

Previsão de Cargas Elétricas utilizando uma Rede Neural ARTMAP Fuzzy com Treinamento Continuado

Thays Abreu¹, Carlos R. Santos Junior² Mara L. M. Lopes¹ Anna Diva Lotudo¹

Carlos R Minussi¹

¹ Universidade Estadual Paulista, Ilha Solteira, Brasil

² Instituto Federal de São Paulo, Hortolândia, Brasil
thays7abreu@gmail.com

Resumo. Minimizar o custo total de geração e operação é uma alternativa de extrema importância para atender os sistemas elétricos de potência. Assim, realizar a previsão de cargas elétricas é uma tarefa relevante para o planejamento e operação dos sistemas elétricos, pois é através da previsão que outras tarefas são executadas, como o despacho econômico, análise de estabilidade, fluxo de potência, entre outras. Fornecer uma previsão com boa precisão garante o fornecimento de energia de forma contínua ao consumidor, além de reduzir o custo de geração. Neste trabalho é utilizada uma rede neural ARTMAP Fuzzy com Treinamento Continuado para realizar a previsão de cargas elétricas. A inclusão do treinamento continuado na rede neural ARTMAP Fuzzy representa uma melhoria na obtenção da qualidade dos resultados (redução do tempo de processamento e maior precisão), se comparada à rede neural com treinamento convencional. Apresentam-se resultados da previsão de carga, considerando-se os dados históricos de uma companhia do setor elétrico brasileiro para três horizontes de previsões distintos.

Palavras-chave: Previsão de Cargas Elétricas, Rede Neural ARTMAP Fuzzy, Treinamento Continuado.

1 Introdução

O planejamento da expansão, fluxo de potência, operação econômica, análise de segurança e controle de sistemas de energia elétrica são alguns exemplos de rotinas que dependem efetivamente do conhecimento do perfil da carga, da estimativa das informações futuras de uma série temporal concebida baseada em valores passados [1]. Por meio da previsão de cargas elétricas que se estabelece a quantidade de energia que se

deve fornecer para geração, distribuição e transmissão. Assim, obter uma previsão com boa precisão é essencial para evitar interrupções no fornecimento de energia.

Dentro deste contexto, a previsão de cargas elétricas torna-se essencial, ou seja, com resultados que contemplem a qualidade (precisão, confiabilidade e rapidez), pois é por meio dela que se estabelece quando e quanto de capacidade de geração, transmissão e de distribuição deve-se dispor para atender o sistema sem interrupções no seu fornecimento.

Na literatura são destacadas diversas técnicas para realizar a previsão de carga [1]: 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]. Todos 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.) [1], [3].

A redes neurais artificiais (RNAs) [4] tem sido um método alternativo e eficiente para realizar a previsão de cargas elétricas na atualidade, uma de suas vantagens é a não necessidade da modelagem da carga.

Este trabalho utiliza uma RNA ARTMAP Fuzzy com treinamento continuado (ON-LINE) com objetivo de melhorar os resultados da previsão de cargas elétricas quando se utiliza uma RNA ARTMAP Fuzzy com treinamento convencional (OFF-LINE).

A RNA ARTMAP Fuzzy [5] é uma RNA pertencente à família de redes ART [6] (Adaptive Resonance Theory), tendo como principal característica a estabilidade e plasticidade, ou seja, a capacidade de aprender novas informações, sem perder o conhecimento adquirido anteriormente.

No treinamento continuado são incluídos novos padrões na matriz sináptica da rede neural durante a previsão, sendo desnecessário reiniciar o treinamento à medida que os dados utilizados para aprendizagem se tornam obsoletos, diferente da maior parte das RNAs encontradas na literatura. [3] [7-11].

Para avaliar a desempenho da Rede Neural ARTMAP Fuzzy com Treinamento Continuado aplicada ao problema de previsão de carga elétrica, foram realizadas três aplicações considerando horizontes de previsões diferentes, de 24, 48 e 72 horas, respectivamente.

2 Rede Neural ARTMAP Fuzzy com Treinamento Continuado

Na rede neural ARTMAP *Fuzzy*, bem como as outras redes da família ART, é possível incorporar o módulo de Treinamento Continuado devido suas características de estabilidade e plasticidade. Este mecanismo constitui de um sistema neural aperfeiçoado quando comparado à rede ARTMAP com apenas o treinamento incremental [12], [13].

O Treinamento Continuado, também denotado por treinamento ON-LINE, permite a inclusão de novos padrões à memória da rede de forma permanente. Trata-se do

desenvolvimento de um sistema que contempla o treinamento de forma contínua, e.g., havendo a disponibilidade de novos padrões assim o treinamento não necessita ser reinicializado para melhora da qualidade da previsão [14]. Deste modo, o treinamento e a análise (diagnóstico) se tornam procedimentos mais rápidos e eficientes. Para que este mecanismo funcione de forma correta, foram adicionados alguns elementos no algoritmo de treinamento da rede neural ARTMAP *Fuzzy* [14].

A mudança da arquitetura da RNA ocorre na camada F2 do módulo ARTa, que além da camada F2 já existente é adicionada a camada F2 temporária [14].

Os parâmetros da rede neural ARTMAP *Fuzzy* com Treinamento Continuado são:

- α : Parâmetro de escolha; ($\alpha > 0$, seleciona as categorias);
- β : Taxa de aprendizagem; ($\beta \in [0,1]$, responsável pela velocidade de aprendizagem da rede);
- ρ_a , ρ_b e ρ_{ab} : Parâmetros de vigilância do módulo ART_a, ART_b e inter-ART, respectivamente; (ρ_a , ρ_b e $\rho_{ab} \in [0,1]$, parâmetros responsáveis pelo número de categorias criadas, ou seja, controla a ressonância da rede);
- $NMIN$ ($NMIN \in \mathbb{N}$, com $NMIN > 1$): parâmetro de permanência, é utilizado como um contador, que verifica quantas vezes uma categoria temporária deve ser ativada para se tornar definitiva;
- $NMAX$ ($NMAX \in \mathbb{N}$, com $NMAX > 1$): parâmetro de exclusão, é utilizado como um contador, que verifica quantas vezes uma categoria não foi ativada para ser excluída.

A rede ARTMAP *Fuzzy* com Treinamento ON-LINE funciona baseada nos seguintes passos [12] [14]:

1º) Leitura dos padrões de entrada a e b ;

Os vetores de entrada e saída são normalizados com o intuito de evitar a proliferação categorias, de acordo com a equação (1).

$$\bar{a} = \frac{a}{|a|} \quad \text{e} \quad \bar{b} = \frac{b}{|b|} \quad (1)$$

2º) Codificação do vetor de entrada e saída;

$$I = [\bar{a} \quad \bar{a}^c] \quad \text{e} \quad I = [\bar{b} \quad \bar{b}^c] \quad (2)$$

3º) Escolha da categoria ganhadora na camada F_2 em ART_a e ART_b;

A camada F2 é modificada com a inclusão dos pesos temporários, além dos definitivos nos módulos ART_a e MapField. Essa inclusão é realizada com objetivo de evitar a existência de categorias semelhantes na memória da rede neural. Assim, no processo de escolha das categorias do módulo ART_a, existem categorias temporárias e definitivas [12]. Logo, são definidas duas funções de escolha em ART_a, uma para as categorias temporárias, equação (3) e outra para as categorias definitivas, equação (4). A categoria ganhadora em ART_b é calculada através da equação (5)

$$T_j^t(I) = \frac{|I \wedge w_j^t|}{\alpha + |w_j^t|} \quad (3)$$

$$T_j^d(I) = \frac{|I \wedge w_j^d|}{\alpha + |w_j^d|} \quad (4)$$

$$T_k^b(I_b) = \frac{|I_b \wedge w_k^b|}{\alpha + |w_k^b|} \quad (5)$$

Em ART_a a categoria escolhida é a com o maior valor de escolha entre as categorias temporárias e definitivas por J com $T_j = \max\{T_j^t, T_j^d\}$ e índice J mínimo e em ART_b ganha a categoria K com $T_k = \max\{T_k\}$ e índice K mínimo.

4º) É feito o teste de vigilância do módulo ART_b de acordo com (6);

$$\frac{|I_b \wedge w_K^b|}{I_b} \geq \rho_b \quad (6)$$

Se a equação (6) é satisfeita é alcançada a ressonância e atualizam-se os pesos através de (7), caso contrário ocorre o reset, assim o neurônio K é excluído do processo de busca, e é determinado um novo neurônio ganhador. Se todos neurônios são rejeitados, a rede cria um novo neurônio.

$$w_K^{novo} = \beta(I_b \wedge w_K^{velho}) + (1 - \beta)w_K^{velho} \quad (7)$$

5º) Teste de vigilância do módulo ART_a é realizado através de (8);

$$\frac{|I_a \wedge w_J^a|}{I_a} \geq \rho_a \quad (8)$$

Se a equação (8) é satisfeita ocorre a ressonância para o modelo ART_a e verifica se a adequação dos neurônios vencedores K e J através do *Match Tracking* descrito com a equação (9).

$$\frac{|y_j^b \wedge w_{JK}^{ab}|}{|y_j|} \geq \rho_{ab} \quad (9)$$

Se ocorrer a ressonância no *Match Tracking*, é ativado o índice J ganhador, confirmado os índices J e K e atualizam-se os pesos no módulo ART_a e Inter-ART através das equações (10) e (11), respectivamente.

$$w_J^{novo} = \beta(I_a \wedge w_J^{velho}) + (1 - \beta)w_J^{velho} \quad (10)$$

$$w_{jk}^{ab} = 1$$

$$w_{jk}^{ab} = 0, \text{ se } j \neq J; k \neq K \quad (11)$$

Se não ocorre a ressonância é descartada a categoria atual e há um acréscimo ε na equação 8 (parâmetro de vigilância) para excluir de vez a categoria da ART_a que não combinou com a categoria do ART_b , conforme a equação (12).

$$\rho_a = \frac{|I_a \wedge w_j^a|}{I_a} + \varepsilon \quad (12)$$

A Figura 1 ilustra uma breve arquitetura da rede neural ARTMAP Fuzzy com Treinamento Contínuo.

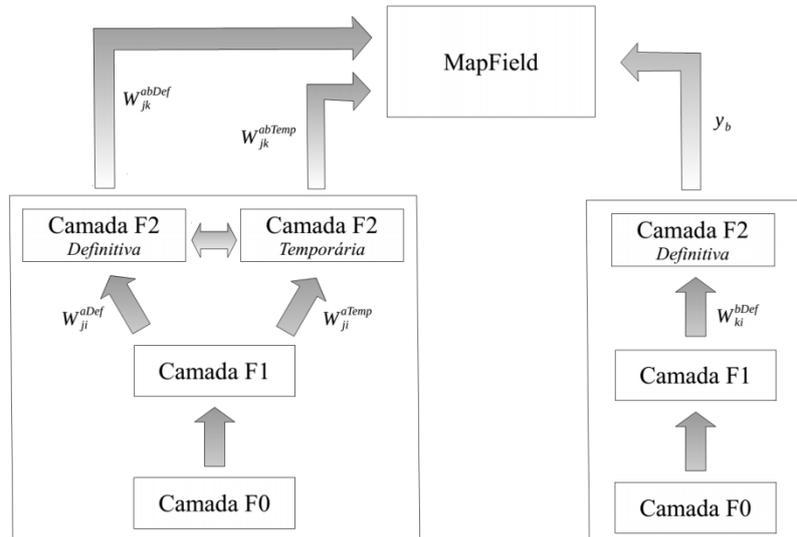


Fig.1: Rede neural ARTMAP-Fuzzy com Treinamento Contínuo

3 Aplicação da Rede Neural ARTMAP Fuzzy com Treinamento Contínuo na Previsão de Cargas Elétricas.

A rede neural ARTMAP Fuzzy com treinamento ON-LINE e com treinamento convencional (OFF-LINE) foram submetidas a três testes distintos, com objetivo de realizar diferentes horizontes de previsão. Para os três testes foram considerados no treinamento 504 vetores, com objetivo de realizar a previsão de 24 horas (Teste 1), 48 horas (Teste 2) e 72 horas (Teste 3).

O conjunto que compõe o vetor de entrada e saída, respectivamente, é definido por (13) e (14).

$$X_h = [t \ L(h) \ L(h-1) \ L(h-2) \ L(h-3)]^T, \ X \in R^b \quad (13)$$

$$Y = [L(h+1)], \ Y \in R^1 \quad (14)$$

em que:

- b : dimensão do vetor X ;
- $L(h-v)$: valor da carga v horas anterior à hora corrente h ;
- $L(h+1)$: valor da carga correspondente à hora subsequente a hora corrente h ;
- t : vetor de tempo referente aos dados históricos (dia da semana, horas) codificados em números binários.

A Tabela 1 apresenta os parâmetros utilizados para a rede neural com treinamento convencional (OFF-LINE).

Tabela 1. Parâmetros utilizados pela rede neural ARTMAP Fuzzy OFF-LINE

Parâmetros	Teste 1	Teste 2	Teste 3
Taxa de Treinamento (β)	1	1	1
Parâmetro de escolha (α)	0.001	0.001	0.001
Parâmetro de vigilância inicial do módulo ART_a (ρ_a)	0.95	0.95	0.95
Parâmetro de vigilância do módulo ART_b (ρ_b)	0.9999	0.999	0.9998
Parâmetro de vigilância do Inter-ART (ρ_{ab})	1	1	1
Acréscimo de ρ_a (ϵ)	0.0001	0.0001	0.001

Na Tabela 2 estão descritos os parâmetros utilizados nos três testes da rede neural com treinamento ON-LINE.

Para analisar os resultados obtidos, foram calculados os erros percentuais médios (MAPE) e o erro máximo (EM), calculados respectivamente pelas equações (15) e (16).

$$MAPE = \frac{1}{NT} \sum_{h=1}^{NT} \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100\% \quad (15)$$

$$EM (\%) = \text{máx} \left\{ \frac{|L(h) - \underline{L}(h)|}{L(h)} \right\} \times 100\% \quad (16)$$

sendo:

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

$\underline{L}(h)$: o valor da carga estimada pelo modelo proposto referente a hora h

NT : o número total de horas.

Tabela 2. Parâmetros utilizados pela rede neural ARTMAP Fuzzy ON-LINE

Parâmetros	Testes 1,2,3
Taxa de Treinamento (β)	1
Parâmetro de escolha (α)	0.001
Parâmetro de vigilância inicial do modulo ART_a (ρ_a)	0
Parâmetro de vigilância do modulo ART_b (ρ_b)	0.988
Parâmetro de vigilância do Inter-ART (ρ_{ab})	1
Acrescimo de ρ_a (ϵ)	0.001
Parâmetro de permanência ($NMIN$)	2
Parâmetro de permanência ($NMIN$)	200

As Tabelas 3, 4 e 5 apresentam os resultados obtidos pela rede neural ARTMAP Fuzzy com treinamento OFF-LINE e com treinamento ON-LINE sendo calculado o MAPE e EM, para as previsões de 24, 48 e 72 horas, respectivamente.

A Figura 3 mostra os resultados da previsão de carga de 24 horas (dados reais, resultados obtidos através da rede ARTMAP com treinamento OFF-LINE e os resultados gerados pela rede ARTMAP com treinamento ON-LINE).

Na Figura 4 estão representados os resultados da previsão de carga de 48 horas (dados reais, resultados obtidos através da rede ARTMAP com treinamento OFF-LINE e os resultados gerados pela rede ARTMAP com treinamento ON-LINE).

Já a Figura 5 mostra a previsão de 72 horas à frente (dados reais, resultados obtidos através da rede ARTMAP com treinamento OFF-LINE e os resultados gerados pela rede ARTMAP com treinamento ON-LINE).

Tabela 3. Resultados comparativos para a Previsão de 24 horas

Item	ARTMAP (OFF-LINE)	ARTMAP (ON-LINE)
MAPE	3,3480	1,6619
EM	7,7700	5,8800

Tabela 4. Resultados comparativos para a Previsão de 48 horas.

Item	ARTMAP (OFF-LINE)	ARTMAP (ON-LINE)
MAPE	2,7174	1,5623
EM	7.8100	5.8800

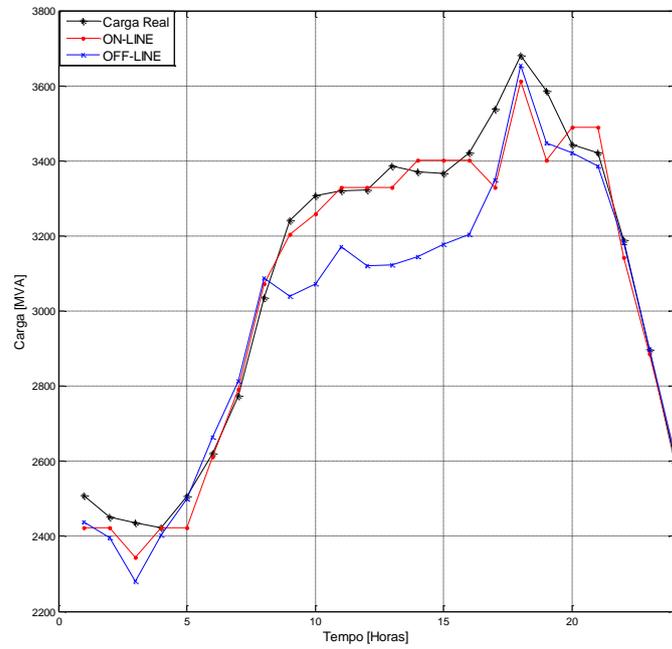


Fig. 2. Resultado da Previsão de Cargas de 24 horas

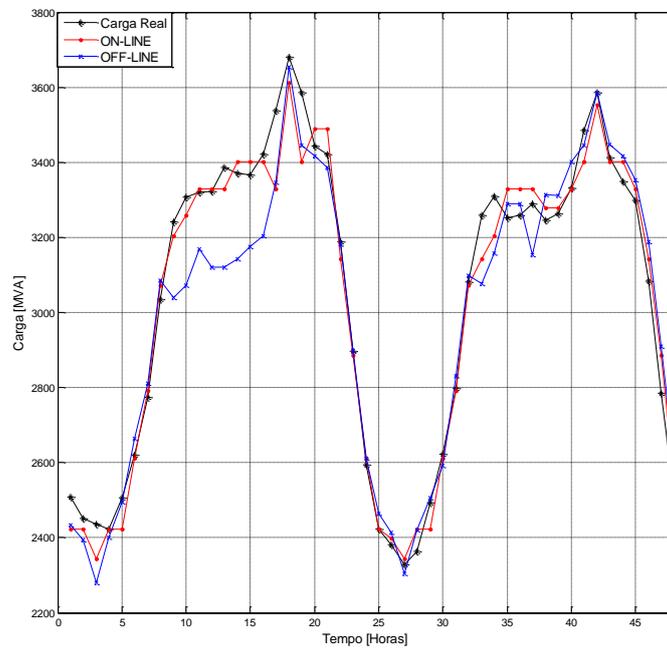


Fig. 3. Resultado da Previsão de Cargas de 48 horas.

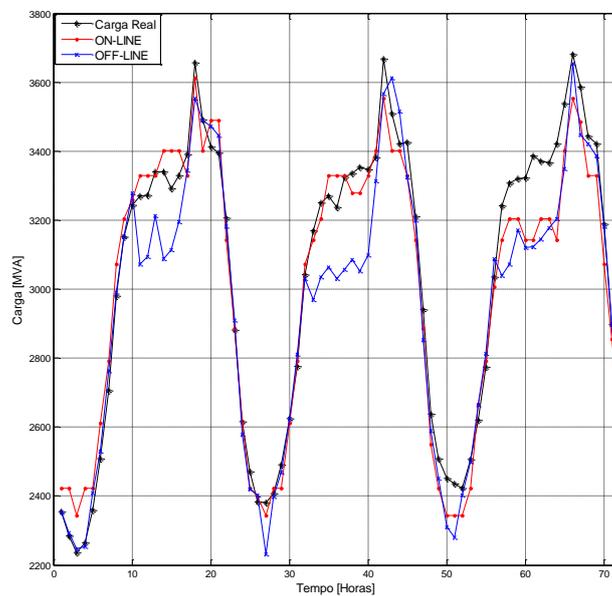


Fig. 4. Resultado da Previsão de Cargas de 72 horas

Tabela 5. Resultados comparativos para a Previsão de 72 horas

Item	ARTMAP (OFF-LINE)	ARTMAP (ON-LINE)
MAPE	3.0873	2.5278
EM	8.9600	8.1200

Pode-se observar através das Figuras 2, 3 e 4, que no treinamento OFF-LINE, conforme a previsão se distancia do ponto em que ela foi treinada a tendência do erro é aumentar, isto ocorre porque os dados utilizados no treinamento se tornam obsoletos.

Através das tabelas 3, 4, e 5 pode-se notar que os resultados obtidos pela rede utilizando o treinamento ON-LINE foi de maior precisão comparados com a rede com treinamento OFF-LINE. Isso ocorre pois, no treinamento ON-LINE conforme a disponibilidade de dados reais, a RNA tem a habilidade de avaliar se essa nova informação tem contribuição na melhora de seu desempenho, de forma que sua aprendizagem incrementa apenas informações relevantes.

Outra grande vantagem de utilizar o treinamento ON-LINE é evitar a proliferação de categorias. Conforme mostra a tabela 6, nos 3 testes realizados o treinamento ON-LINE criou um número menor de categorias em relação ao

treinamento OFF-LINE, mostrando sua capacidade de generalização, manutenção das informações relevantes e menor exigência computacional.

Tabela 6. Números de categorias criadas

Previsões	Treinamento	ART_a		ART_b
		Definitivo	Temporário	
24 horas	OFF-LINE	504	-	430
	ON-LINE	96	104	38
48 horas	OFF-LINE	495	-	204
	ON-LINE	104	113	38
72 horas	OFF-LINE	504	-	379
	ON-LINE	106	118	38

4 Conclusão

Neste trabalho foi aplicada uma rede neural ARTMAP Fuzzy com treinamento continuado na previsão de cargas elétricas em diferentes horizontes de previsão. Para analisar a eficiência da rede neural utilizando o treinamento ON-LINE, foi utilizada a mesma rede neural com treinamento convencional (OFF-LINE). Conforme as tabelas 1, 2 e 3, é possível notar que o Treinamento Continuado obteve resultados mais precisos que os resultados do treinamento convencional, o que se torna indispensável do ponto de vista econômico. Observa-se também, através das figuras 2, 3 e 4, que as curvas de previsão do treinamento ON-LINE foram de mais qualidade que as curvas do treinamento OFF-LINE, principalmente conforme o horizonte da previsão se distancia do hora final do treinamento, sendo capazes de acompanhar as curvas de cargas reais nas três aplicações. Uma das grandes vantagens de utilizar a rede neural ARTMAP *Fuzzy* com Treinamento Continuado é a não proliferação de dados irrelevantes, ou seja, sua capacidade de verificar se a nova informação contribui na melhora de seu desempenho.

References

1. O'Donovan, Short Term Forecasting: An Introduction to the Box-Jenkins Approach, New York: John Wiley & Sons, 1983.
2. Box, G.E., Jenkins, G.M. Times series analysis: forecasting and control. San Francisco, USA: Holden- Day, 1976.

3. Lopes, M. L. M.; Minussi, C. R. and Lotufo, A. P. Electric Load Forecasting Using a Fuzzy ART&ARTMAP Neural Network. *Journal of Applied Soft Computing*. 5(2), 5235-244 (2005).
4. Haykin, S., *Neural networks: A comprehensive foundation*, Prentice-Hall, Upper Saddle River, New Jersey, USA, 1994.
5. Carpenter, G. A., Grossberg, S., Markuzon, Reynolds, J. H., Rosen B. D., Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps, *IEEE Transactions on Neural Networks*, 3(5), pp. 698 – 713, (1992).
6. Carpenter, G. A., Grossberg, S. A massively parallel architecture for a self-organizing neural pattern recognition machine. *Computer Vision, Graphics, and Image Processing*. 37, 54-115, (1987).
7. Kermanshahi, B., Iwamiya, H. Up to Year 2020 Load Forecasting Using Neural Nets. *International Journal of Electrical Power & Energy Systems*, 24 (9), 789-797 (2002).
8. Abdel, R. E. Improving Electric Load Forecasts Using Network Committees. *Electric Power Systems Research*. 74, 83-94 (2005).
9. Singh, A.K., Ibraheem, S., Khatoun, S., Muazzam Md., D. K., Chaturvedi, D.K. Load Forecasting Techniques and Methodologies: A Review. In 2nd International Conference on Power, Control and Embedded Systems, (2012)
10. Li, S., Wang, P., Goel, L. A Novel Wavelet-Based Ensemble Method for Short-Term Load Forecasting with Hybrid Neural Networks and Feature Selection. *IEEE Transactions on Power Systems*. 31(3) 1788-1798 (2016).
11. Abreu, T., Lopes, M. L. M., Santos Junior, C. R. , Lotufo, A. D. P Electrical Demand Load Forecasting by ARIMA Regression and Artificial Neural Networks. *International Journal of Computer and Information Technology*. 5, 284-289 (2016).
12. Marchiori, S. C., Silveira, M. C. G , Lotufo, A. D. P. , Minussi, C. R., Lopes M. L. M. Neural network based on adaptive resonance theory with continuous training for multi-configuration transient stability analysis of electric power systems. *Applied Soft Computing*, 11, 706–715 (2011).
13. Moreno, A. L. Análise da estabilidade transitória via rede neural ART-ARTMAP Fuzzy euclidiana modificada com treinamento continuado. Tese (Doutorado em Engenharia Elétrica) – Faculdade de Engenharia, Universidade Estadual Paulista, Ilha Solteira, 2010.
14. Santos Junior, C. R., Abreu, T., Lotufo, A. D. P. Rede neural ARTMAP Fuzzy com treinamento continuado para detecção de spams, XII Congresso Brasileiro de Inteligência Computacional, Curitiba, 2015.