

**Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**

---

# Previsão de Carga Multinodal a curto prazo utilizando Redes Neurais Artificiais

Aline Jardim Amorim<sup>1</sup>

Departamento de Engenharia Elétrica, FEIS, UNESP, Ilha Solteira, SP

Carlos Roberto Minussi<sup>2</sup>

Departamento de Engenharia Elétrica, FEIS, UNESP, Ilha Solteira, SP

Mara Lúcia Martins Lopes<sup>3</sup>

Departamento de Matemática, FEIS, UNESP, Ilha Solteira, SP

**Resumo.** Apresenta-se, neste artigo, uma metodologia para a previsão de carga multimodal baseada na teoria de redes neurais artificiais. A rede neural usada é uma arquitetura multicamadas feedforward com o treinamento realizado usando-se o algoritmo backpropagation (BP). O algoritmo BP é considerado, pela literatura especializada, como um método benchmark em termos de precisão. Porém, possui baixa convergência, ou não convergência, em razão, principalmente, da existência de pontos de mínimos locais e a ocorrência de paralisia no ajuste de pesos. Por conseguinte, implementam-se melhorias no desempenho da técnica de treinamento por meio da adaptação da taxa de treinamento baseado num controlador *fuzzy* e a adaptação dos principais parâmetros da função de ativação (sigmoide): inclinação e deslocamento. Este conjunto de ações tem proporcionado uma sensível melhoria dos resultados auferidos, principalmente, aumentando a velocidade convergência do processo de treinamento compreendendo uma redução drástica de casos de ocorrência de paralisia e o escape de pontos mínimos locais. A realização da previsão multimodal tem-se tornado viável com a inclusão do conceito definido como "fator de participação da carga global". Neste caso, a previsão é constituída por dois módulos: (1) previsão global e (2) a previsão local. Visando à análise de desempenho da arquitetura proposta, apresenta-se uma aplicação (previsão de carga multimodal 24h à frente) considerando-se uma base de dados (Centralised Dataset - CDS) disponibilizada pelo Electricity Commission da Nova Zelândia.

**Palavras-chave.** Redes Neurais, Backpropagation, Lógica *Fuzzy*, Previsão de carga, Fator de Participação.

## 1 Introdução

A carga dos sistemas de energia elétrica constitui-se numa rotina de grande importância, pois a totalidade dos estudos realizados (fluxo de potência, diagnóstico da estabilidade estática e dinâmica, análise de sensibilidade etc.), que envolvem o planejamento e a operação, é dependente do conhecimento da demanda a ser atendida pelas companhias

---

<sup>1</sup>alinejardinekes@yahoo.com.br

<sup>2</sup>crminussi@gmail.com

<sup>3</sup>mara@mat.feis.unesp.br

do setor elétrico. A carga a ser atendida deve ser prevista, com a devida antecedência, para que tais estudos sejam ultimados a tempo de serem realizados os referidos estudos e o planejamento da operação. Na maioria das vezes, a previsão de carga é realizada levando-se em conta a carga global correspondente ao somatório de todas as cargas que serão atendidas pelo sistema. Esta previsão é determinada a partir de bases históricas do consumo de energia e, também, de outros parâmetros como fatores climáticos, dias atípicos etc. A previsão de carga tem sido realizada por métodos clássicos, e.g., como proposta na referência [7]. Na atualidade, os métodos denominados inteligentes (Redes Neurais Artificiais (RNA) [4, 12], teoria de conjuntos *fuzzy* [13] etc.) têm sido intensamente empregados na literatura especializada como procedimentos alternativos que, via de regra, são considerados promissores. As cargas locais, ou seja, nos diversos pontos da rede elétrica (subestação, alimentador, transformador etc.), as quais são as que efetivamente interessam ao operador, são estabelecidas baseadas na divisão (partição) da carga global. Na literatura há pouca disponibilidade de propostas neste sentido [2, 6, 10]. Por conseguinte, neste artigo, tem-se por objetivo o desenvolvimento de uma metodologia para a previsão multimodal de sistemas elétricos de potência baseada nas RNA. Trata-se de uma arquitetura multicamadas feedforward com treinamento realizado usando-se o algoritmo backpropagation (BP) [11], mas observam-se alguns problemas que têm distanciado o interesse atual por se tratar de uma técnica bastante lenta, ou seja, apresentando baixa taxa de convergência e até, em muitos casos, não havendo a convergência requerida. As causas principais são procedentes da existência de um grande número de pontos de mínimos locais observados na função multidimensional do erro quadrático correspondente à saída da RNA e a ocorrência de processos de paralisia [12]. Neste artigo, são implementadas melhorias importantes que visam tornar o algoritmo BP mais competitivos: (1) adaptação "ótima" da taxa de treinamento via uso de um controlador fuzzy; (2) a inclusão de novas equações no processo de adaptação de pesos no algoritmo BP contemplando o ajuste dos parâmetros de inclinação e o de deslocamento da função sigmoide. O modelo previsional é formulado considerando-se dois módulos: previsões global e local. A previsão global é realizada de modo completo envolvendo os dados históricos e demais dados exógenos. A previsão local é tratada de forma mais simples por meio do uso do conceito do "Fator de Participação da Carga Global" (FPCG) [1]. Ressalta-se que o segundo módulo (previsão local) é realizado com um custo computacional adicional bastante reduzido representando uma grande vantagem em relação às demais propostas disponíveis na literatura [4, 6, 10] entre outras).

## 2 Metodologia

O algoritmo BP convencional destina-se ao treinamento de RNA feedforward baseado no método do gradiente descendente, que consiste na adaptação dos pesos com o propósito de minimizar o erro quadrático da RNA. O erro quadrático instantâneo medido na saída da RNA é dado por [5, 12] :

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

sendo:  $\varepsilon_i = d_i - y_i$ . Onde  $d_i$  é a saída desejada do  $i$ -ésimo elemento da última camada da rede,  $y_i$  a saída do  $i$ -ésimo elemento da última camada da rede e  $ns$  o número de neurônios da última camada. A função de ativação corresponde à função sigmoide (que é afeita ao problema abordado neste artigo, ou seja, a previsão de carga) definida por [2]

$$y_i = \frac{1}{1 + \exp^{-\lambda(s_i + \rho)}} \quad (2)$$

Em que  $\lambda$  e  $\rho$  são os parâmetros de declividade e translação da função sigmoide, respectivamente, e  $s_i$  é a saída do  $i$ -ésimo neurônio. Este algoritmo pode ser encontrado em [12]. Contudo, este algoritmo apresenta problemas referentes à baixa convergência decorrentes de processo de paralisia e a possibilidade de convergência para pontos mínimos locais. Visando dar maior capacidade de convergência, neste artigo, implementa-se uma versão do algoritmo BP contemplando melhorias que correspondem à maximização do seu desempenho, ou seja, adicionar, ao algoritmo convencional do BP, a possibilidade da adaptação da taxa de treinamento, assim como do ajuste dos parâmetros que definem a inclinação (declividade) e o deslocamento da função sigmoide. A adaptação da taxa de treinamento é formulada via projeto de um controlador fuzzy, considerando-se uma versão da referência [3]. Com relação aos parâmetros de declividade e de translação sigmoide, os ajustes são executados da mesma forma como é conduzido na adaptação dos pesos da RNA. A adaptação da declividade e do deslocamento da função sigmoide visa evitar a convergência para um ponto de mínimo local e a ocorrência de processo de paralisia. Ainda que estes resultados sejam empíricos, nos vários experimentos realizados tem-se observado uma sensível melhoria dos resultados: maior precisão, maior rapidez e ausência de paralisia. Baseado no algoritmo BP convencional, a seguir, serão abordados os procedimentos relativos às adaptações correspondentes aos parâmetros de declividade e de translação da função sigmoide. Os parâmetros de  $\lambda$  e  $\rho$  possuem taxas de treinamentos, para as quais são realizados ajustes, baseados no algoritmo BP convencional que utiliza o método do gradiente descendente. O ajuste destes parâmetros é semelhante ao ajuste dos pesos [12], considerando o  $i$ -ésimo neurônio.

## 2.1 Ajuste do Parâmetro de Inclinação da Função Sigmoide

O ajuste do parâmetro de inclinação da função sigmoide pode ser dado pela equação [9]:

$$\lambda_i(h + 1) = \lambda_i(h) + 2\gamma_\lambda \beta_i^\lambda \quad (3)$$

$\lambda_i$  : vetor contendo a inclinação do neurônio  $i$ . Se o elemento  $i$  encontrar-se na última camada, então:

$$\beta_i^\lambda = \sigma_i^\lambda \varepsilon_i \quad (4)$$

Se o elemento  $i$  encontrar-se nas demais camadas, tem-se:

$$\beta_i^\lambda = \sigma_i^\lambda \sum \omega_{ik} \beta_k^\lambda \quad (5)$$

Derivando a equação (2), em relação  $\lambda_i$ , obtém-se:

$$\sigma_i^\lambda = (s - \rho)y[1 - y^2] \quad (6)$$

$\sigma_i^\lambda$ : derivada da função sigmoide com relação a  $\lambda_i$

## 2.2 Ajuste do Parâmetro Translação da Função Sigmoide

Para ajustar o parâmetro da translação da função sigmoide é dado por [9]:

$$\rho_i(h + 1) = \rho_i(h) + 2\gamma_\rho \beta_i^\rho \quad (7)$$

em que  $\rho_i$  é o vetor contendo a translação do neurônio  $i$ . Se o elemento  $i$  encontrar-se na última camada, então:

$$\beta_i^\rho = \sigma_i^\rho \varepsilon_i \quad (8)$$

Se o elemento  $i$  encontrar-se nas demais camadas, tem-se:

$$\beta_i^\rho = \sigma_i^\rho \sum \omega_{ik} \beta_k^\rho \quad (9)$$

Derivando a equação (2), em relação  $\rho_i, \sigma_i^\rho$ , pode ser descrita pela equação:

$$\sigma_i^\rho = \frac{\partial}{\partial \rho_i} \left\{ \frac{1}{1 + e^{-\lambda(s_i - \rho)}} \right\} = -\lambda y(1 - y) \quad (10)$$

O controlador fuzzy é empregado com vistas a gerar a taxa de treinamento variável, ajustando-a para mais ou para menos com o propósito de acelerar a convergência, ou seja, fazer com que o erro global (1) tenda para zero em um número mínimo de iterações. Este procedimento é descrito em [2]. A previsão multinodal é realizada por meio de dois sistemas previsores, o Sistema Previsor Global (SPG), composto por uma RNA responsável pela previsão de carga global e o Sistema Previsor Local (SPL) que é formado por vários módulos, sendo que cada módulo é responsável pela previsão local [1]. O módulo SPL é treinado de forma independente utilizando os dados exógenos (dia e hora) e dados de carga (MW). Com isso, estabelecem-se as estimativas de carga para cada ponto de interesse da rede elétrica, onde o FPCG é determinado para cada módulo pela equação (11) [1]:

$$FPCG_j = \frac{CL_j}{CG} \quad (11)$$

sendo:  $CL_j$  : carga local referente ao  $j$ -ésimo ponto (subestação, alimentador, transformador etc.) de interesse;  $CG$ : carga global (somatório de todas as cargas do sistema).

O previsor de carga global é treinado da mesma forma, contudo, os dados de carga deste módulo é dado pelo somatório das cargas locais, de acordo com a equação (12), fornecendo como saída a previsão de carga global (CG). Na fase de previsão os valores do FPCG previstos são multiplicados pelo valor da carga global obtendo-se, assim, a saída do previsor de carga local de cada subestação dada pela equação (13):

$$CG = \sum_{j=1}^N CL_j \quad (12)$$

$$CL_j^{(prevista)} = FPCG_j^{(prevista)}(h) \cdot CG^{(prevista)}(h) \quad (13)$$

Na figura 1 ilustra-se o sistema previsor de carga multimodal do tipo FPCG

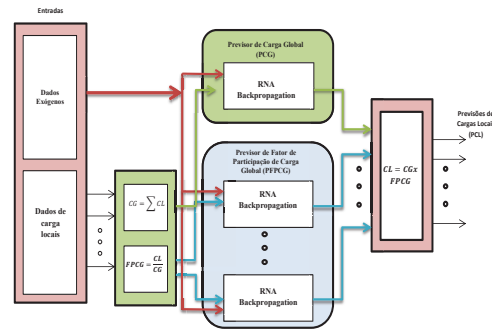


Figura 1: Sistema de previsão FPCG

Para avaliar a metodologia proposta, foi utilizado o erro percentual absoluto médio MAPE [8], erro máximo  $EM$  da previsão diária, ou seja, a realização de análise comparativa entre os valores reais da carga e os valores gerados pela RNA:

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left( \frac{L(h) - \hat{L}(h)}{L(h)} \right) \cdot 100 \quad (14)$$

$$EM = \max \left( \frac{L(h) - \hat{L}(h)}{L(h)} \right) \cdot 100 \quad (15)$$

sendo:  $L(h)$ : valor da carga real referente a hora  $h$ ;  $N$ : número total de horas.

### 3 Resultados

Os resultados apresentados (análise comparativa) foram consignados tomando-se duas propostas: (1) o Método Proposto (MP) neste artigo e (2) o método proposto na referência [1]. Assim, para validar a previsão de carga multimodal, as RNA foram treinadas com os dados históricos apresentados, os quais foram fornecidos por uma companhia do setor elétrico da Nova Zelândia (Electricity Commission da Nova Zelândia) [6]. Foram considerados os dados das cargas correspondentes a 15 dias históricos, compreendidos entre os dias 15 e 29 do mês de outubro do ano de 2007, num total de 360 valores de entrada, para prever o dia 30 de outubro de 2007. No trabalho realizado, como descrito na referência [1], foi obtida a previsão de carga para o mesmo período, porém foi utilizado a RNA BP com a função de ativação de base radial. Na referência [1], as subestações de Kopu, Waihou e Waikino são designadas: unidades 1, 2 e 3, respectivamente. A análise comparativa, considerando-se ambos os trabalhos, é mostrada na Tabela 1. Ressalta-se que foi selecionadas três subestações, porém, esta número pode ser ampliado em consonância com o interesse do usuário.

Na Figura 2, são ilustrados os comportamentos da curva da carga prevista com o FPCG e a curva de carga real das subestações de Kopu, Waihou e Waikino. Ressalta-se que o erro máximo não se constitui num dado importante, porém, serve para indicar a máxima discrepância observada durante o período considerado.

Tabela 1: Resultados Numéricos do treinamento utilizando o fator de participação.

Subestação	MAPE		Erro Máximo	
	MP	[1]	MP	[1]
Kopu	2,45	3,27	7,59	8,69
Waihou	1,62	4,35	5,68	9,10
Waikino	2,76	2,93	8,16	5,50

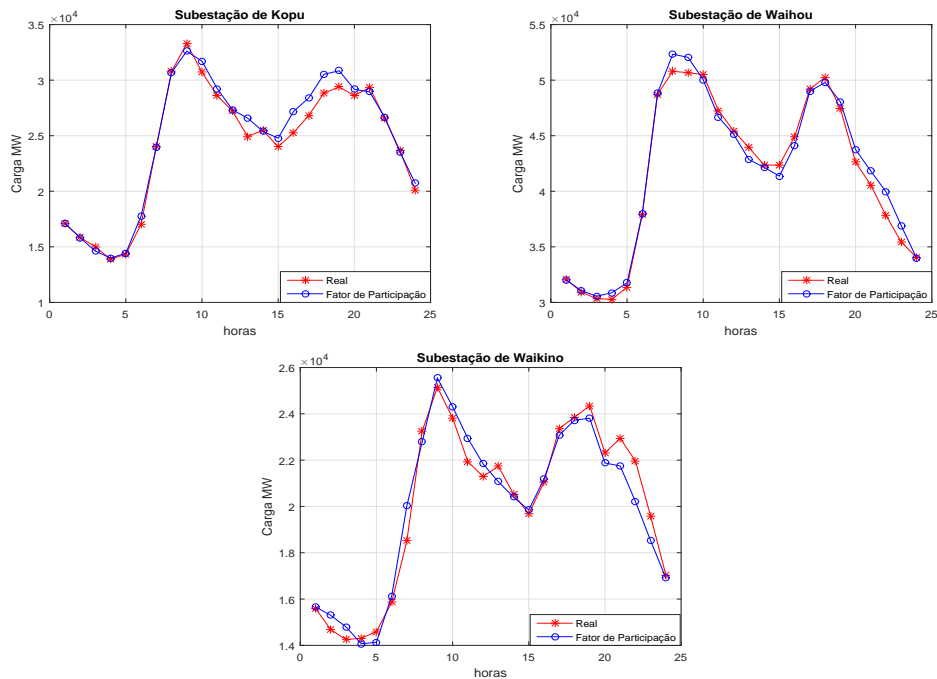


Figura 2: Curva de carga das subestações de Kopu, Waihou e Waikino.

## 4 Conclusões

A previsão foi realizada em curto prazo (24 horas à frente) baseado na teoria das RNA e o uso do conceito de FPCG, proposto em [1], para realizar a previsão de carga, modelo este que tornou o treinamento mais rápido e que há exigência de uma base de dados menor, se comparado com à literatura. O erro da previsão foi inferior a 5% (percentual máximo observado de 4,35 referente à subestação de Waihou), que é um erro compatível com as exigências normativas do setor elétrico.

## Referências

- [1] A. B. Altran, Sistema Inteligente para previsão de carga multinodal em sistema elétricos de potência, Tese de doutorado, Unesp, 2010.
- [2] A. J. Amorim, Desenvolvimento de uma rede neuro-*fuzzy* para a previsão da carga, Dissertação de Mestrado, Unesp, 2015.
- [3] P. Arabshahi; J.J. Choi; R.J. Marks II and T.P. Caudell " *Fuzzy* parameter adaptation in optimization: Some neural net training examples," *IEEE Computational Science & Engineering*, Vol. 3, No. 1, pp. 57-65, 1996.
- [4] S. Haykin, *Neural Networks: A comprehensive Foundation*. Upper Saddle River: Prentice- Hall, pages 768, 1994.
- [5] M. L. M. Lopes, Desenvolvimento de um sistema previsor de cargas elétricas via redes neurais, Dissertação de Mestrado, Unesp, 2000.
- [6] K. Nose-Filho, A. D. P. Lotufo and C. R. Minussi, Short-Term Multinodal Load Forecasting Using a Modified General Regression Neural Network. *IEEE Transation on Power Delivery*, volume 26, pages 2862-2869, 2011.
- [7] T. M O'Donovan, *Short term forecasting: an introduction to the Box-Jenkins approach*, New York: John Wiley & Sons, 256p, 1983.
- [8] D. Srinivasan, S. S. Tan, C. S. Chang e E. K. Chan, Practical Implementation of a Hibrid *Fuzzy* Neural Network for One-Day-Ahead Forecasting. *IEEE Proceedings Generation, Transmission and Distribution*, volume 145, no 6, pages 687-692.
- [9] N. Stamatis, D. Parthimos and T. M. Griffith, Forecasting Chaotic Cardiovascular Times Series with an Adaptive Slope Multilayer Perceptron Neural Network. *IEEE Transactions on Biomedical Engineering*, volume 46, No.12, pages 1441-1453, 1999.
- [10] S. A. Villalba and C. A. Bel. Hybrid demand model for load estimation and short term load forecasting in distribution electric systems," *IEEE Transactions on Power Delivery*, Vol. 15, No. 2, pp. 764-769, 2000.
- [11] P.J. Werbos. "Beyond regression: New tools for prediction and analysis in the behavioral sciences", PHD. Thesis - Harvard University, 1974.
- [12] B. Widrow, B. and M.A. Lehr "30 years of adaptive neural networks: Perceptron, madaline and backpropagation", *Proceedings of the IEEE*, Vol. 78, No 9, pp. 1415-1442, Sept. 1990.
- [13] Zadeh, L.A. *Fuzzy sets*. *Information and Control*, Maryland Heights, v. 8, n. 3, p. 338-353, 1965.