



Grupo IX

GRUPO DE ESTUDO DE OPERAÇÃO DE SISTEMAS ELÉTRICOS (GOP)

UTILIZAÇÃO DE VARIÁVEIS METEOROLÓGICAS NA PREVISÃO DE CARGA ATRAVÉS DE REDES NEURAIS

Alexandre Pinhel Soares*
UERJ - Universidade do
Estado do Rio de Janeiro

André Pinhel Soares
UERJ - Universidade do
Estado do Rio de Janeiro

RESUMO :

O consumo de energia elétrica (carga) está intimamente relacionado às condições meteorológicas sendo reconhecido que métodos de previsão que se utilizem de variáveis como temperatura, umidade ou insolação conseguem bons desempenhos.

Este trabalho apresenta os resultados obtidos com a utilização da temperatura do ar e da pressão atmosférica na previsão de carga via Redes Neurais Artificiais (ANN). Os dados de carga foram fornecidos pela Light Serviços de Eletricidade S.A, os de temperatura pelo Departamento de Climatologia e Meteorologia da Universidade do Estado do Rio de Janeiro (UERJ) e os de pressão pelo Departamento de Meteorologia da Universidade Federal do Rio de Janeiro (UFRJ).

O uso da temperatura do ar em métodos de previsão de carga é bastante comum, porém o uso da pressão atmosférica não foi encontrado pelos autores na literatura.

PALAVRAS-CHAVE :

Previsão de carga - Redes Neurais – Meteorologia – Pressão atmosférica - Temperatura do ar

1 - INTRODUÇÃO :

A utilização de variáveis meteorológicas, especialmente a temperatura do ar, é prática comum

na previsão de carga. Diversos são os métodos empregados [1,2,3,4,5,6,7] inclusive a modelagem por Redes Neurais Artificiais (ANN) [8,9,10].

Uma ANN é uma estrutura computacional baseada em arquiteturas de processamento distribuído encontradas em seres vivos. É composta pela interligação de elementos processadores muito simples, chamados neurônios, e podem ser construídas em meios elétricos, óticos e híbridos ou simuladas em *software*.

Os tipos de redes existentes são caracterizadas pelo modelo do neurônio, pela topologia das interligações e pelo algoritmo de treinamento. Uma visão geral pode ser encontrada em [11] e [12]. Neste trabalho utilizou-se a *multilayered perceptron* (MLP).

Em uma MLP a saída é função da entrada, de forma que os dados utilizados devem ter alguma correlação. Neste trabalho a saída final é o valor, em megawatts (MW), da carga estimada para a próxima hora e as entradas são os valores dos passados imediatos da carga (MW), da temperatura do ar (graus centígrados) e da pressão atmosférica (milímetros de mercúrio).

A idéia da utilização da temperatura do ar baseia-se na estreita correlação que existe entre conforto térmico e carga (uso de ar-condicionado, geladeira, etc).

A idéia da utilização da pressão atmosférica baseia-se no princípio de que mudanças meteorológicas de maior amplitude (frentes frias, por exemplo) antes de alterarem a temperatura do ar (e, conseqüentemente, a carga), alteram a pressão.

2 - A REDE :

Uma MLP é composta por neurônios que possuem n entradas com pesos variáveis (sinapses), uma saída (axônio) e três funções internas (entrada, ativação e saída) que diferem conforme a posição dentro da rede (figuras 1 e 2).

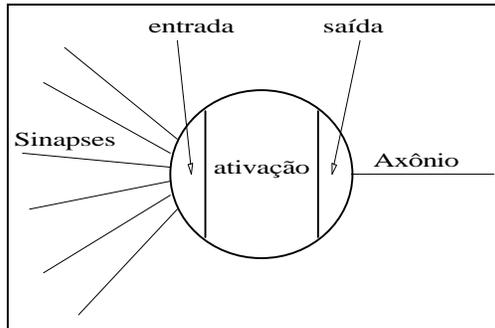


FIGURA 1 : NEURÔNIO DE UMA REDE MLP

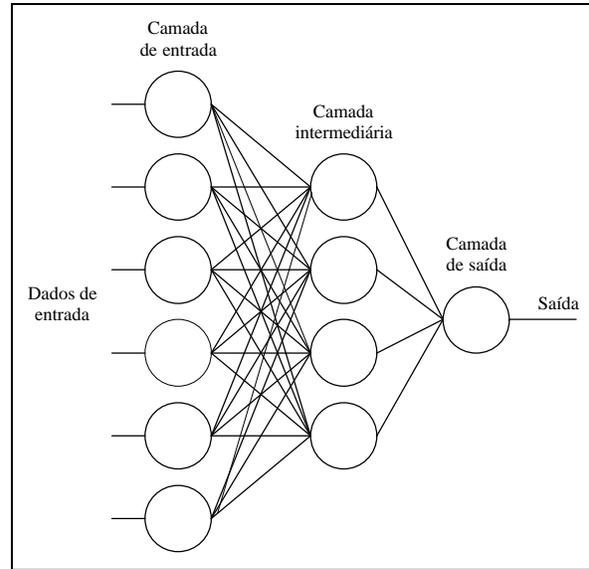


FIGURA 2 : REDE MLP

Tipicamente a função de entrada calcula a soma ponderada dos sinais aplicados nas sinapses e a função de ativação recebe essa soma e fornece o nível de atividade do neurônio para a função de saída que o aplica ao axônio. A retenção do conhecimento se dá pela variação dos pesos das sinapses no decorrer do treinamento.

O potencial da MLP é conhecido há bastante tempo, porém a sua popularização só veio a ocorrer em 1986, com o trabalho de Humelhart, Hinton e Williams [13], pois até então era desconhecida qualquer estratégia de treinamento. Esses autores desenvolveram a *generalized delta rule*, conhecida também como *backpropagation error correction algorithm*. Essa técnica aplica um padrão na entrada, compara a saída encontrada com a esperada e recalcula os pesos das sinapses a partir da retropropagação do erro.

3 - O EXPERIMENTO :

Foram definidas quatro redes neurais cujos desempenhos foram comparados visando concluir qual a contribuição do uso da temperatura do ar e da pressão atmosférica na previsão da carga. Os nomes das redes foram definidos em função das entradas de dados utilizadas, portanto na rede 'MW' só foi utilizado o passado da carga e nas outras redes utilizou-se o passado da carga em conjunto com a temperatura do ar (MWT), com a pressão atmosférica (MWP) e com a temperatura e a pressão (MWTP). A figura 3 exemplifica a aparência das curvas de carga, temperatura e pressão.

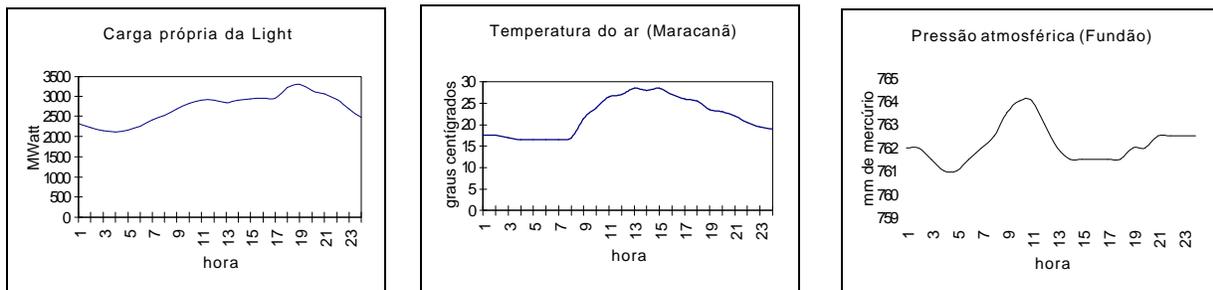


FIGURA 3 : EXEMPLOS DAS 3 VARIÁVEIS UTILIZADAS (DIA 7 DE JUNHO DE 1995)

Os dados utilizados tiveram procedências distintas, sendo necessária a confecção de uma base de dados integrada onde inseriu-se também as informações de feriado e dia da semana. Explorando esse grau de liberdade, direcionou-se o experimento para o estudo dos dias úteis (segunda a sexta-feira, excetuando os feriados), i.e., em nenhum momento foram feitas previsões para sábados, domingos e feriados e nem foram usadas amostras desses tipos de dias.

Os dados de pressão foram obtidos a partir dos gráficos do barógrafo da estação meteorológica da Ilha do Fundão e os de temperatura a partir dos gráficos do termógrafo da estação meteorológica do Maracanã. O processo de confecção das séries numéricas a partir dos gráficos é essencialmente manual podendo produzir erros. Devido a isso foram feitas consistências nas séries de temperatura e pressão. A série de temperatura possui lacunas devido à eventuais falhas no termógrafo. Essas lacunas são identificadas no treinamento e tais amostras são descartadas, reduzindo o tamanho efetivo do conjunto de treinamento.

O *software* utilizado foi escrito em Pascal e todo o experimento foi feito em um PII-333 adquirido para essa finalidade. As redes implementadas chegaram a ter 143 neurônios e, apesar de ter sido utilizado um compilador de 32 bits e o código ter sido otimizado para o PII e não fazer acesso a disco, os treinamentos chegaram a durar 10 horas (50000 iterações como critério de parada). O experimento durou cerca de três meses, excetuando-se o tempo gasto na obtenção e integração dos dados.

4 - RESULTADOS :

Observa-se, pela tabela 1 e pela figura 4, que a utilização da pressão ou da temperatura (redes MWT e MWP) melhoram sensivelmente as previsões, porém a utilização da pressão e da temperatura (rede MWTP) produz resultados muito superiores. Os 5 exemplos apresentados a seguir são bem representativos, pois as previsões foram feitas para meses, dias de semana e horários distintos.

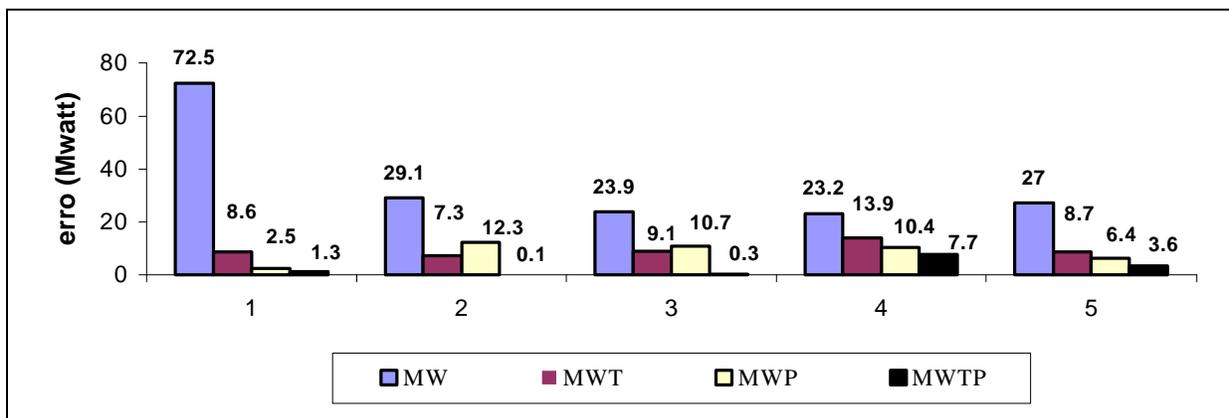
TABELA 1 : COMPARAÇÃO ENTRE OS RESULTADOS DAS QUATRO REDES NEURAIAS

Treinamento	MW			MWT			MWP			MWTP		
	E24	ET	na	E24	ET	na	E24	ET	na	E24	ET	na
04/01 a 06/02 5hs	72.5	106.1	430	8.6	39.6	422	2.5	19.2	430	1.3	11.7	422
06/02 a 07/03 10hs	29.1	64.6	370	7.3	16.7	337	12.3	32.4	370	0.1	0.2	337
07/03 a 05/04 14hs	23.9	44.6	421	9.1	6.3	259	10.7	24.2	421	0.3	0.5	259
05/04 a 11/05 19hs	23.2	38.3	474	13.9	22.7	382	10.4	33.4	474	7.7	31.8	382
11/05 a 08/06 23hs	27.0	33.9	406	8.7	14.3	377	6.4	12.6	406	3.6	6.3	377

E24 - erro médio (em MW) das previsões feitas para as 24 amostras subsequentes ao conjunto de treinamento

ET - erro médio (em MW) das previsões feitas para as amostras do conjunto de treinamento

na - número de amostras efetivamente utilizadas no treinamento (descartadas amostras com lacunas e amostras de sábados, domingos e feriados)



1 - Período de 6hs de 6 de fevereiro (segunda-feira) a 5hs de 7 de fevereiro

2 - Período de 11hs de 7 de março (terça-feira) a 10hs de 8 de março

3 - Período de 15hs de 5 de abril (quarta-feira) a 14hs de 6 de abril

4 - Período de 20hs de 11 de maio (quinta-feira) a 19hs de 12 de maio

5 - Período de 0hs de 9 de junho (sexta-feira) a 23hs de 9 de junho

FIGURA 4 : COMPARAÇÃO ENTRE OS ERROS MÉDIOS DE PREVISÃO DAS 24 AMOSTRAS SUBSEQUENTES AO CONJUNTO DE TREINAMENTO

Em função dos resultados apresentados anteriormente, assumiu-se que a rede MWTP é a que consegue os melhores desempenhos. Pela tabela 1 observa-se que, em alguns casos, o erro médio do conjunto de treinamento (ET) mostrou-se superior ao erro médio das 24 amostras subsequentes (E24), i.e., obteve-se melhor desempenho sobre amostras que não foram usadas no treinamento. Essa constatação sugeriu que o conjunto de treinamento talvez estivesse grande demais, possuindo amostras que estariam muito distantes no passado, contribuindo negativamente no aprendizado pois

teriam menos semelhança com o futuro, já que a carga tem características sazonais, variando significativamente no decorrer dos meses.

Foram então feitos testes com conjuntos de treinamento de tamanhos inferiores. Pelas tabela 2 e figura 5 pode-se concluir que conjuntos de treinamento com cerca de 20 dias de amostragem horária não só são suficientes como conseguem até melhores resultados. Conjuntos menores parecem não possuir quantidade suficiente de amostras para o treinamento.

TABELA 2A : A REDE MWTP COM PERÍODO DE TREINAMENTO DE CERCA DE 20 DIAS

Faixa de treinamento	MWTP		
	E24	ET	na
18/01 a 06/02 5hs	0.6	1.2	230
20/02 a 07/03 10hs	0.0	0.1	161
21/03 a 05/04 14hs	0.1	0.1	73
19/04 a 11/05 19hs	2.9	13.0	243
25/05 a 08/06 23hs	0.1	0.4	185

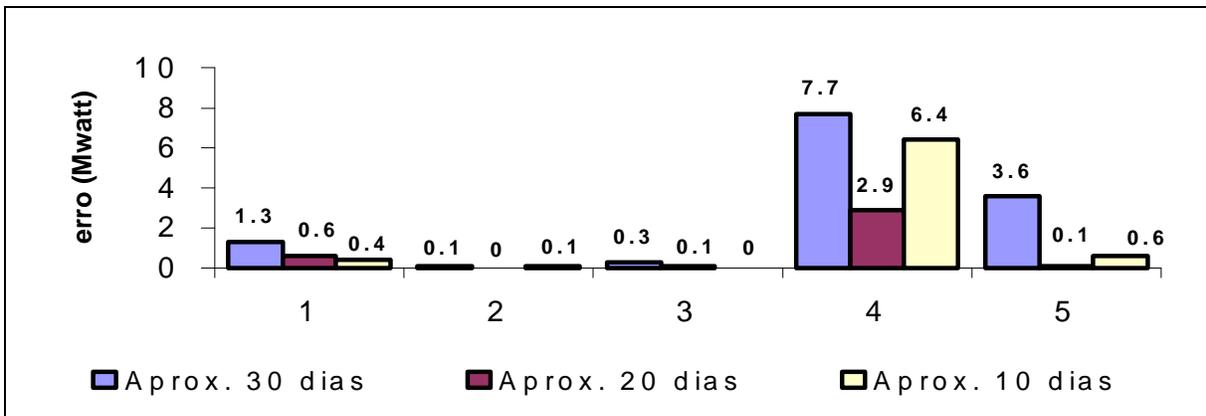
TABELA 2B : A REDE MWTP COM PERÍODO DE TREINAMENTO DE CERCA DE 10 DIAS

Faixa de treinamento	MWTP		
	E24	ET	na
25/01 a 06/02 5hs	0.4	0.3	158
27/02 a 07/03 10hs	0.1	0.1	65
28/03 a 05/04 14hs	0.0	0.0	17
26/04 a 11/05 19hs	6.4	2.2	196
01/06 a 08/06 23hs	0.6	1.4	118

E24 - erro médio (em MW) das previsões feitas para as 24 amostras subsequentes ao conjunto de treinamento

ET - erro médio (em MW) das previsões feitas para as amostras do conjunto de treinamento

na - número de amostras efetivamente utilizadas no treinamento (descartadas amostras com lacunas e amostras de sábados, domingos e feriados)



1 - Período de 6hs de 6 de fevereiro (segunda-feira) a 5hs de 7 de fevereiro

2 - Período de 11hs de 7 de março (terça-feira) a 10hs de 8 de março

3 - Período de 15hs de 5 de abril (quarta-feira) a 14hs de 6 de abril

4 - Período de 20hs de 11 de maio (quinta-feira) a 19hs de 12 de maio

5 - Período de 0hs de 9 de junho (sexta-feira) a 23hs de 9 de junho

FIGURA 5 : COMPARAÇÃO ENTRE OS ERROS MÉDIOS DE PREVISÃO DAS 24 AMOSTRAS SUBSEQUENTES A CONJUNTOS DE TREINAMENTO COM TAMANHOS DIFERENTES UTILIZANDO A REDE MWTP

5 - CONCLUSÕES :

O uso da pressão atmosférica aumentou sensivelmente a qualidade das previsões, especialmente quando em conjunto com a temperatura. Faixas de treinamento da

ordem de vinte dias mostraram-se suficientes, o que implica em um baixo tempo de processamento.

A consistência das séries foi de particular importância para a validade do experimento pois sequências com

erro alteraram significativamente os resultados. O erro mais comum foi a troca de Algarismos na amostra (por exemplo 765 ao invés de 756).

A pressão atmosférica é uma variável representativa para grandes áreas, portanto um só ponto de aquisição pode ser suficiente para um sistema de previsão de carga, o que é uma vantagem em termos de custos. Já a temperatura, devido a influências do relevo e da ocupação humana, pode não ser muito representativa, sendo talvez necessária a utilização de mais de um ponto de aquisição. No caso desse trabalho a estação meteorológica utilizada (Maracanã) é considerada, pelo Instituto Nacional de Meteorologia (INMET), representativa para a região metropolitana do Rio de Janeiro, que é responsável por parte significativa da carga própria da Light. Testes com mais de uma série de temperatura estão sendo avaliados.

Os resultados apresentados correspondem a previsões feitas para a hora seguinte. Do ponto de vista operacional praticamente não há interesse nesse tipo de informação, porém usando o resultado da previsão da hora n e as estimativas da temperatura e da pressão como dados de entrada para se obter a previsão da hora $n+1$ (realimentação), pode-se conseguir um produto de grande aplicabilidade, desde que o erro propagado seja aceitável.

A estimativa da temperatura já está disponível [14] e a estimativa da pressão pode ser obtida por meios similares, portanto, como continuidade do trabalho, está em desenvolvimento um sistema que tem por objetivo fornecer a previsão da carga para as próximas 24 horas.

6 - REFERÊNCIAS :

[1] M. T. Hagan, S. M. Behr, "The Time Series Approach to Short Term Load Forecasting", IEEE Transactions on Power Systems, vol. PWRS-2, no. 3, Aug 1987.

[2] K. Ho, Y. Hsu, C. Chen, T. Lee, C. Liang, T. Lai, K. Chen, "Short Term Load Forecasting of Taiwan System Using a Knowledge-Based Expert System", IEEE Transactions on Power Systems, vol. 5, no. 4, Nov 1990.

[3] G. L. Torres, J. Haddad, L. E. Borges, D. Mukhedkar, "Um Sistema Especialista Difuso para a Previsão da Carga Elétrica a Curto Termo", XI SNPTEE, Grupo X, RJ/GOP/15, 1991.

[4] D. B. Belzer, M. A. Kellogg, "Incorporating Sources of Uncertainty in Forecasting Peak Power Loads – A Monte Carlo Analysis Using Extreme Value Distribution", IEEE Transactions on Power Systems, vol. 8, no. 2, May 1993.

[5] J. Y. Fan, J. D. McDonald, "A Real-Time Implementation of Short-Term Load Forecasting for Distribution Power Systems", IEEE Transactions on Power Systems, vol. 9, no. 2, May 1994.

[6] T. Haida, S. Muto, "Regression Based Peak Load Forecasting Using a Transformation Technique", IEEE Transactions on Power Systems, vol. 9, no. 4, Nov 1994.

[7] O. Hyde, P. F. Hodnett, "An Adaptable Automated Procedure for Short-Term Electricity Load Forecasting", IEEE Transactions on Power Systems, vol. 12, no. 1, Feb 1997.

[8] D. C. Park, M. A. El-Sharkawi, R. J. Marks II, L. E. Atlas, M. J. Damborg, "Electric Load Forecasting Using An Artificial Neural Network", IEEE Transactions on Power Systems, vol. 6, no. 2, pp. 442-449, May 1991.

[9] T. M. Peng, N. F. Hubele, G. G. Karady, "Advancement in the Application of Neural Networks for Short-Term Load Forecasting", IEEE Transactions on Power Systems, vol. 7, no. 1, pp. 250-257, Feb. 1992.

[10] C. N. Lu, H. T. Wu, S. Vemuri, "Neural Network Based Short Term Load Forecasting", IEEE Transactions on Power Systems, vol. 8, no. 1, Feb. 1993.

[11] R. P. Lippman, "An Introduction to Computing with Neural Nets", IEEE ASSP Magazine, pp. 4-22, Abril 1989.

[12] Z. L. Kovács, "Redes Neurais Artificiais - Fundamentos e Aplicações", Edição Acadêmica, Brasil, 1996.

[13] D. Rumelhart, G. Hinton, R. Williams, "Learning Internal Representations by Error Propagation", in Parallel Distributed Processing Explorations in Microstructures of Cognition, vol. 1 : Foundations, pp. 318-362, MIT Press, 1986.

[14] A. Pinhel Soares, A. P. Soares, "Previsão de temperatura através de redes neurais artificiais", X Congresso Brasileiro de Meteorologia, Brasília, 1998.