

Previsão de Cargas Elétricas Através de Uma Rede Neural Híbrida Back-ART Fuzzy

C. M. Oliveira, A. D. P. Lotufo

Departamento de Engenharia Elétrica
Universidade Estadual Paulista, UNESP
Ilha Solteira, São Paulo
cicero.feis.unesp@gmail.com,
annadiva@ieee.org

M. L. M. Lopes

Departamento de Matemática
Universidade Estadual Paulista, UNESP
Ilha Solteira, São Paulo
mara@mat.feis.unesp.br

M. C. G. Silveira

Serviço Técnico de Informática
Universidade Estadual Paulista, UNESP
Ilha Solteira, São Paulo
carmino@adm.feis.unesp.br

Resumo—O presente artigo apresenta um modelo híbrido de previsão de cargas elétricas que utiliza duas redes neurais artificiais: ART fuzzy e Perceptron multicamadas via algoritmo Backpropagation. O objetivo é realizar a previsão de carga elétrica em curto prazo (24 horas a frente), valendo-se das melhores características encontradas em cada arquitetura. A rede ART fuzzy é responsável pela classificação de dados históricos e a rede neural Perceptron, pela previsão em si. A partir da classificação obtida através da rede ART fuzzy é realizada a previsão de demanda de carga elétrica pela rede Perceptron. Os dados utilizados nas simulações correspondem a dados históricos de cargas elétricas fornecidos por uma empresa do setor elétrico.

Palavras-chave: ART nebulosa, backpropagation, previsão de carga, método híbrido.

Abstract- This paper presents a hybrid model for electric load forecasting using two different neural networks: ART fuzzy and Multilayer Perceptron by Backpropagation algorithm. The objective is to execute short term load forecasting (24 h in advance) containing the best characteristics in each architecture. The ART fuzzy classifies the historical data and the Perceptron runs the prediction. The data used for the simulations are historical data from a Brazilian electric company.

Keywords—ART fuzzy, backpropagation, load forecasting, hybrid method.

I. INTRODUÇÃO

A partir de 1995, no Brasil, ocorreu a reformulação do setor de fornecimento de energia, mediante a abertura do mercado às empresas privadas. Tornou-se, então, importante o conhecimento prévio da real demanda do produto, para fins de visualização do futuro quanto a diversos aspectos, como o planejamento de expansão, segurança de sistemas, fluxo de potência, entre outros ligados ao perfil da carga, estimativa de informações futuras de uma série temporal, com base em valores anteriormente obtidos [1].

Encontram-se na literatura várias técnicas de previsão de carga, dentre elas: alisamento exponencial, estimação de estado, regressão linear múltipla ou simples, filtro de Kalman, entre outras [1]. Para utilização de tais métodos é imprescindível que seja feita uma modelagem prévia da carga, com a finalidade de se obter o conhecimento de alguns dados

importantes que influenciam a carga elétrica, como por exemplo: efeitos atmosféricos (nebulosidade, variações de temperatura e velocidade do vento), além de efeitos de dias atípicos, como é o caso de feriados [1].

As técnicas baseadas na inteligência artificial vêm se destacando na literatura quanto ao problema de previsão de cargas elétricas e dentre elas as Redes Neurais Artificiais [2]. Alguns trabalhos podem ser citados tratando do assunto de previsão de cargas por redes neurais artificiais destacando a Perceptron Multicamadas com treinamento por Backpropagation ou Levenberg-Marquardt [3-7] ou ART&ARTMAP [8].

O objetivo deste artigo é utilizar uma rede neural artificial híbrida [9] (composta por duas arquiteturas de redes neurais distintas: a rede neural ART fuzzy [10-11] e a rede neural Perceptron Multicamadas - MLP (Multilayer Perceptron), via algoritmo Backpropagation, [12-13]) e aplicá-la ao problema de previsão de cargas elétricas a curto prazo.

É importante enfatizar, que esta arquitetura é uma inovação na literatura e a idéia da utilização da arquitetura ART fuzzy aliada a Perceptron multicamadas está no fundamento de tornar os dados de entrada da rede neural Perceptron multicamadas completamente binários. Isto representa um ganho de tempo de processamento, para a rede neural Perceptron multicamadas via Backpropagation, bem como a discriminação das cargas elétricas que compunham os dados de entrada da rede neural.

Os resultados obtidos pela rede neural artificial Back-ART fuzzy são satisfatórios, levando-se em consideração, os resultados apresentados na literatura referentes a rede neural Perceptron multicamadas via Backpropagation [7] propriamente dita.

II. REDES NEURAS ARTIFICIAIS

As redes neurais artificiais que compõem o modelo híbrido proposto se fundamentam em duas arquiteturas. São elas: rede neural Perceptron multicamadas e rede neural ART fuzzy.

A. Rede Neural Perceptron Multicamadas, via algoritmo Backpropagation

A rede neural Perceptron multicamadas via algoritmo Backpropagation possibilita a solução de problemas

complexos [12-13]. Tal algoritmo é considerado referência quanto à precisão obtida, principalmente quando se deseja trabalhar com problemas reais, neste caso, a previsão de cargas elétricas.

O algoritmo *Backpropagation* se trata de um método eficiente para o treinamento da rede neural *Perceptron* multicamadas, e ocorre de modo supervisionado [12].

Existem características que devem ser definidas antes de efetuar o treinamento da rede neural dentre elas tem-se: a) determinar o número de camadas intermediárias; b) definir o número de neurônios de cada camada intermediária; e c) especificar os pesos sinápticos dos neurônios interconectados de diferentes camadas [14].

O treinamento da rede neural *Perceptron* multicamadas via algoritmo *Backpropagation* ocorre da seguinte forma [12]: os padrões são apresentados às unidades da camada de entrada, as quais fazem o processamento e propagam para o(s) neurônio(s) da(s) saída(s), que processa(m) os resultados vindos da camada intermediária antecedente, obtendo a(s) saída(s) estimada(s), a(s) qual(ais) será(ao) comparada(s) com o(s) valor(es) desejado(s) obtendo desta maneira o(s) erro(s), o qual é retropropagado às camadas anteriores, até atingir a camada de entrada, adaptando-se os pesos das camadas intermediárias, modificando-os.

No algoritmo *Backpropagation*, ocorre a adaptação de pesos por meio do método do gradiente descendente, que minimiza o erro quadrático. Inicialmente, os pesos são representados por números aleatórios no intervalo]0,1[e a soma dos erros quadráticos de cada neurônio da camada de saída é dada por [13]:

$$\varepsilon^2 = \sum_{i=1}^{ns} \varepsilon_i^2$$

sendo:

$\varepsilon_i = d_i - y_i$
 d_i : saída desejada (i -ésimo neurônio da camada de saída);
 y_i : saída estimada (i -ésimo neurônio da camada de saída);
 ns : número de neurônios da camada de saída.

Através do método do gradiente descendente, tem-se o ajuste de pesos dado por (1):

$$V_i(h+1) = V_i(h) - \theta_i(h) \quad (1)$$

no qual:

$\theta_i(h) = \gamma (\nabla_i(h))$
 $V_i = [w_{0i} \ w_{1i} \ \dots \ w_{ni}]^T$
 h : índice de iteração;
 $\nabla_i(h)$: gradiente do erro quadrático dos pesos do neurônio i ;
 γ : taxa de aprendizado.

Obtém-se, então, a adaptação de pesos por (2) [13]:

$$V_i(h+1) = V_i(h) - 2\gamma \beta_i X_i \quad (2)$$

Caso o i -ésimo neurônio esteja na última camada tem-se:

$$\beta_i = \sigma_i \varepsilon_i$$

Se o i -ésimo neurônio estiver em outras camadas tem-se:

$$\beta_i = \sigma_i \sum_{j \in Q(i)} w_{ij} \beta_j$$

sendo:

σ_i : derivada da função de ativação;
 $Q(i)$: conjunto de índices dos neurônios da próxima camada do i -ésimo neurônio e que estão interligados ao i -ésimo neurônio.

Para tornar o algoritmo *Backpropagation* mais eficiente computacionalmente, é viável utilizar o algoritmo *Backpropagation* com momento, no qual o cálculo do gradiente é realizado como em (1) e a adaptação de pesos é dada por [13]:

$$v_{ij}(h+1) = v_{ij}(h) - \Delta v_{ij}(h)$$

sendo:

$\Delta v_{ij}(h) = 2\gamma(1 - \eta)\beta_j x_i + \eta \Delta v_{ij}(h-1)$
 v_{ij} : peso da interligação do i -ésimo e j -ésimo neurônio;
 η : constante momento ($0 \leq \eta \leq 1$).

Quanto ao parâmetro β_i , o cálculo é feito de maneira semelhante ao do algoritmo *Backpropagation* sem momento.

B. Rede Neural ART Fuzzy

A rede neural ART *fuzzy* tem como uma de suas principais características a capacidade de produzir respostas estáveis (categorias ou *clusters*) relacionadas a padrões de entradas analógicos ou binários. O treinamento da rede ART *fuzzy* é feita de forma não supervisionada.

Rede neural ART *fuzzy* mantém o dilema de estabilidade/plasticidade [10-11], ou seja, tem capacidade de aprendizado com ajuste de pesos, preservando conhecimento anteriormente adquirido. Ela utiliza a teoria dos conjuntos *fuzzy* [15], através do operador de interseção (\wedge).

Os passos efetuados para o desenvolvimento do algoritmo ART *fuzzy* será descrito para uma melhor compreensão da arquitetura [15-16]:

Passo 1. Valores iniciais dos pesos e inicialização de parâmetros da rede:

O processo é iniciado, atribuindo-se o valor 1 a todos os pesos, ou seja, os nós estão descomprometidos ou desativados, conforme (3):

$$w_{jI}(0) = \dots = w_{jM}(0) = 1 \quad (3)$$

Passo 2. Normalização do vetor de entrada:

Esta fase tem como função evitar a proliferação de categorias, sendo que, a normalização é realizada por (4):

$$I = a / |a| \quad (4)$$

sendo:

a : vetor de entrada;

$I = [I_1, I_2, \dots, I_M]$;

$|\cdot|$: função norma.

A norma é dada por:

$$|a| = \sum_{i=1}^M |a_i|$$

Passo 3. Codificação complementar:

Nesta fase, preserva-se a amplitude de informação dos vetores de entrada. Para se obter o complemento do vetor de entrada, tem-se:

$$a_i^c = 1 - a_i$$

cuja representação do vetor de entrada é dada por (5):

$$I = [a \ a^c] = [a_1 \dots a_M \ a_1^c \dots a_M^c] \quad (5)$$

Passo 4. Escolha de categoria:

O cálculo da função de escolha para cada uma das entradas é feito, utilizando-se:

$$T_j = \frac{|I \wedge w_j|}{\alpha + |w_j|}$$

sendo:

\wedge : operador *fuzzy* AND, que se define por:

$$(p \wedge q)_i = \min(p_i, q_i)$$

O índice J é o responsável pela indexação da categoria escolhida, sendo:

$$T_J = \max\{T_j : j = 1, \dots, N\}$$

Passo 5. Ressonância (Critério de Vigilância):

A ressonância irá ocorrer quando a categoria escolhida satisfizer o critério de vigilância dado por [15-16]:

$$\frac{|I \wedge w_j|}{|I|} \geq \rho$$

sendo:

ρ : parâmetro de vigilância.

Em caso de não ocorrer a ressonância, o valor da função de escolha T_j é fixado em 0 evitando que o processo de busca persista na mesma categoria. Sendo assim, a busca continua até que a categoria escolhida J satisfaça o critério de vigilância.

Passo 6. Aprendizagem:

Finalizada a busca, ocorre a adaptação de pesos do vetor w_j , conforme (6) [16-17]:

$$w_j^{novo} = \alpha (1 \wedge w_j^{velho}) + (1 - \alpha)w_j^{velho} \quad (6)$$

sendo:

α : taxa de treinamento da rede neural ART *fuzzy*.

III. REDE NEURAL BACK-ART FUZZY APLICADA AO PROBLEMA DE PREVISÃO

A previsão de cargas elétricas é realizada através de duas redes neurais distintas, sendo uma rede neural ART *fuzzy*, que possui uma das características necessárias para o funcionamento da rede neural artificial (dilema da estabilidade/plasticidade) e a rede neural *Perceptron* multicamadas via algoritmo *Backpropagation*, considerado na literatura um benchmark em termos de precisão.

O objetivo é utilizar a rede neural ART *fuzzy* como um módulo que capta todas as características do conjunto de dados de entrada agrupando-os em seus respectivos padrões (categorias ou *clusters*). Estas categorias são associadas aos dados de tempo relacionados ao banco de dados de entrada o qual foi classificado.

O conjunto de dados de entrada do módulo ART *fuzzy* é composto por dados de cargas elétricas horárias relacionadas às horas $h, h-1, h-2$ e $h-3$ conforme mostra a Figura 1.

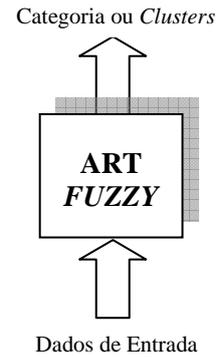


Figura 1. Módulo ART *fuzzy*.

A saída do módulo ART *fuzzy* será a classificação das cargas elétricas em categorias.

A rede neural *Perceptron* multicamadas tem a incumbência de realizar todo o processamento e, conseqüentemente, a previsão de cargas elétricas. O conjunto de dados de entradas da rede neural *Perceptron* multicamadas será composto da categoria proveniente do módulo ART *fuzzy* e dos dados de tempo relacionados a dia da semana (domingo a sábado), hora e feriado. Devido a diferença entre os dados de entrada (categoria, dia da semana, hora e feriado) foi necessário efetuar a binarização destes dados para que a rede neural *Perceptron* multicamadas pudesse processar corretamente. Os dados de saída da rede neural *Perceptron* multicamadas é formada pelo conjunto de cargas elétricas da hora subsequente, ou seja, hora ($h+1$). Assim tem-se:

$$X_{MLP} = [CAT^{bin} \ t^{bin}]^T$$

$$Y_{MLP} = [L(h+1)]^T$$

sendo:

CAT^{bin} : vetor binarizado da categoria obtida pelo módulo ART *fuzzy*;

t^{bin} : vetor contendo dados de tempo (dia da semana, hora e feriado) binarizado;

$L(h+1)$: carga elétrica referente a hora $(h+1)$.

A dimensão do vetor de entradas da rede neural artificial *Perceptron* multicamadas é de tamanho 18, no qual 9 bits são provenientes da binarização dos dados de tempo (dia da semana, hora e feriado) e 9 bits da representação binária das categorias obtidas pelo módulo ART *fuzzy*. Foram utilizadas cargas horárias de uma empresa do setor elétrico brasileiro, com intervalos temporais pré-definidos da seguinte forma:

- **Aplicação 1:** 1 a 31 de julho de 1998 (744 cargas);
- **Aplicação 2:** 1 de junho a 31 de julho de 1998 (1464 cargas);
- **Aplicação 3:** 1 de maio a 31 de julho de 1998 (2208 cargas).

A Figura 2 apresenta a rede neural Back-ART *fuzzy* [9], organizada e ajustada para resolver o problema de previsão de cargas elétricas. Pode-se observar, na Figura 2, as duas redes neurais: ART *Fuzzy* e *Perceptron* multicamadas, que compõem a rede neural híbrida.

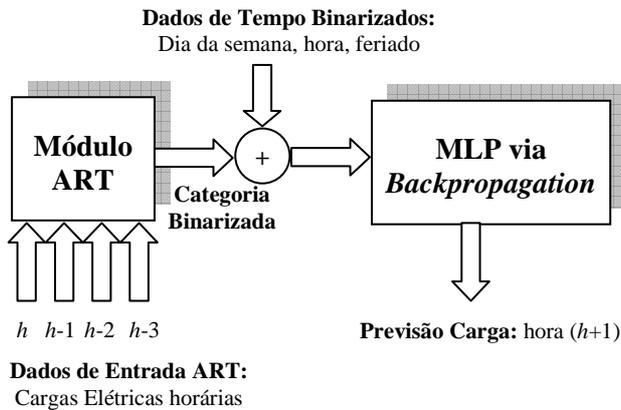


Figura 2. Rede neural Back-ART *fuzzy*.

Na fase de previsão, ambas as redes neurais passam a ter atividade simultânea, sendo que a primeira rede neural (ART *fuzzy*) realiza a classificação de dados e a segunda rede neural (*Perceptron* multicamadas), fica responsável pela previsão da carga elétrica referente hora posterior (subseqüente).

IV. RESULTADOS

Para analisar a metodologia proposta fez-se análise dos resultados obtidos da previsão de cargas elétricas utilizando o cálculo do erro médio percentual absoluto (MAPE), bem como do erro máximo da previsão da seguinte forma:

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

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

no qual:

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

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

N : número total de horas.

A Tabela I apresenta os parâmetros utilizados na rede neural Back-ART *fuzzy* para a aplicação 1.

TABELA I. PARÂMETROS DA REDE NEURAL - APLICAÇÃO 1

| PARÂMETROS | VALORES |
|--|---------|
| Número de vetores padrão | 744 |
| Taxa de treinamento - ART <i>fuzzy</i> | 1,0 |
| Parâmetro de escolha | 0,1 |
| Parâmetro de vigilância - Treinamento | 0,98 |
| Parâmetro de vigilância - Diagnóstico | 0,5 |
| Número de Camadas | 3 |
| Quantidade de neurônios (por camada) | 18-35-1 |
| Tolerância | 0,08 |
| Taxa de Aprendizado - MLP | 2,0 |
| Constante Momento | 0,9 |
| Lambda | 1,0 |

A Figura 3 mostra o resultado obtido pela rede Back-ART *fuzzy*, para previsão a curto prazo, utilizando-se as cargas do mês de julho de 1998 referente à Aplicação 1. As cargas elétricas previstas são referentes ao dia 1 de agosto de 1998.

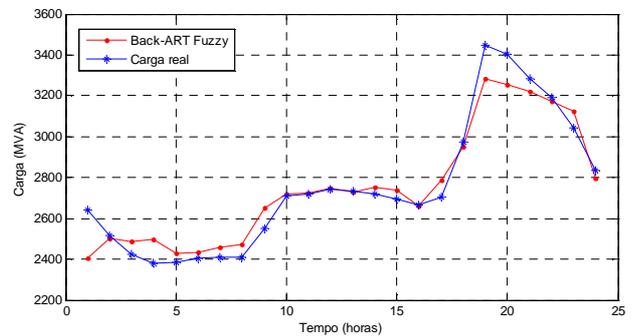


Figura 3. Resultado da rede Back-ART *fuzzy*.

TABELA II. PARÂMETROS DA REDE NEURAL - APLICAÇÃO 2

| PARÂMETROS | VALORES |
|--|---------|
| Número de vetores padrão | 1464 |
| Taxa de treinamento - ART <i>fuzzy</i> | 0,1 |
| Parâmetro de escolha | 1,0 |
| Parâmetro de vigilância - Treinamento | 0,98 |
| Parâmetro de vigilância - Diagnóstico | 0,6 |
| Número de Camadas | 3 |
| Quantidade de neurônios (por camada) | 18-34-1 |
| Tolerância | 0,06 |
| Taxa de Aprendizado - MLP | 4,0 |
| Constante Momento | 0,8 |
| Lambda | 0,64 |

Na Tabela II, têm-se os parâmetros utilizados para o treinamento e diagnóstico da rede neural Back-ART *fuzzy*.

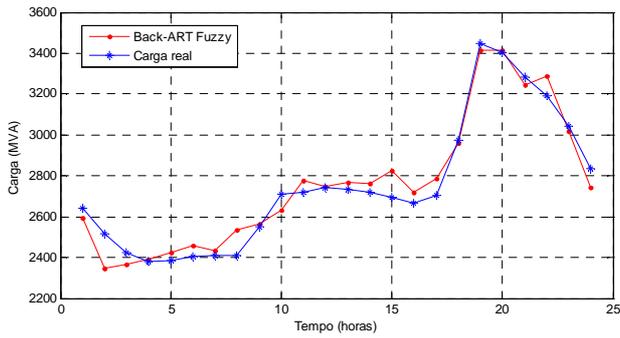


Figura 4. Resultado da rede Back-ART *fuzzy*.

A Figura 4 mostra o resultado obtido para a Aplicação 2, considerando-se 61 dias de cargas elétricas, com 1464 dados (junho e julho de 1998), sendo que a previsão está sendo efetuada para o dia 1 de agosto de 1998.

Conforme Tabela III, têm-se os parâmetros utilizados para a Aplicação 3 que utiliza cargas elétricas horárias de 91 dias, representando 2208 dados (maio a julho de 1998). O objetivo é prever a carga elétrica do dia 1 de agosto de 1998

TABELA III. PARÂMETROS DA REDE NEURAL – APLICAÇÃO 3

| PARÂMETROS | VALORES |
|--|---------|
| Número de vetores padrão | 2208 |
| Taxa de treinamento - ART <i>fuzzy</i> | 0,1 |
| Parâmetro de escolha | 1,0 |
| Parâmetro de vigilância - Treinamento | 0,99 |
| Parâmetro de vigilância - Diagnóstico | 0,7 |
| Número de Camadas | 31 |
| Quantidade de neurônios (por camada) | 18-39-1 |
| Tolerância | 0,06 |
| Taxa de Aprendizado - MLP | 2,5 |
| Constante Momento | 0,7 |
| Lambda | 0,8 |

A Figura 5 mostra o resultado obtido pela rede neural híbrida Back-ART *fuzzy*, utilizando-se as cargas elétricas dos meses de maio a julho de 1998 para o treinamento.

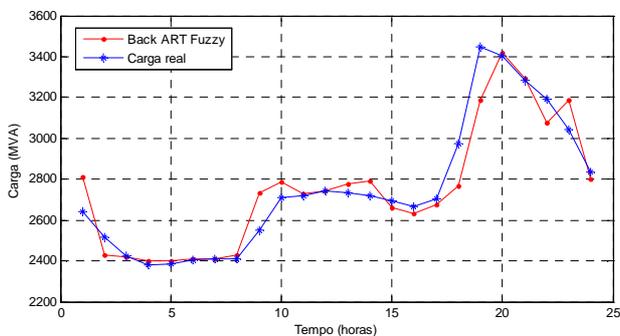


Figura 5. Resultado da rede Back-ART *fuzzy*.

Os resultados obtidos pela metodologia proposta (Rede neural híbrida Back-ART *Fuzzy*) serão comparados com os resultados de Nose Filho et al. [7] com relação a arquitetura da rede neural *Perceptron* Multicamadas via algoritmo Backpropagation.

Na Tabela IV, pode-se observar os resultados do MAPE e erro máximo com relação obtidos para as três aplicações (1, 2 e 3), levando em consideração os valores obtidos de previsão de carga elétrica a curto prazo, para a metodologia proposta e o artigo de Nose Filho et al. [7].

Ressalta-se que Nose Filho et al. [7] comparou diversas técnicas de redes neurais artificiais, porém, a comparação neste artigo somente foi feita para a mesma arquitetura no intuito de mostrar que um procedimento híbrido aplicado a esta arquitetura pode vir a contornar diversas desvantagens que ela apresenta devido ao algoritmo de treinamento do gradiente descendente (mínimo local, saturação, tempo de processamento elevado, etc.). Portanto, os resultados obtidos pela rede neural Back-ART *Fuzzy* são parecidos com os resultados obtidos na literatura.

TABELA IV. COMPARAÇÃO ATRAVÉS DO MAPE E ERRO MÁXIMO

| RNA | APLICAÇÃO | MAPE (%) | ERRO MÁXIMO (%) |
|--|-----------|----------|-----------------|
| Back-ART <i>Fuzzy</i> | 1 | 1,9979 | 4,8453 |
| | 2 | 2,0929 | 5,0218 |
| | 3 | 2,3134 | 7,0879 |
| MLP via <i>Backpropagation</i> com momento (Nose Filho et al., 2009) | 1 | 2,1768 | 9,0214 |
| | 2 | 2,0689 | 6,7439 |
| | 3 | 2,3205 | 7,6358 |

No que diz à previsão de carga elétrica a curto prazo, os resultados demonstraram que o modelo híbrido, rede Back-ART *fuzzy*, se mostra eficiente, com capacidade de apresentar resultados satisfatórios, apesar de que se forem comparados com outras metodologias tradicionais, como por exemplo ANFIS (rede neuro *fuzzy*), GRNN (*General Regression Neural Network*), *Perceptron* multicamadas com treinamento por *Levenberg-Marquardt* o MAPE obtido pela metodologia proposta está um pouco acima destes.

V. CONCLUSÃO

A utilização de redes neurais, aliadas ao hibridismo, tem possibilitado grandes avanços na resolução do problema de previsão de cargas elétricas, seja de curto, médio ou longo prazo buscando resultados de forma satisfatória e com baixo custo computacional. O artigo teve o intuito de utilizar uma rede neural híbrida, destacando as melhores características das arquiteturas das redes neurais artificiais utilizadas no modelo que foram: ART *fuzzy* e *Perceptron* multicamadas via algoritmo *Backpropagation*.

A rede neural ART *fuzzy* possibilitou a classificação das cargas elétricas em categorias. As categorias obtidas do módulo ART *fuzzy* foram binarizadas e unidas aos dados de

tempo binarizados a qual pertencia a carga elétrica referenciada (dia da semana, hora e o fato de ser ou não feriado) para gerar os dados de entrada da rede neural *Perceptron* multicamadas, via algoritmo *Backpropagation*, a qual é responsável em realizar a previsão da carga elétrica.

No intuito de obter a previsão de carga a curto-prazo, 24 horas à frente, foram realizados três testes, respectivamente, em relação a 744 cargas - primeira aplicação (mês de julho de 1998); 1464 cargas - segunda aplicação (meses de junho e julho de 1998) e 2208 cargas - terceira aplicação (meses de maio a julho de 1988). Os resultados de previsão de demanda de cargas elétricas obtidos com relação as aplicações 1, 2 e 3, forneceram valores do MAPE pouco superior a 2% e erros máximos inferiores a 9%, demonstrando a viabilidade do modelo híbrido na previsão de carga elétrica. A finalidade de compor uma rede neural híbrida (ART *fuzzy* e *Perceptron* multicamadas) fundamenta-se em utilizar como dados de entrada da rede neural *Perceptron* multicamadas via algoritmo *Backpropagation* apenas dados binários, o que favorece um ganho em tempo de processamento, além de bons resultados (previsões de cargas elétricas horárias).

REFERENCES

- [1] T. M. O'Donovan, Short Term Forecasting: an Introduction to the Box-Jenkins approach, New York: John Wiley & Sons, 1983, 256 p.
- [2] S. Haykin, Neural Networks: A Comprehensive Foundation, Prentice-Hall, Upper Saddle River, New Jersey, USA, 1999.
- [3] J. N Fidalgo, and J. A. P. Lopes, "Load forecasting performance enhancement when facing anomalous events," IEEE Transactions on Power Systems, New York, vol. 20, no. 1, pp. 408-415, Feb. 2005.
- [4] L. M. Saini, and M. K. Soni, "Artificial neural network based peak load forecasting using Levenberg-Marquardt and quasi-Newton methods," IEEE Proceedings on Generation, Transmission and Distribution, New York, vol. 149, no. 5, p. 578- 584, 2002.
- [5] N. Amjady, "Short-term bus load forecasting of power systems by a new hybrid method," IEEE Transactions on Power Systems, New York, vol. 22, no. 1, pp. 333-341, Feb. 2007.
- [6] K. Nose-Filho, K. A. M. Araújo, J. L. Y. Maeda, A. D. P. LOTUFO, "Previsão de cargas elétricas utilizando diferentes arquiteturas de redes neurais artificiais com o auxílio das toolboxes do MATLAB," In: 8th Latin-American Congress on Electricity Generation and Transmission – CLAGTEE 2009, Ubatuba, Brasil, 2009.
- [7] K. Nose Filho, A. D. P. Lotufo and C. R. Minussi, "Short-term load forecasting using a modified general regression neural network," IEEE Transactions on Power Delivery, vol. 26, no. 4, Oct. 2011.
- [8] M. L. M. Lopes, A. D. P. Lotufo, and C. R. Minussi, "Application of the fuzzy ART&ARTMAP neural network to the electrical load forecasting problem," In: Jimmy J. Zhu. (Org.). Forecasting Model - Methods and Applications. 12 ed.: iConcept Press, 2010, pp. 179-190.
- [9] C. M. Oliveira, Previsão de Cargas Elétricas através de uma Rede Neural Híbrida Back-ART Fuzzy, 2012, Dissertação (Mestrado) – Faculdade de engenharia, Universidade Estadual Paulista Julio de Mesquita Filho, Ilha Solteira.
- [10] G. A. Carpenter, and S. A. Grossberg, "Massively parallel architecture for a selforganizing neural pattern recognition machine," Computer Vision, Graphics and Image Processing. New York, vol. 37, pp. 54-115, 1987a.
- [11] G. A. Carpenter, and S. A. Grossberg, "ART 2: Self-organizing of stable category recognition codes for analog input patterns," Applied Optics, New York, vol. 26, pp. 4919-4930, 1987b.
- [12] P. J. Werbos, Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences, (Thesis) - Harvard University, Harvard, 1974.
- [13] B. Widrow, and M. A. Lehr. "30 years of adaptative neural networks: Perceptron, madalineand backpropagation," Proceedings of the IEEE, New York, vol. 78, no. 9, pp. 1415-1442, 1990.
- [14] G. Cybenko, "Approximation by superpositions of sigmoidal function," Mathematics of Control Signals, and Systems, New York, vol. 2, pp. 303-314, 1989.
- [15] L. A. Zadeh, "Fuzzy sets," Information and control, New York, vol.8, pp. 338-353, 1965.
- [16] G. A. Carpenter, S. Grossberg, N. Markuzon, J. H. Reynolds, and D. B. Rosen, "Fuzzy ARTMAP: A neural network architecture for incremental supervised learning of analog multidimensional maps," IEEE Transactions on Neural Networks, vol. 3, no. 5, pp. 698-713, 1992.
- [17] M. Georgiopoulos, H. Fernlund, G. Bebis, and G. L. Heileman, "Order of search in fuzzy ART and fuzzy ARTMAP: Effect of the choice parameter," Neural Networks, vol. 9, no. 9, pp. 1541-1559, 1996.