

# ESTUDO E APRENDIZADO DE REDES NEURAIS ARTIFICIAIS PARA APLICAÇÃO EM PREVISÃO DE CARGAS ELÉTRICAS. Kenji Nose Filho, Anna Diva P. Lotufo, Carlos R. Minussi, Mara Lúcia M. Lopes. Engenharia Elétrica – Departamento de Engenharia Elétrica – Faculdade de Engenharia – Campus de Ilha Solteira

Esta pesquisa de iniciação científica tem por objetivo a resolução do problema da previsão de cargas elétricas por RNA (Redes Neurais Artificiais). A previsão de carga constitui-se de um importante estudo para a realização dos cálculos relativos ao fluxo de potência, operação econômica, análise de segurança, controle, entre outras rotinas, as são essenciais para o planejamento e a operação de sistemas elétricos de potência.

As RNA foram projetadas para emular o comportamento do cérebro humano, ou seja, ter a capacidade de aprender e se adaptar, quando submetidas a estímulos (treinamento).

A rede neural usada nesta pesquisa corresponde a uma arquitetura não-recorrente com o treinamento via técnica retropropagação (*backpropagation*), usando o aplicativo MATLAB e a *toolbox Neural Networks*. O algoritmo retropropagação é uma técnica sistemática de adaptação de pesos baseada do método do gradiente descendente, como forma a minimizar a média da soma dos erros quadráticos.

Para a realização do sistema neural visando a resolução da previsão de cargas, foram desenvolvidas duas configurações diferentes designadas “Aplicação 1” e “Aplicação 2”. Para realizar as simulações foram utilizados dados reais fornecidos por uma empresa do setor elétrico brasileiro, referentes ao período de 4 de maio a 30 de junho de 1998.

A primeira configuração é uma configuração mais simples, que conta com 10 neurônios na camada de entrada, 24 neurônios na camada intermediária e 1 neurônio na camada de saída. Como vetores de entrada foram utilizados os dias da semana, em representação binária; a hora (hora  $h$ ) correspondente à carga desejada na saída (carga  $h$ ) e os valores de duas cargas das horas anteriores (carga  $h-1$  e carga  $h-2$ ) em decimal na escala 1:1000. Na segunda configuração foram empregados mais neurônios nas camadas de entrada e intermediária, totalizando 12 neurônios na camada de entrada, 30 neurônios na camada intermediária e 1 neurônio na camada de saída. Como vetores de entrada foram utilizados os dias da semana, em representação binária; a hora (hora  $h$ ) da carga correspondente a qual se desejam obter na saída (carga  $h$ ), representação binária; e os valores de quatro cargas das horas anteriores (carga  $h-1$ , carga  $h-2$ , carga  $h-3$ , carga  $h-4$ ) em decimal na escala 1:1000.

As funções de transferências das camadas de entrada, intermediária e de saída, em ambas as RNA, correspondem às funções sigmóide com variação entre  $-1$  e  $1$ , sigmóide com variação de  $0$  a  $1$  e linear de  $-\infty$  a  $+\infty$ , respectivamente.

Utilizou-se para treinar a rede a função *traingdx*, esta função treina a rede no modo retropropagação no método do gradiente descendente com momento e taxa de treinamento ajustável. A função *learnbd* ajusta os pesos e *bias* utilizando o método do gradiente descendente, e *mse* é a função de desempenho da rede que utiliza a média do erro quadrático. Tais funções são partes integrantes do aplicativo MATLAB.

Os parâmetros referentes à taxa de treinamento, erro máximo admissível e número máximo de iterações foram arbitrados como sendo 0,25, 0,0001 e 5000, respectivamente.

Na Figura 1, é ilustrada a previsão de carga (Aplicação 1) para o dia 30 de junho de 1998, considerando a rede neural treinada com os vetores de entrada compreendidos entre os dias 4 de maio de 1998 e 29 de junho de 1998. Na referida figura encontram-se registradas, para fins de comparação, as curvas prevista e real. Neste caso, a previsão apresentou um maior erro em torno das 5:00h (madrugada) da ordem de 13,54%. Este erro pode ser considerado excessivo, pois o valor esperado deveria estar abaixo de 10%, conforme é consenso na literatura técnica. Em vista disto, foram realizadas experiências com a arquitetura designada “Aplicação 2”, cuja análise comparativa encontra-se ilustrada na Figura 2. Agora, o maior erro, também, observado no horário das 5:00h, foi de 4,84%, se comparada à curva correspondente à carga real.

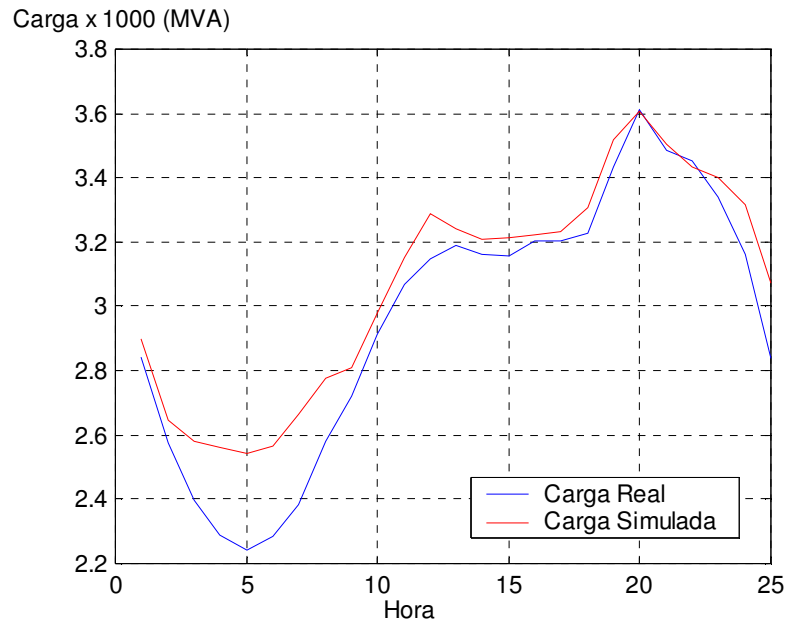


Figura 1 – Simulação gráfica da Aplicação 1.

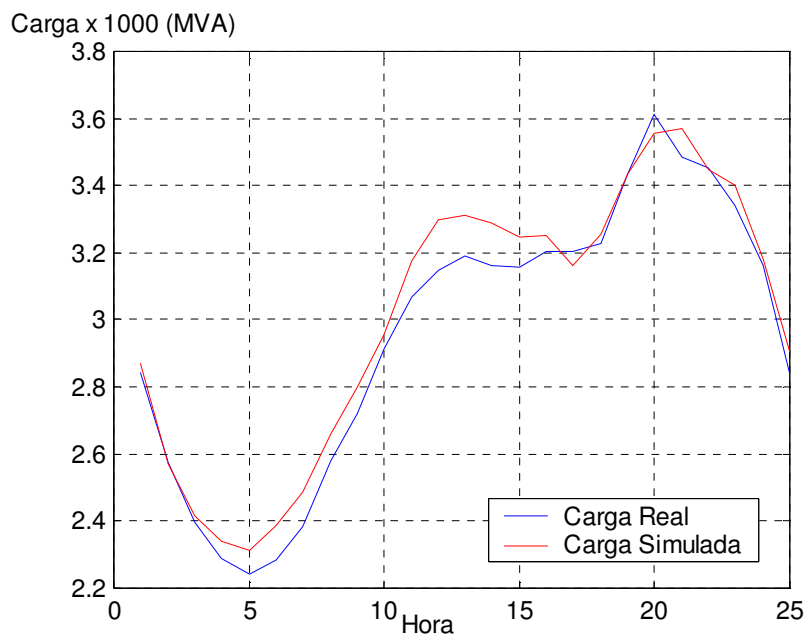


Figura 2 - Simulação gráfica da Aplicação 2.

Ressalta-se que, para se trabalhar com uma RNA faz-se necessário tomar alguns cuidados, que se não forem respeitados, os resultados obtidos podem se apresentar totalmente fora do esperado, ou a rede neural artificial pode vir a não convergir. Neste sentido, nesta pesquisa, os dados de entrada tiveram de ser pré-processados, antes de serem implementados na rede neural artificial. Os dias das semanas e as horas foram usados em códigos binários e os valores das cargas elétricas foram divididos por 1000, como forma de compatibilizar com as funções de ativação empregadas (funções sigmoidais).

O número de neurônios utilizados em cada camada deve estabelecer uma relação para que a convergência dos dados seja possível. Neste caso, utilizou-se o número de componentes de entrada na camada de entrada e o número de componentes na saída na camada de saída, no caso da aplicação 1 estes valores foram de 10 e 1 neurônios, respectivamente. No caso da aplicação 2 estes valores foram de 12 e 1 neurônios. O número de neurônios na camada intermediária foi obtido pelo método da

tentativa e erro, sendo que para a aplicação 1 e para a aplicação 2 os números que apresentaram melhor desempenho (menor tempo de treinamento) foram 24 e 30 neurônios, respectivamente.

Considerando-se as experiências realizadas pode-se concluir que o sistema neural simulado usando o aplicativo MATLAB apresentou um desempenho satisfatório, principalmente quando há os devidos cuidados no pré-processamento dos dados e o uso de um maior número de variáveis históricas em cada janela temporal considerada. Este detalhe pode ser observado nos resultados referentes à aplicação 2, cujo erro produzido foi inferior a 5% que é, certamente, um resultado igual ou melhor em comparação aos obtidos com o uso das principais propostas disponíveis na literatura especializada.

### **Referências bibliográficas**

- [1] GROSS, G. and GALIANA, F. D. "Short term load forecasting," Proceedings of the IEEE, Vol. 75, No. 12, pp. 1558-1573, 1987.
- [2] KARTALOPOULOS, S. V. "Understanding neural networks and fuzzy logic: Basic concepts and applications," IEEE Press, Piscataway, NJ, USA, 1996.
- [3] LOPES, M. L. M. "Desenvolvimento de um sistema previsor de cargas elétricas via redes neurais", Dissertação de Mestrado, Programa de Pós-graduação em Engenharia Elétrica - Faculdade de Engenharia de Ilha Solteira - UNESP, 2000.

**Bolsa:** FAPESP