo uma necessidade conter o menor erro possível no processo da modelagem, não comprometendo assim as previsões a curto prazo, para tal, é apresentado neste trabalho um modelo desenvolvido em Carvalho (2016), com aplicação as previsões de energia elétrica, sendo uma proposta científica a ser utilizada, tendo em conclusão à eficiência nos resultados apresentados a série histórica da demanda de energia elétrica.

3 Fundamentação

Para o processo de identificação de sistemas de energia elétrica através dos modelos autorregressivos integrador de média móvel, e a séries temporal *fuzzy* aplicados em séries sazonais de energia elétrica, onde seu dimensionamento é através da função de autocorrelação estendida, e monitorada por critérios de comparação de erros.

3.1 Series Temporais

Modelos padrão e combinados com outras técnicas, apresentam soluções para melhoria do processo de predição Wei et al. (2006). Os modelos em questão, são apresentados como ARMA, ARIMA, SARIMA e FSARIMA com binado com autocorrelação estendida.

3.1.1 Modelo ARMA

O processo autorregressivo que afeta o sinal real Z_i , é dimensionado pelo polinômio de coeficientes a_i com fator p , no lado esquerdo da equação (1), o polinômio com coeficientes b_i , influenciam a média móvel e é dimensionado por q , definindo por ARMA (p, q) . Neste caso não existe influência externa, somente o ruído e_i influencia o sinal, bem como, os valores passados, na predição do próprio sinal, para cada a_t e t o processo é normal $\mathcal{N}(0, \sigma^2)$, e para definir o modelo, Tsay and Tiao (1984) propõem o uso da autocorrelação estendida.

$$Z_i - a_1 Z_{i-1} - \dots - a_p Z_{i-p} = e_i - b_1 e_{i-1} - \dots - b_q e_{i-q} \quad (1)$$

3.1.2 Modelo ARIMA

A Introdução do operador de translação denotado por B , e delta é a variação do sinal Z_i , em diferença com o antecessor Z_{i-1} , definindo o no modelo um integrador, visto na equação (2).

$$\Delta = (1 - B) \quad (2)$$

A série pode ser diferenciada d vezes, como mostra a equação (3), definindo um modelo não estacionário. Em (4), a equação apresenta seus coeficientes com a mesma dimensão do operado.

$$W_t^d = \Delta^d Z_t \quad (3)$$

O processo de estimação do modelo ARIMA (p, d, q) em (4), por verossimilhança, podem ser definidos usando valores iniciais para os W 's e para os coeficientes, a 's, sendo dois procedimentos, um condicional supostos valores conhecidos, outro incondicional que são valores iniciais estimados, Hamilton (1994).

$$(1 - \phi_1 B - \dots - \phi_p B^p) (1 - B)^d Z_t = (1 - \theta_1 B - \dots - \theta_q B^q) a_t \quad (4)$$

3.1.3 Modelo SARIMA

Quando há sazonalidade determinística, t é uma função determinística, e N é um processo estacionário, em (5) obtemos o modelo sazonal determinístico com a aplicação da diferença sazonal. Quando há *lags* sazonais de múltiplos períodos, considera-se que exista uma sazonalidade estocástica, sendo este modelo dimensionado com os parâmetros p, d, q (4), e P, D, Q (6), com o número de períodos sazonais $s = 12$, SARIMA $(p, d, q) (P, D, Q)_{12}$.

$$(1 - B^{12} Z_t) = (1 - B^{12}) \mu_t + (1 - B^{12}) N_t \quad (5)$$

$$(1 - \Phi_1 B^{12} - \dots - \Phi_p B^{12P}) (1 - B^{12})^D Z_t = (1 - \Theta_1 B^{12} - \dots - \Theta_Q B^{12Q}) \alpha_t \quad (6)$$

3.2 Função de Autocorrelação Estendida

A função de autocorrelação estendida (face) é a união dos processos, função de autocorrelação (fac), que define o índice p do modelo autorregressivo, e a função da autocorrelação parcial (facp) que define o q do processo de média móvel, Tsay and Tiao (1984), dimensionando o modelo ARMA. A face tem a capacidade de anular valores após uma determinada defasagem, Cryer (2008), e a equação (7) é define o modelo ARMA estacionário.

$$\rho_j = \phi_1 \rho_{j-1} + \dots + \phi_k \rho_{j-k} + \gamma_{za}(j) - \dots - \theta_1 \gamma_{za}(j-1) \quad (7)$$

Define-se que para em qualquer posição de j na equação (8), modelo sazonal, onde este deve ser maior ou igual ao regresso que possa zerar seu índice na equação matricial conforme em a equação (9), Cryer (2008).

$$W_{k,t}^{(j)} = (1 - \phi_1^{(j)} B - \dots - \phi_k^{(j)} B^k) Z_t \quad (8)$$

a equação (8) é redefinida para (9),

$$G_{(k)}^j \phi_{(k)}^{(j)} = P_{(k)}^j \quad (9)$$

o número de elementos $\rho_{k,j}$, na equação (11), é definida como a função de autocorrelação estendida.

$$\rho_{k,j} = \frac{\phi_{(k)}^{*(j)} G_{(k+1)}^j \phi_{(k)}^{*(j)}}{\phi_{(k)}^{*(j)} G_{(k+1)}^j \phi_{(k)}^{*(j)}} \quad (10)$$

Primeira análise, em 12, $k = p$, o processo $W_{k,t}^{(j)}$, é um processo de média móvel MA (q) .

Quando $k \geq p$, é um processo estacionário ARMA (p, q) , demonstrado em (11), Cryer (2008).

$$\rho_{k,t} = \begin{cases} c & , j = q + k - p \\ 0 & , j > q + k - p \end{cases} \quad (11)$$

onde $-1 < c < 1$.

3.2.1 FSARIMA

A transformação da série de energia elétrica de número convencionais reais (*crisp*) para um referente *fuzzy* e com saída novamente *crisp*, representa a nova série temporal FSARIMA, Wang (1999). As definições aplicadas para modelagem da série *Fuzzy* Sazonal Auto Regressivo Integrado de Média Móvel, FSARIMA.

As séries *fuzzy* são implementadas neste processo analítico, com as entradas de números *crisp*, onde contido em um universo de discurso U seus valores são definidos sob regras, fuzzyficação, neste caso representadas por triângulos, e saída, defuzzyficação, pelo método centroide, para uma resposta *crisp*, Zadeh (1965). As variáveis linguística que definem as regras geram, na função de pertinência φ_{A_i} , valores definidos no intervalo $[0,1]$, Wang (1999).

Conforme Sadaei et al. (2014), a série temporal $F(t, t - 1) = F(t - 1, t - 2)$ é definida como invariante para todo t , caso contrario a entrada $F(t)$ será uma série de tempo variante distorcido, sendo $F(t - 1)$ definida por A_i e $F(t)$ por A_j sendo definido uma Relação Lógica *Fuzzy* (RLF), onde A_i relaciona A_j para $i, j = 1, 2, 3, \dots, p$, sendo p um subintervalo, definindo A_i o lado direito e A_j o lado esquerdo da RLF, as relações entre regras podem ser agrupamento em um grupo Difuso Lógico Ordenado (FLG), colocando todos juntos no RHS da FLG, e de acordo com Efendi et al. (2015), podem ser escrito como $A_i \rightarrow A_j, A_i \rightarrow A_k, \dots, A_i \rightarrow A_p; i, j, k, p, \dots, N$. A serie temporal difusa $F(t)$, que apresentam sazonalidade (FSARIMA) são descritos como uma relação de regras como deslocamento m , sendo $F(t + m) \rightarrow F(t)$, ou, $F(t) = f(t + m)$, sendo t um período sazonal, Tseng and Tzeng (2002).

O valor que define o máximo valor da função de pertinência $\varphi_{A_i}(x)$, relacionado a regra A_i , é um subconjunto do universo de discurso U , sendo definido por $Supp(A) = \{X \subset L : \varphi_{A_i}(x) > 0\}$, sendo L um subconjunto difuso e X um conjunto compacto convexo, Bitar et al. (2009).

O sistema de referência $\alpha - cut$ é um conjunto variante no intervalo $[0, 1]$ para representar as regras $[A] = \{x \in L : \varphi_A(x) \geq \alpha\}$, sendo $\alpha > 0$, e $[A]^0$ o encerramento do valor $Supp(A)$, Wang (1999).

A implementação da Função de Autocorrelação Estendida *Fuzzy* (AECF) com α como conjunto de corte, é aplicado a função sazonal $W_{i,p,q}^{\alpha-cut}$, sendo i o grau do integrador, p do regressivo e q da média móvel, Carvalho (2016). A ativação dos conjuntos contidos no universo de discurso L , serão relacionados a cada intervalo *fuzzy*, sendo os valores desta função os elementos da série temporal *fuzzy* com $\alpha - cut$ gerados pela a série original $Z_i(t)$, onde $1 \leq i \leq m$ e $1 \leq i \leq T$, sendo m e T valores finais de cada regra *fuzzy* na equação (12), onde $p = 0, 1, 2, \dots, q = 0, 1, 2, \dots,$

$h = 0, 1, 2, \dots, r, b = 0, 1, 2, \dots,$ para $\phi_p^{\alpha-cut}(\alpha, b)$ indica o operador com corte em especificado em α , Carvalho and Costa (2016).

$$W_{i,p,q}^{\alpha-cut}(h, \alpha, b) = Z_1^{\alpha-cut}(\alpha, b) - \dots - \phi_1^{\alpha-cut}(\alpha, b)Z_{i-1}^{\alpha-cut}(\alpha, b) - \dots - \phi_p^{\alpha-cut}(\alpha, b)Z_{i-p}^{\alpha-cut}(\alpha, b) - \dots \quad (12)$$

3.3 Critérios de Comparação

Posto que estas medidas são relativas, e seguem uma distribuição de probabilidade com média sem definição e a variância não converge para um valor que caracterize a amostra de acordo com Hyndman and Koehler (2006). O modelo de medição de erro utilizado é o Erro Médio Absoluto Escalonado (MASE), o valor real do MASE demonstrado pela média dos valores relativos em (13), por ser predição sazonal e o escalonamento como parte da predição, onde μ é a média.

$$MASE = \mu \left(\left| q_i = \frac{|Z_i - \hat{Z}_i|}{\frac{1}{n-1} \sum_{i=2}^n |Z_i Z_{i-1}|} \right| \right) \% \quad (13)$$

Outro método de medida é o Erro Percentual Médio Absoluto (MAPE) (14), é o controle comparativo observado, nas medidas das séries utilizado neste trabalho.

$$MAPE = \frac{100}{T} \sum_{i=1}^n \frac{|Z_i - \hat{Z}_i|}{Z_i} \% \quad (14)$$

3.4 Demanda de Energia Elétrica

A demanda de energia elétrica para o Estado de Rondônia é definida em Potência Ativa (W), o valor total é definido pelo barramento ao sistema interligado nacional, o contrato é definido nos Leilões Nacionais de Energia Elétrica.

4 Metodologia

O processo de Identificação *Fuzzy* Para Modelos Autorregressivos Sazonais Mediante a Função de Autocorrelação Estendida, é implementado as séries temporais de energia elétrica, e os passos para obtenção de resultados operacionais são implementados em análise para o intervalo registrado nos dias 10 a 14 de outubro de 2006(segunda semana), a predição acontece no intervalo de 17 a 20 de outubro de 2016(terceira semana). Os passos são apresentados em sequência de 1^o a 7^o.

1^o passo: Coleta de Dados.

2^o passo: Definição do Universo de discurso U , onde se define o desvio padrão, sendo este acrescentado no valor máximo e subtraído do valor mínimo de $U = [Z(\min) - \alpha; Z(\max) + \alpha]$.

3^o passo: Partição do universo de discurso U em n regras para o caso $n=7$, as regras *fuzzy* $A_i, i=1,$

..., n são da forma triangular, sendo $u_j = (a_j ; b_j ; c_j)$ $j=1,2,3$, extremidade esquerda, centro e direita da base do triângulo.

4^o passo: Definição dos conjuntos *fuzzy* A_i , a partir dos intervalos *fuzzy*, através do intervalo U do 2^o passo construir os intervalos para as regras, sendo as regras $u_1(a_1; b_1)$ para a regra A_1 e $u_7(b_1; c_1)$ para regra A_7 sendo as demais no formado $u_j = (a_j; b_j; c_j)$.

5^o passo: Atribuir o α - *cut* aos conjuntos *fuzzy* construídos no passo anterior a partir do valor definido a priori; por exemplo, corte α - *cut* = 0, 25, 0, 50 ou 0, 75.

6^o passo: Ativar os conjuntos difusos usando o corte α - *cut* = 0, 25 usado no passo anterior para definir o intervalo *fuzzy* correspondente a cada conjunto *fuzzy* A_j que é ativado.

7^o passo: Gerar aleatoriamente 1000 funções de autocorrelação de amostra a partir do suporte dos conjuntos *fuzzy* ativados. Para esta etapa, a média das 1000 funções é calculada em cada intervalo *fuzzy*, e a função de autocorrelação estendida *fuzzy* é aplicada sobre a série da função de autocorrelação média da amostra resultante. Relacionadas com cada intervalo *fuzzy* para produzir o modelo *fuzzy* série temporal.

5 Resultados

O Métodos de Identificação *Fuzzy* apresentado, teve como base a demanda de energia elétrica do Estado de Rondônia, Figura 1, em sequência de horas relacionado a potência ativa de demanda. A segunda semana do mês de outubro de 2016, é a base dados do processo para definição dos valores de predição para semana subsequente.




Figura 1 Demanda de Energia Segunda Semana

A série temporal *fuzzy* obtida, é definida através do método centroide, para da saída dos sistemas com valores *crisp*, Wang (1999). Para o dimensionamento do modelo FSARIMA, utilizando-se o software R (software livre), em seu pacote TSA, a função de autocorrelação estendida (eacf (w)) é utilizados para definir a dimensão da parte

sazonal, e os valores dos modelos, projeção, intervalo de mínimo e máximo, validação e predição, apresentados neste artigo pelo software Gretl (software livre).

A Figura 2. Mostra uma simulação no software R, definindo o valor AR e MA, do FSA-RIMA, a parte sazonal, é através do periodograma, o deslocamento da série sazonal Cryer (2008).




Figura 2 Função de Autocorrelação Estendida

Os valores de probabilidade, estatisticamente diferente de zero, ao nível de significância de 5%. O modelo FSARIMA ajustado Pollock (1993). Conforme a tabela 1, apresenta-se a relação entre as regras de predição.

Tabela 1 Relacionamento de Lógica Fuzzy

Tempo (Hora)	Potência (MW)	Regra Ativa	Relacionamento Lógica Fuzzy
1	492,1008	A4	A4 → A4
2	474,4336	A4	A4 → A3
3	456,3421	A3	A3 → A3
⋮	⋮	⋮	⋮
118	532,6151	A5	A4 → A5
119	557,288	A5	A5 → A5
120	562,7148	A6	A5 → A6

A relação do sinal fuzzyficado e o sinal real da segunda semana, apresenta boa aderência assintótica, e o modelo definido na Figura 3 é o $FSARIMA(2, 1, 1)(1, 0, 1)_{s=36}$.




Figura 3 Comparativo; FSARIMA e Demanda

O processo de validação do modelo em estudo é apresentado na Figura (4), todos os modelos apresentam um acompanhamento assintótico durante o período de identificação, os 4 primeiros dias (96 horas), porem na validação de 24 horas, de 96 a 118, todas os modelos, no intervalo de 95% aderem o sinal real, entretanto o FSARIMA tem acompanhamento assintótico com precisão mais acentuada.




Figura 4 Validação do Modelos para 24 horas.

Para o processo de predição é utilizado a semana subsequente ao do preditor, conforme Figura (5), apresentando o consumo de energia elétrica para o Estado de Rondônia, a medição de 96 horas (4 dias) de energia, de 17 a 20 de outubro de 2016, com a mesma característica sazonal.




Figura 5 Terceira Semana.

A predição para 96 horas, Figura 6, é a projeção com relação aos valores da terceira semana de demanda de energia elétrica, no mês de referência de 2016. O valor de demanda está dentro do intervalo de 95%, e com boa aderência do sinal preditor.

6 Discussões

O comparativo entre os modelos para validação define de forma gráfica a diferença na validação, o gráfico e predição coloca o sinal real dentro da faixa de 5% definida pelo modelo FSARIMA,




Figura 6 Predição da Demanda para 96 horas.

durante as 96 horas, o sinal real da figura 5, fica dentro da faixa de erro. Em conformidade a relação de erros médio escalonado e percentual médio absoluto, para todos os modelos observa-se o melhor desempenho no método em estudo, de acordo com a Tabela 2, em referência a Carvalho and Costa (2016).

Tabela 2 Relação Comparativa de Erro.

Modelos	MASE (%)	MAPE (%)
ARMA	8,8347	12,7500
ARIMA	1,7905	9,3910
SARIMA	0,7603	6,1032
FSARIMA	0,7238	2,2300

Em conformidade com modelo do setor energético brasileiro, determinando que as distribuidoras e consumidores livres tenham 100% da energia que irão consumir contratada e prevista com margem de erro dentro da faixa de 0% a 3%, superior e inferior de acordo com a legislação vigente as relações de segurança para contratação de energia elétrica, o modelo FSARIMA $(2, 1, 1)(1, 0, 1)_{s=36}$, demonstra o menor MASE de 0,7238%, e no MAPE 2,23%, em comparação com os demais modelos.

7 Conclusão

Como apresentado, o planejamento para distribuição, passa por um processo de análise e predição de demanda para atender a legislação sobre a diminuição do erro na contratação de energia elétrica a curto prazo. O método apresentado neste contexto apresenta um modelo de série temporal sazonal que se assemelha ao sinal real de valores de energia coletados, e com desempenho satisfatório baseado nas relações de comparação, dentro das características da demanda de energia elétrica do Estado de Rondônia. Com base nos resultados demonstrada neste artigo o método é uma opção válida, uma vez que as relações de erros apresentaram um desempenho melhor que os modelos em referência. Este método pode ser aplicado para

análise de energia elétrica de pequenas hidrelétricas, análise de séries de falhas de equipamentos, análise aplicada a circuitos de distribuição e subestação, propondo uma eficiência na predição em séries temporais de energia elétrica.

Agradecimentos

Agradecemos o apoio irrestrito do meu Orientador Pro.DR. Carlos Tavares, Prof. DR. Gracildo pela partilha de seus conhecimentos- Universidade Federal do Pará, ao Prof.DR. Fabrício Morais de Almeida- Universidade Federal de Rondônia. Além disso a Eletrobras Distribuidora Rondônia.

Referências

- Andrade, L. C. M. d. (2010). *Abordagem neurofuzzy para previsão de demanda de energia elétrica no curtíssimo prazo*, PhD thesis, Universidade de São Paulo.
- Bitar, S. D., da Costa Junior, C. T., Barreiros, J. A. and João, C. d. L. (2009). Expansion of isolated electrical systems in the amazon: An approach using fuzzy multi-objective mathematical programming, *Energy Policy* **37**(10): 3899–3905.
- BOX, G., JENKINS, G. and REINSEL, G. (1994). *Time Series Analysis Forecasting and Control*, 3^aed edn, New Jersey.
- BRASIL (2004). *Decreto n^o 5.163 de 30 de junho*, Regulamenta a comercialização de energia elétrica.
- Carvalho, J. and Costa, C. (2016). Identification method for fuzzy forecasting, *Elsevier B.V.* All rights reserved.
- Carvalho, J. G. J. (2016). *Métodos de identificação fuzzy para modelos autoregressivos sazonais mediante a função de autocorrelação estendida*, PhD thesis, UFPA - Universidade Federal do Pará.
- Cryer, J. D. and Chan, K. (2008). *Time Series Analysis, With Applications in R*, Springer.
- Darbellay, G. A. and Slama, M. (2000). Forecasting the short-term demand for electricity: Do neural networks stand a better chance, *International Journal of Forecasting* **16**(1): 71–83.
- Efendi, R., Ismail, Z. and Deris, M. M. (2015). A new linguistic out-sample approach of fuzzy time series for daily forecasting of Malaysian electricity load demand, *Applied Soft Computing* **28**: 422–430.
- Hamilton, J. D. (1994). *Time series analysis*, Vol. 2, Princeton university press Princeton.
- Hyndman, R. J. and Koehler, A. B. (2006). Another look at measures of forecast accuracy, *International Journal of Forecasting* **22**(679-688).
- Morettin, P. and Toloi, C. (2006). *Análise de Séries Temporais*, 2 edn, ABE Associação Brasileira de Estatística, São Paulo.
- Pollock, D. (1993). *A SHORT COURSE OF TIME-SERIES ANALYSIS AND FORECASTING*, At The Institute of Advanced Studies. At The Institute of Advanced Studies, Viena from March 22nd to April.
- Rodrigues, D. (2002). *Previsão de fornecimento de energia elétrica: Um estudo de caso do ponto de vista do barramento*, Master's thesis, Universidade Federal de Minas Gerais, Brasil, Belo Horizonte.
- Sadaei, H., Enayatifar, R., Abdullah, A. and Gani, A. (2014). Short-term load forecasting using a hybrid model with a refined exponentially weighted fuzzy time series and an improved harmony search, *Int. J. Electr. Power Energy Syst*, *Int. J. Electr. Power Energy Syst* **62**.
- Tsay, R. S. and Tiao, G. C. (1984). Consistent estimates of autoregressive parameters and extended sample autocorrelation function for stationary and nonstationary arma models, *Journal of the American Statistical Association* **79**(385): 84–96.
- Tseng, F.-M. and Tzeng, G.-H. (2002). A fuzzy seasonal arima model for forecasting, *Fuzzy Sets and Systems* **126**(3): 367–376.
- Wang, L.-X. (1999). *A course in fuzzy systems*, Prentice-Hall press, USA.
- Wei, W. et al. (2006). *Time Series Analysis- Univariate and Multi-variate Methods*, 2nd edn, Pearson Addison Wesley.
- Zadeh, L. A. (1965). Fuzzy sets, *Information and control* **8**(3): 338–353.