

Previsão de Cargas Elétricas através de um modelo de Regressão ARIMA e uma Rede Neural ARTMAP Fuzzy

T. Abreu, C. R. Santos Junior, M. L. M. Lopes, A. D. P. Lotufo

FEIS – Faculdade de Engenharia de Ilha Solteira

Universidade Estadual Paulista – UNESP

Ilha Solteira-SP, Brasil

thays7abreu@gmail.com, carlos9.rsj@gmail.com, mara@mat.feis.unesp.br, annadiva@ieee.org

Abstract— A utilização de técnicas híbridas para previsão de séries temporais vem sendo cada vez mais aplicada para solucionar diversos tipos de problemas, como convergência, precisão entre outros. Neste trabalho é desenvolvida uma metodologia híbrida, utilizando os modelos de regressão ARIMA de Box & Jenkins e uma rede neural ARTMAP Fuzzy, com a finalidade de melhorar a precisão dos resultados com relação à previsão de cargas elétricas em curto prazo. Apresentam-se resultados para uma série temporal de demanda de energia elétrica de uma companhia do setor elétrico brasileiro.

Keywords— Modelos de Regressão ARIMA, Previsão de Cargas Elétricas, Rede Neural ARTMAP Fuzzy.

I. INTRODUÇÃO

Os sistemas elétricos de potência crescem em tamanho e complexidade e é necessário criar alternativas para minimizar o custo total de geração e operação. A previsão de cargas elétricas é uma tarefa fundamental em um centro de controle e operação, para tanto esta tarefa deve ser precisa para que o sistema opere de forma segura e confiável. A precisão da previsão é de grande importância já que é através dela que é estabelecida quando e quanto de capacidade de geração e transmissão deve-se dispor para atender os consumidores sem interrupções no fornecimento, com o propósito de garantir o fornecimento de energia de forma econômica, segura e contínua, [1]. Na literatura destacam-se as seguintes técnicas para previsão de carga: técnica de regressão linear simples ou múltipla, alisamento exponencial, estimação de estado, filtro de Kalman, ARIMA (*Auto Regressive Integrated Moving Average*) de Box e Jenkins [2]. Esses métodos necessitam da modelagem prévia da carga para aplicação posterior. Os fatores que ajudam a modelar a carga podem ser condições meteorológicas como: nebulosidade, velocidade do vento, variações bruscas de temperatura; fatores diversos como efeito de dias atípicos (feriados, greves, etc.) [3], [1].

Atualmente, o uso das redes neurais artificiais (RNAs) é um método alternativo e eficiente para previsão de cargas elétricas.

Uma de suas vantagens é que não necessita da modelagem prévia da carga [4].

Dentro da literatura são encontrados inúmeros trabalhos que utilizam redes neurais artificiais (rede *Perceptron* via algoritmo retropropagação) e os modelos ARIMA de Box & Jenkins. Esses trabalhos são voltados para o tratamento de séries temporais empregados a uma variedade de problemas reais. Existem poucos trabalhos que aplicam modelos híbridos na resolução do problema de previsão de cargas elétricas.

No trabalho de Koutroumanidis [5], é apresentada uma descrição da contribuição de fontes de energia renováveis para a produção de eletricidade. Os modelos ARIMA e RNA são unidos, sendo o ARIMA responsável por gerar os parâmetros da carga e as redes neurais são usadas para prever os preços futuros de venda de madeira na Grécia. O uso do modelo híbrido obteve ótimos resultados, possibilitando aos fabricantes prosseguirem com um planejamento mais racional para produção e mercado de lenha. Nos trabalhos de Khashei e Bijari [6], [7], são utilizados o hibridismo entre ARIMA e RNA com o objetivo de obter uma previsão precisa, sendo considerados os dados históricos dos registros das manchas solares por ano, o número de lincas que é capturado por ano no rio Mackenzie (Canadá) e a taxa de cambio libra (Britânica) / dólar (Estados Unidos). No qual os modelos ARIMA são utilizados na primeira fase para gerar os dados necessários a partir das séries históricas, em seguida na segunda fase uma rede neural é usada para modelar os dados gerados pelo modelo ARIMA, e para prever a série temporal [1].

Alguns trabalhos como o de Valenzuela [8] e Khashei [9] além de utilizar os modelos ARIMA e as redes neurais, ainda combinam regras nebulosas (*Fuzzy*) ou algoritmos genéticos para aperfeiçoar os resultados [10].

Neste trabalho será desenvolvido um modelo híbrido predictor de cargas elétricas em curto prazo, utilizando os modelos de regressão ARIMA e uma rede neural ARTMAP *Fuzzy*. O modelo ARIMA é responsável pela parte linear da série e a rede ARTMAP *Fuzzy* pela parte não linear dos resíduos do ARIMA. É importante enfatizar que a união dessas

ferramentas é inovadora, já que não existe na literatura. O modelo híbrido foi testado nos períodos de 30, 60 e 90 dias, respectivamente, com o objetivo de prever o dia 1 de agosto de 1998.

II. Modelo de Regressão ARIMA

Por mais de meio século os modelos autorregressivos integrados de médias móveis, ARIMA dominaram muitas áreas de previsão de séries temporais.

Os métodos ARIMA (p, d, q), dependem apenas de seus dados para a especificação do modelo, sendo que o valor futuro de uma variável é assumido como uma função linear de várias observações passadas e erros aleatórios. O processo que gera a série de tempo tem a forma dada por (1), [11].

$$\phi(B)\Delta^d Z_t = \theta(B)a_t \quad (1)$$

sendo:

- p = ordem do modelo autorregressivo;
- d = indicação de quantas vezes a série foi diferenciada até se tornar estacionária;
- q = ordem do modelo de media móvel;
- Z_t = valores atuais no período t ;
- a_t = erros aleatórios no período t ;
- $\phi(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p$
operador autorregressivo de ordem p ;
- $\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$
operador das médias móveis de ordem q ;
- $\Delta^d = (1 - B)^d$
diferenciação da série.

Para realizar a previsão de séries temporais a metodologia mais utilizada é a de Box & Jenkins [2]. Essa metodologia permite que valores futuros de uma série (neste caso previsão de cargas elétricas) sejam previstos utilizando apenas seus valores presente e passados, através da correlação temporal que existe entre os valores exibidos pela série.

A construção do modelo é abordada em um ciclo iterativo: identificação, estimação e verificação [2].

- Identificação: Consiste em descobrir qual dentre as várias versões do modelo ARIMA descreve o comportamento da série.
- Estimação: Consiste em estimar os parâmetros do modelo identificado;
- Verificação: Tem por finalidade avaliar se o processo de estimação foi bem sucedido.

Quando se obtém um modelo satisfatório, já é possível realizar a previsão.

Os modelos ARIMA exploram a correlação de valores observados em instantes de tempo consecutivos, enquanto os modelos ARIMA que possuem sazonalidade apresentam correlação entre os instantes de tempo distantes entre si por m

ou múltiplos de m , sendo m o número de observações contidas em um ano ($m = 12$ para dados mensais e $m = 4$ para dados trimestrais) [12], [1]. Para acomodar esse tipo de série, surgem os modelos ARIMA sazonais, também conhecidos como modelos SARIMA(p, d, q)(P, D, Q) $_m$, denotados por (2), [11].

$$\phi(B)\Phi(B^m)\Delta^d\Delta_m^D Z_t = \theta(B)\Theta(B^m)a_t \quad (2)$$

no qual:

- P = ordem do modelo autorregressivo sazonal;
- D = número de diferenças sazonais;
- Q = ordem do modelo de media móvel sazonal;
- m = período da sazonalidade;
- $\Phi(B^m) = 1 - \phi_1 B^m - 1 - \phi_2 B^{2m} - \dots - 1 - \phi_p B^{Pm}$
operador autorregressivo sazonal de ordem P ;
- $\Theta(B^m) = 1 - \theta_1 B^m - 1 - \theta_2 B^{m^2} - \dots - 1 - \theta_Q B^{mQ}$
operador de medias móveis sazonal de ordem Q ;
- $\Delta_m^D = (1 - B^m)^D$
diferenciação da série sazonal.

Para identificação, estimação e verificação de modelos sazonais, não há em principio nenhuma dificuldade adicional. A diferença é que é necessário diferenciar a série com respeito à Δ e Δ_m para produzir estacionariedade. Com isso são obtidos os valores de d e D , que na maioria das vezes assumem valores no máximo iguais ao valor 2. As fases de estimação e verificação dos modelos SARIMA(p, d, q)(P, D, Q) $_m$ são análogos aos do modelo ARIMA(p, d, q), [13], [1].

III. REDES NEURAIAS ART

As Redes Neurais ART (*Adaptive Resonance Theory*) são desenvolvidas para codificar reconhecimentos estáveis, em tempo real, através da auto-organização, em resposta a sequências arbitrarias de padrões de entrada. Essas redes são cada vez mais utilizadas, devido a sua capacidade de aprendizagem sem perder o conhecimento adquirido anteriormente. Essa habilidade se dá devido ao dilema da plasticidade/estabilidade, no qual sugere que o sistema seja flexível para novos conhecimentos e estável a fim de preservar o conhecimento já adquirido [14]. Neste trabalho será utilizada uma rede ARTMAP *Fuzzy*, que é composta por duas redes ART *Fuzzy*, e um módulo inter-ART.

A RNA ART *Fuzzy* é formada por três camadas: F_0 , F_1 e F_2 . A camada do módulo F_0 tem M unidades e é uma etapa de pré-processamento a qual codifica o complemento do padrão de entrada, sendo este a entrada da camada F_1 . A camada F_1 possui então $2M$ unidades. A camada F_2 é competitiva e as suas unidades estão completamente interconectadas via conexões laterais e cada unidade caracteriza um retorno inibitório (negativo), esta também é chamada “camada de

representação de categoria”, uma vez que cada unidade está associada a uma categoria interna [15].

A rede neural ARTMAP Fuzzy é um sistema de aprendizagem supervisionado capaz de auto-organizar o reconhecimento estável de categorias em resposta a seqüências arbitrárias de padrões de entradas. A rede é composta de um par de módulos da rede ART Fuzzy, ART_a e ART_b que são conectados através de um módulo de memória associativa inter-ART, F^{ab} , [17]. A Figura 1 mostra a arquitetura da rede ARTMAP Fuzzy.

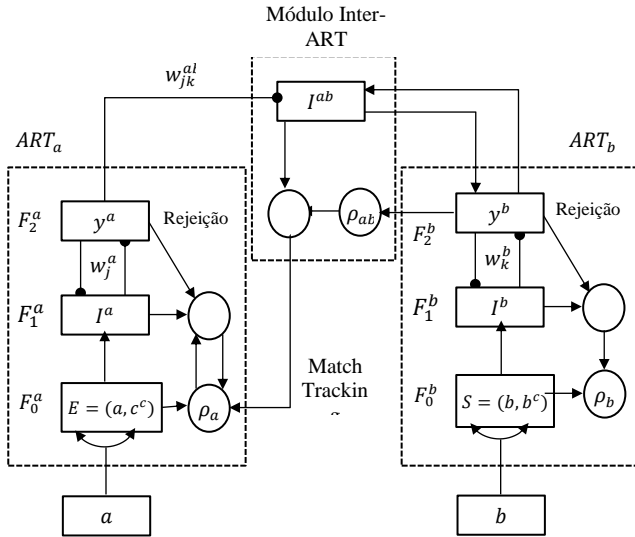


Fig. 1. Estrutura da RNA ARTMAP Fuzzy

A rede ART_a Fuzzy é que recebe e processa um determinado padrão de entrada apresentado, e a ART_b Fuzzy constitui a resposta desejada para o padrão apresentado à rede que são interligadas pelo módulo de memória associativa Inter-ART, que realiza o mapeamento mínimo de categorias de reconhecimento em ART_a, ou “unidades ocultas”, necessárias para atingir o critério de precisão [17].

O módulo inter-ART é responsável pela verificação se há casamento da entrada (ART_a) e da saída (ART_b). Todas as matrizes de pesos são iniciadas com valores iguais a 1, ou seja, todas as atividades encontram-se inativas. Estas atividades são ativadas à medida que ocorre ressonância entre os padrões de entrada e de saída [17].

O módulo ART_a aprende a classificar os padrões de entrada apresentados em sua camada e o módulo ART_b desenvolve categorias referentes aos padrões de saída desejados [17].

Toda vez que os pares de entrada, associados aos módulos ART_a e ART_b, são confirmados, de acordo com o teste do match tracking (processo auto-regulador que maximiza a generalização e minimiza os erros), o par de treinamentos será confirmado nas matrizes de pesos, caso contrário deve-se buscar outro padrão de entrada, até que o critério seja satisfeito, [17].

O funcionamento da rede ARTMAP Fuzzy [17, 16] é baseado nas etapas descritas abaixo:

1) Redes Neurais ARTa e ARTb

O vetor ART_a representa um padrão de entrada e o vetor ART_b a saída desejada correspondente ao vetor de entrada ART_a. As entradas para o ART_a e o ART_b estão na forma de codificação de complemento. Para o módulo ART_a tem-se $I = E = [a, a^c]$ e para o ART_b $I = S = [b, b^c]$.

2) Vetores de pesos

Todos os vetores de pesos das redes ART_a, ART_b e do inter-ART iniciam iguais a 1, representando as categorias não ativas, e são representados respectivamente por: $w_{j1}^a = 1$, $w_{k1}^b = 1$ e $w_j^{ab} = 1$.

3) Parâmetros da rede ARTMAP Fuzzy

- Parâmetro de escolha: $\alpha > 0$;
- Parâmetro taxa de aprendizagem: $\beta \in [0,1]$;
- Parâmetro de vigilância do módulo ART_a, ART_b e inter-ART ρ_a, ρ_b e $\rho_{ab} \in [0,1]$.

Match Tracking: No início de cada padrão de entrada apresentado a ART_a, o parâmetro de vigilância ρ_a é igual ao valor de vigilância base, $\bar{\rho}_a$. O parâmetro de vigilância do módulo inter-ART é ρ_{ab} . Se a equação (9) é satisfeita, então ρ_a é ligeiramente incrementado até que satisfaça a equação (10).

$$|x^{ab}| < \rho_{ab} |y^b| \quad (9)$$

$$|x^a| = |E \wedge w_j^a| < \rho_a |E| \quad (10)$$

No qual J representa o nó ativo de F_2^a . Quando isto ocorre, ART_a busca novamente outro nó J de F_2^a para ativação através de (11) e (12).

$$|x^a| = |E \wedge w_j^a| \geq \rho_a |E| \quad (11)$$

e

$$|x^{ab}| = |y^b \wedge w_j^{ab}| \geq \rho_a |y^b| \quad (12)$$

4) Aprendizagem

As regras de aprendizagem determinam como os vetores de pesos do *map field* w_{jk}^{ab} mudam ao longo do tempo. O vetor de pesos w_{jk}^{ab} via $F_2^a \rightarrow F^{ab}$ inicialmente satisfaz $w_{jk}^{ab} = 1$ e

durante o processo de ressonância se a categoria J ativa do módulo ART_a e a categoria K ativa do módulo ART_b combinarem a adaptação dos pesos inter-ART será efetuada da seguinte maneira:

$$w_{jk}^{ab} = 1 \text{ para } j = J \text{ e } k = K$$

$$w_{jk}^{ab} = 0 \text{ para } j \neq J \text{ e } k \neq K.$$

IV. METODOLOGIA

A metodologia proposta é baseada no trabalho de Abreu [1] que utilizou um modelo híbrido através dos modelos ARIMA e uma rede neural *perceptron* multicamadas com treinamento por *Levenberg-Marquardt*, para previsão de cargas elétricas em curto prazo.

A proposta deste trabalho é de unir os modelos de regressão ARIMA com uma rede neural da família ART, devido ao fato dessa rede se adaptar a mudanças na natureza, ou seja, conforme os dados de entrada são alterados, ela consegue adquirir novos conhecimentos, preservando o conhecimento adquirido anteriormente.

A rede ART utilizada neste trabalho é a ARTMAP *Fuzzy*, devido ao fato da mesma identificar padrões de entrada analógicos e de realizar treinamento supervisionado, [17].

O primeiro passo da metodologia proposta consiste em aplicar os dados reais no *software R* utilizando a biblioteca *forecast* [18], com objetivo de obter o melhor modelo ARIMA, que é representado através de uma série simulada. Como as cargas elétricas estão sendo consideradas de hora em hora, os modelos obtidos apresentam sazonalidade, devido às correlações em instantes de tempo de 24 horas. Assim a correlação entre as cargas no período da noite deve ser alta e provavelmente maior do que a correlação das cargas da manhã do mesmo dia [1]. Tais modelos são conhecidos como modelos SARIMA.

Na Figura 2 esta detalhada os passos do *software R*.

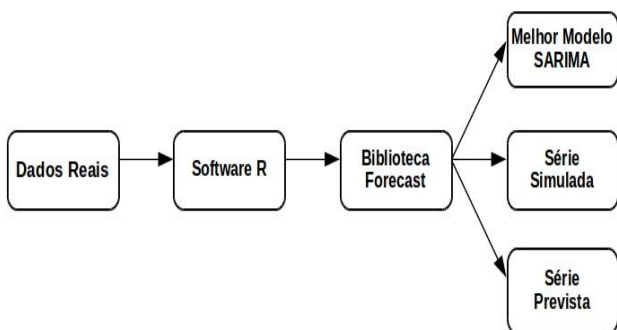


Fig. 2. Diagrama de blocos do software R.

O próximo passo da metodologia híbrida é utilizar a série simulada obtida através do modelo de regressão SARIMA como uma das entradas da rede ARTMAP *Fuzzy*, que é composta por duas redes ART *Fuzzy*, ART_a e ART_b . A rede

ART_a é responsável pela entrada dos dados, e esta representada na Figura 3. A rede neural foi implementada utilizando a linguagem de programação JAVA [19], devido à portabilidade e um maior controle sobre o ambiente de desenvolvimento e ao seu baixo custo e tempo computacional.




Fig. 3. Entrada da rede neural.

sendo:

- Dia : Representa os 30 dias do mês
- Mês : Representa os 12 meses do ano
- Hora : Representa as 24 horas de um dia
- Dia da Semana: Representa os 7 dias da semana
- Dia Atípico : Feriado ou dia típico
- Série Simulada : Representa a carga simulada do SARIMA em relação a ao dia, mês, hora, dia da semana e dia atípico.

A saída da rede neural ARTMAP *Fuzzy* é composta pelos valores da carga real, conforme a Figura 4.




Fig. 4. Saída da rede neural.

V. RESULTADOS

O modelo proposto foi submetido a três aplicações distintas, diferenciadas pela quantidade de dias utilizados em cada aplicação. A Tabela I descreve os períodos utilizados na análise. A escolha do mesmo período auxilia na validação da metodologia, uma vez que, os resultados obtidos através do modelo híbrido podem ser comparados aos resultados obtidos por outros trabalhos da literatura [1], [10] que utilizam outras arquiteturas de redes neurais.

TABELA I. PERÍODO DE TEMPO PARA AS APLICAÇÕES

Aplicação	Período	Número de Padrões	Dia Previsto
1	31 dias - 01/07/98 a 31/07/98	744	01/08/1998
2	61 dias - 01/06/98 a 31/07/98	1464	01/08/1998
3	84 dias - 01/05/98 a 31/07/98	2208	01/08/1998

Os modelos SARIMA obtidos através do *software* R para cada aplicação são:

- Aplicação 1: SARIMA(2,0,0)(2,0,2)₂₄, modelo autorregressivo de ordem 2, autorregressivo sazonal de ordem 2 e de média móvel sazonal de ordem 2.
- Aplicação 2: SARIMA(2,0,2)(2,0,2)₂₄, modelo autorregressivo de ordem 2, média móvel de ordem 2, autorregressivo sazonal de ordem 2 e média móvel sazonal de ordem 2.
- Aplicação 3: SARIMA(3,0,1)(2,0,2)₂₄ modelo autorregressivo de ordem 3, média móvel de ordem 1, autorregressivo sazonal de ordem 2 e média móvel sazonal de ordem 2.

Nas três aplicações o período de sazonalidade foi 24, devido a série temporal da carga elétrica se repetir de 24 em 24 horas.

Os parâmetros utilizados na rede neural são especificados na Tabela II.

TABELA II. PARÂMETROS RNA ARTMAP FUZZY

Parâmetros	Aplicações 1, 2 e 3
α	0.001
β	1
ρ_a	0.99
ρ_b	0.99
ρ_{ab}	0.99

Para analisar os resultados, verificamos o MAPE e o erro máximo obtido durante a previsão das cargas nas 24 horas, que são calculados respectivamente por (13) e (14) [20].

$$MAPE = \frac{1}{NT} \sum_{h=1}^N \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \cdot 100\% \quad (13)$$

$$Erro\ máximo\ (\%) = máx \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \cdot 100\% \quad (14)$$

no qual:

$L(h)$ = valor da carga real referente a hora h ;

$\underline{L}(h)$ = valor da carga estimada pelo modelo híbrido referente a hora h ;

NT = número total de horas.

A Tabela III apresenta os valores do MAPE e erro máximo obtidos para as aplicações 1, 2 e 3.

As Figs. 5-7 apresentam as curvas de previsão de 24 horas das cargas real e prevista, do dia 1 de agosto de 1998 para cada aplicação.

TABELA III. MAPE E ERRO MÁXIMO OBTIDO 24 HORAS A FRENTE

Aplicação	MAPE (%)	Erro máximo (%)
1	2,4509	15,5117
2	2,1299	14,3955
3	2,1559	14,6284

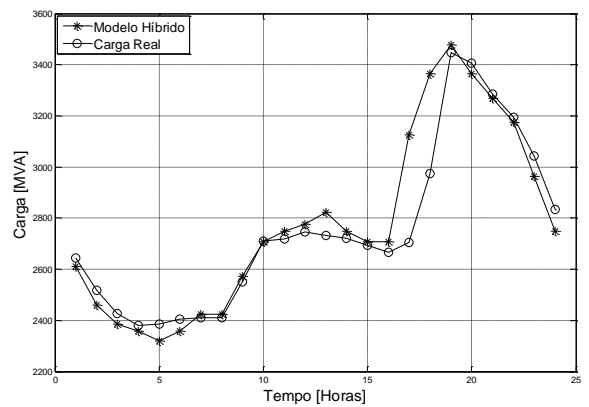


Fig. 5. Resultado da previsão de 24h para aplicação 1.




Fig. 6. Resultado da previsão de 24h para aplicação 2.

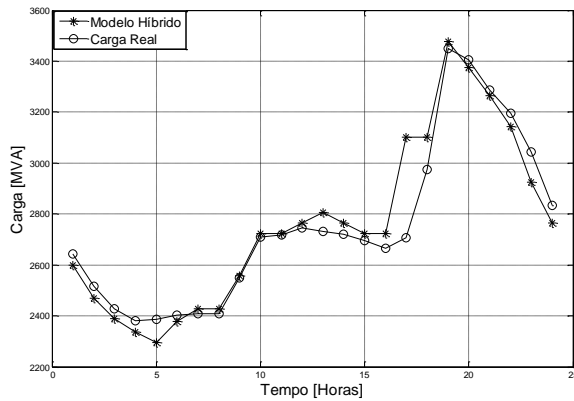


Fig. 7. Resultado da previsão de 24h para aplicação 3.

CONCLUSÃO

Este artigo propõe o desenvolvimento de um sistema previsor de cargas elétricas em curto prazo baseado nas redes neurais artificiais. O modelo estrutural utiliza os modelos de regressão SARIMA e a rede neural ARTMAP *Fuzzy*.

O modelo SARIMA é responsável pela linearidade da série de dados fornecendo uma série simulada, a qual é considerada como uma informação adicional para compor o conjunto de entrada de dados para o treinamento da rede neural ARTMAP *Fuzzy*.

Logo, a previsão de cargas elétricas é realizada pela rede neural ARTMAP *Fuzzy* que associa a não linearidade da rede neural com a linearidade fornecida pelo SARIMA.

Os valores dos erros percentuais médios (MAPE), obtidos para as Aplicações 1, 2 e 3 variam em torno de 2% a 2,5%. As figuras 5, 6 e 7 mostram que as curvas de previsões obtidas pelo modelo híbrido foram capazes de acompanhar as curvas de previsões dos dados reais nas três aplicações.

A rede neural ARTMAP *Fuzzy* realiza a previsão através de uma classificação de categoria, portanto, espera-se através de uma modificação na estratégia de formação do conjunto de dados, entrada e saída da rede neural, obter uma nova estrutura a qual irá fornecer melhores previsões.

Uma das grandes vantagens da rede neural ARTMAP *Fuzzy* é que a previsão de cargas elétricas é realizada em segundos levando em consideração o tempo de execução para o treinamento e diagnóstico (previsão). Portanto, esta estrutura fornece bons resultados em tempo real.

AGRADECIMENTOS

Os autores agradecem a CAPES pelo apoio financeiro.

- [1] T. A. A. Silva, 'Previsão de Cargas Elétricas através de um Modelo Híbrido de Regressão com Redes Neurais'. Dissertação (Mestrado)-Universidade Estadual Paulista "Julio de Mesquita Filho", Faculdade de Engenharia, Ilha Solteira, Fev. 2012.
- [2] T. M. O'Donovan, Short Term Forecasting: An Introduction to the Box-Jenkins Approach, New York: John Wiley & Sons, 1983.
- [3] G.E. Box e G.M. Jenkins, Times series analysis: forecasting and control. San Francisco, USA: Holden- Day, 1976.
- [4] S. Haykin, Neural networks: A comprehensive foundation, Prentice-Hall, Upper Saddle River, New Jersey, USA, 1994.
- [5] T. Koutroumanidis, K. Ioannou e G.Arabatziz, "Predicting fuelwood prices in Greece with the use of ARIMA models, artificial neural networks and a hybrid ARIMA-ANN model", Energy Police, vol. 37 pp. 3627-3624, Mai. 2009.
- [6] M. Khashei e M. Bijari, "An artificial neural network (p, d, q) model for time series forecasting", Expert Systems with Applications, vol. 37, pp. 479-489, 2010.
- [7] M. Khashei e M. Bijari, "A novel hybridization artificial neural networks and ARIMA models for time series forecasting", Applied Soft Computing, vol. 11, pp. 2664-2675, Nov. 2011.
- [8] O. Valenzuela, I. Rojas, F. Rojas, L. J. Herrera, A Guillen, L Marquez and M. Pasadas, "Hybridization of intelligent techniques and ARIMA models for time series prediction", Fuzzy Sets and Systems, vol.159, no. 7, pp. 821-845, 2008
- [9] M. Khashei, M. Bijari and G. A. R. A. Ardali, "Improvement of autoregressive integrated moving average models using fuzzy logic and artificial neural networks", Neurocomputing, vol.72 no. 4-6, pp. 956-967, 2009.
- [10] T. Abreu, K. A. M. Araújo, M. L. M. Lopes end A. D. P. Lotufo., "Método Híbrido utilizando os modelos ARIMA e Redes Neurais Artificiais para Previsão de Cargas Elétricas", XIX Congresso Brasileiro de Automática, Campina Grande, 2012.
- [11] G. E. P. Box, G. M. Jenkins e G. Reinsel, Times Series Analysis: Forecast and Control, 3rd ed. Englewood Cliffs: Prentice Hall, 1994.
- [12] V. L. Fava, "Metodologia de Box-Jenkins para modelos univariados". In: M. A. S. Vasconcellos; D. C. O. Alves. (Org.). Manual de Econometria: Nível Intermediário. SÃO PAULO: ATLAS, 1999, v. 1, pp. 205-232.
- [13] P. A. Morettin e C. M. C. Tolo, Análise de Séries Temporais, 2nd ed. São Paulo: Edgard Blucher, 2006.
- [14] S. Grossberg, "Adaptive pattern classification and universal recoding. I: Parallel development and coding of neural feature detectors". Biological Cybernetics, vol. 23, p. 121- 134, 1976.
- [15] G. A. Carpenter, S. Grossberg and D. B. Rosen, "Fuzzy ART: Fast stable learning and categorization of analog patterns by an adaptive resonance system". Neural Networks, New York, v.4, n.1, p.759-771, 1991.
- [16] M. L. M. Lopes, "Desenvolvimento de Redes Neurais para Previsão de Cargas Elétricas de Sistemas de Energia Elétrica". Tese (Doutorado)-Universidade Estadual Paulista "Julio de Mesquita Filho", Faculdade de Engenharia, Ilha Solteira, Dez. 2005.
- [17] G. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds e D. Rosen, "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps," IEEE Transactions on Neural Networks, vol. 3(5), 1992, pp. 698 - 713.
- [18] R. J. Hyndman e K. Yeasmin. "Automatic time series forecasting: the forecast package for R". Journal of Statistical Software, v. 27, Jul. 2008.
- [19] C. R. Santos Junior, 'Teoria da Ressonância Adaptativa para detecção e classificação de e-mails indesejados'. Dissertação (Mestrado)-Universidade Estadual Paulista "Julio de Mesquita Filho", Faculdade de Engenharia, Ilha Solteira, Fev. 2013.
- [20] D. Srinivasan, S. S. Tan, C. S. Chang, e E. K. Chan, "Practical Implementation of a Hybrid Fuzzy Neural Network For One-Day-Ahead Load Forecasting," IEE Proceedings Generation, Transmission and Distribution, vol. 145, no 6, pp. 687-692, Nov. 1998.