

# 1º Congresso Brasileiro de Redes Neurais

Escola Federal de Engenharia de Itajubá  
Itajubá, 24 a 27 de outubro de 1994

## UM SISTEMA HÍBRIDO PARA A PREVISÃO DE CARGA A CURTO-PRAZO

Germano Lambert Torres<sup>1</sup>  
Alexandre Pinto Alves da Silva<sup>1</sup>  
Jamil Haddad<sup>1</sup>  
Luiz Octávio Mattos dos Reis<sup>2</sup>

1 - ESCOLA FEDERAL DE ENGENHARIA DE  
ITAJUBÁ  
2 - UNIVERSIDADE DE TAUBATÉ

**Abstract** - Este artigo apresenta um método alternativo para a previsão da carga elétrica por barramento ou por área de um sistema elétrico de potência. Este método é composto por um sistema híbrido que comporta uma rede neural treinada para este tipo de atividade e um sistema especialista difuso para um melhor ajuste da previsão. O artigo apresenta uma revisão dos métodos clássicos de previsão e exemplos do método proposto com dados reais de um sistema elétrico.

**Keywords** - Previsão de carga, operação de sistemas elétricos, redes neurais, sistemas especialistas difusos.

### I. INTRODUÇÃO

Durante o planejamento de um sistema elétrico é necessário prever o crescimento da carga para se poder construir um sistema de geração-transmissão que seja capaz de fornecer toda a demanda requerida. A grande dificuldade neste tipo de previsão é o tempo envolvido pois deve ser realizado em planos decenais ou quinquenais, podendo ser a

previsão alterada por diversos fatores, principalmente, os econômicos-financeiros, sociais e ecológicos.

Durante a operação dos sistemas elétricos de potência deve-se harmonizar a geração com o consumo de energia elétrica, ou seja, deve-se somente gerar o que está sendo efetivamente consumido, pois um desbalanço nesta equação poderia causar problemas de elevação ou queda de tensão no sistema. Com isto, o operador do sistema deverá ser capaz de saber a carga que será consumida antecipadamente para acionar o sistema de geração. Atualmente, os operadores dispõem de alguns recursos empíricos para realizar tal previsão.

Todavia, com o aumento e a diversificação da carga e com a aposentadoria de vários operadores experientes, está cada vez mais difícil de realizar tal previsão com uma margem pequena de erro.

Existem dois diferentes objetivos para o estudo da previsão da carga elétrica são eles: a operação econômica das usinas de geração de energia e uma solução tecno-econômica dos sistemas de transmissão e distribuição. O primeiro objetivo visa melhorar o desempenho global do sistema sem levar em consideração cada barra de carga. O segundo objetivo trabalha com as características de um dado barramento ou área do sistema.

Pode-se classificar as diversas previsões de carga baseadas no fator tempo. Esta classificação é feita da seguinte maneira:

- curto-prazo - dos próximos quinze minutos até uma semana a frente,
- médio-prazo - de uma semana a um ano a frente.
- longo-prazo - após um ano.

Os tempos discriminados acima são orientativos podendo segundo a conveniência ou o tipo de

departamentalização da concessionária por ser alterado.

Os critérios que são importantes para a previsão em cada um dos intervalos acima variam. Por exemplo, para uma previsão a curto-prazo podem ser importantes os seguintes fatores: temperatura, hora do dia, estação do ano, humidade, entre outros. Enquanto, para uma previsão de longo prazo aspectos econômicos e políticos devem ser levados em consideração.

Também os objetivos para cada tipo de previsão são diferentes. Em uma previsão de curto-prazo deseja-se compatibilizar a geração com a carga, enquanto na de médio-prazo, o objetivo pode ser realizar um programa de manutenção do sistema ou de otimizar as fontes de energia primária utilizadas.

Este artigo apresenta inicialmente uma revisão dos métodos clássicos de previsão da carga a curto-prazo. Em seguida, o sistema proposto é descrito, sendo feita uma análise de cada um de seus componentes. Depois, é apresentado a interação deste sistema em um centro de operação e seu relacionamento com os operadores. Finalmente, alguns exemplos utilizando dados reais são apresentados e o desempenho do sistema é analisado.

## II. REVISÃO DOS MÉTODOS DE PREVISÃO DA CARGA ELÉTRICA A CURTO-PRAZO

A adaptação da geração a carga deve levar em consideração as características de cada uma e, também, dos caminhos que podem fazer esta ligação, ou seja, o sistema de transmissão.

As curvas de carga podem ser representadas por valores horários, diários ou por ciclos semanais. Os valores destas curvas podem ser afetadas por fatores climáticos ou sazonais ou ainda por fatores cíclicos semanais, mensais ou anuais.

Por outro lado, as características da geração podem ser afetadas por elementos previsíveis, tais como períodos de seca ou manutenção preventiva, e por elementos aleatórios, como uma saída forçada da geração.

Os caminhos entre a geração e a carga podem ser achados através de processos lógicos ou buscas

heurísticas. Esta seção apresenta a formulação clássica do problema e as técnicas de solução.

### II.1 Formulação do Problema

A previsão de carga pode ser dividida em dois tipos: modelagem da carga máxima e modelagem da curva de carga [1]. Enquanto o primeiro expressa somente o valor máximo diário, semanal ou mensal, o segundo modela todo o comportamento da curva. Neste artigo apresenta-se um procedimento alternativo para o segunda tipo de modelagem.

Na modelagem da curva de carga, o valor previsto  $F(t)$  é obtido através da operação entre a curva padrão de carga,  $B(t)$ , e de uma curva de desvio,  $W(t)$ . Esta operação pode ser aditiva ou multiplicativa segundo a obtenção da curva de desvio.

$$F(t) = B(t) + W(t) \quad (1)$$

$$F(t) = B(t) \bullet W(t) \quad (2)$$

*a. Curva Padrão da Carga* - Este valor deve caracterizar a carga de base da barra, área ou sistema a ser previsto. É calculada utilizando dados históricos, que são agrupados segundo critérios hora-do-dia, dia-da-semana e tempo-no-ano (semanalmente, mensalmente ou sazonalmente). Esta divisão permite separar cargas que tenham o mesmo comportamento, por exemplo, separar sábados e domingos como dias da semana, se for o caso.

A carga padrão pode ser dividida em duas partes. A primeira utilizando a média da carga dos dias comuns do período. No caso estudado, por exemplo, os feriados tinham comportamento semelhante aos sábados e domingos e eram, portanto, reunidos com estes dias. A segunda parte expressa características particulares de cada dia da semana individualmente. Isto pode ser feito através de uma média móvel simples ou ponderada. As equações (3) a (5) apresentam o cálculo da carga padrão.

$$B(t) = B_1(t) + B_2(t) \quad (3)$$

$$B_1(t) = \frac{1}{m \cdot n} \sum_{w=1}^m \sum_{d=1}^n L(t, d, w) \quad (4)$$

$$B_2(t) = \frac{1}{n} \sum_{w=1}^m L(t, d, w) \cdot B_1(t) \quad (5)$$

Onde  $L(t, d, w)$  representa a carga em um tempo  $t$  para o dia-da-semana  $d$  da semana  $w$ . O valor de  $n$  pode mudar de uma semana para outra e representa a homogeneidade dos dias da semana. O valor de  $m$  representa o número de semanas do período que está sendo modelado.

Outros fatores podem ser somados a equação (3) dependendo da correlação existente entre os dados utilizados. Por exemplo, em [2], propõe-se a inclusão de uma parcela de polinômios de segunda ordem e componentes dependentes da temperatura.

**b. Curva de Desvio da Carga** - Este valor é utilizado para representar as variações do desempenho recente da carga. Este valor contém informações sobre as últimas horas ou até últimos dias. Alguns métodos utilizados para calcular este tipo de carga são a autoregressão ou o alisamento exponencial.

## II.2 Revisão dos Trabalhos

Gross e Galiana, em [3], dividiram a previsão da curva de carga em horária e baseada em modelos dinâmicos. No primeiro, a curva de carga é obtida baseada nos dias da semana e nas condições climáticas, bastando ao operador selecionar qual a curva que mais se adapta ao dia em questão. No segundo tipo, a previsão da carga não é somente função da hora do dia mas também das informações exógenas ao sistema.

Lambert Torres *et al.*, em [4], propuseram um sistema especialista para calcular a carga prevista. Neste encaminhamento, técnicas de matemática formal são agregadas à experiência do operador, resultando em regras representadas por proposições condicionais difusas.

Monghram e Rahman, em [5], avaliaram cinco diferentes métodos de previsão: regressão multilinear, séries estocásticas (média móvel integrada autoregressiva), alisamento exponencial, filtros de Kalman e sistemas especialistas. Cada método foi aplicado a mesma base de dados, permitindo uma comparação direta dos resultados.

## III. APRESENTAÇÃO DO MÉTODO PROPOSTO

Como foi visto na seção anterior, existem várias maneiras para se prever a carga elétrica, todavia, em todos eles, é desejável a montagem de uma base de dados que reflita o histórico da carga, bem como aspectos climáticos relevantes. Esta seção apresenta inicialmente a estrutura da base de dados construída, para, em seguida, mostrar o sistema proposto.

### III.1 Estrutura da Base de Dados

A base de dados que contém informações históricas sobre o comportamento da carga e os parâmetros meteorológicos foi montado. Dados, tais como: temperatura a bulbo seco e molhado, umidade relativa e direção e intensidade do vento, foram alguns dos elementos que compunham esta base. Além desses, informações especiais como inclinação do sol e nebulosidade também podem afetar a carga, principalmente, a residencial.

A estrutura da base de dados foi a seguinte, onde  $v$  representa o valor da grandeza,  $h$ , a hora,  $d$ , o dia,  $w$ , a semana do ano,  $y$ , o ano, e  $s$  a estação:

Potência Ativa :	$P(v, h, d, w, y, s)$
Temperatura a bulbo seco:	$\Theta(v, h, d, w, y, s)$
Temperatura a bulbo molhado:	$M(v, h, d, w, y, s)$
Umidade Relativa :	$H(v, h, d, w, y, s)$
Direção do vento:	$WD(v, h, d, w, y, s)$
Velocidade do vento:	$WS(v, h, d, w, y, s)$

Os valores de potência real, valores de temperatura, umidade relativa e velocidade do vento são armazenados em [MW], [°C], [%] e [km/h], respectivamente. Para os valores de direção do vento, emprega-se a convenção a seguir: Norte é 1, e cada 22,5° no sentido horário é 1 mais. Para dia calmo usa-se 0. Assim, por exemplo, a direção WSW é 12 e NE é 3.

Utiliza-se a notação 24 horas para valores horários. Os valores de dia são numerados de 1 para segunda-feira a 7 para Domingo. Os feriados recebem o número 6 (Sábado). Os valores de semana são numerados por estação e o mais recente recebe o número 1. Este banco de dados é construído para manipular usando os últimos três anos e o ano atual.

Os valores de ano são de 1 para o ano atual a 4 para três anos depois. Os valores de estação são os seguintes: inverno - 1, primavera - 2, verão - 3, e outono - 4.

Para até dois valores em falta (v) dos mesmos dados, eles são calculados usando-se média simples entre o valor anterior e o próximo valor. Quando há mais de dois valores faltando, os dados são esquecidos.

Dias especiais (como tempestade de neve) são armazenados no banco de dados com um "flag". Estes valores não são usados para os cálculos de corrente, exceto quando esta condição de tempo é prevista.

### III.2 Descrição do Método

O método proposto faz a previsão de carga de curto-prazo utilizando um modelo híbrido com técnicas de redes neurais e sistemas especialistas. Inicialmente, a rede tem o objetivo de realizar a melhor previsão possível enquanto o sistema especialista vai adequar este valor previsto a fatos ou características especiais da carga. A figura 1 apresenta o sistema híbrido proposto.




Figura 1 - Sistema Híbrido Proposto

A estrutura usada é um modelo de camada com três camadas (camada "input", camada "hidden" e camada "output"). A camada "input" é composta de um número de neurônios igual ao número de dados de informação sobre a carga e seus parâmetros de tempo. A temperatura de bulbo seco, a temperatura de bulbo úmido, a umidade relativa, a direção do vento, a velocidade do vento, são os parâmetros de tempo mais comuns. Para cargas especiais, outros fatores (como inclinação do sol, nebulosidade) também podem exercer influência sobre a carga. O número de insumos depende do tipo de barramento, tipo de previsão de carga (uma hora a frente, duas horas a frente) e a hora do dia. A camada "output" é composta de um ou mais neurônios. Estes neurônios dão os valores de previsão de

carga. Através de uma regra empírica, o número de neurônios da camada "hidden" é uma média entre as camadas "input" e "output".

No método proposto, os pesos são calculados por um processo de aprendizado usando-se a retro-propagação do erro. O processo de aprendizado é feito usando-se dados medidos de barramento. Um conjunto inicial de dados da "input" é apresentado ao sistema neural que ajusta os valores de peso para um erro mínimo. A seguir, é apresentado um novo conjunto de dados iniciais e os valores de peso são ajustados consoantemente. O processo acaba quando a diferença entre "output" alvo e "output" encontrado para todos os conjuntos "input" está próxima de zero.

O sistema especialista visa ajudar na previsão da carga em duas situações comportamento não convencional da carga devido a fatores endógenos e exógenos. Os fatores endógenos são quando a situações pouco comum, normalmente, das condições meteorológicas, como por exemplo, tempestades de neve ou valores de temperatura e/ou humidade atípicos.

Os fatores exógenos refletem hábitos e comportamentos dos consumidores face a variadas situações, como por exemplo a rotina diária e a inércia térmica.

A carga de rotina diária pode ser descrita como atitudes usuais para uma parte específica do dia. Por exemplo, se houver um ponto de carga a 9:00 am e a carga as 8:00 am for maior do que a carga padrão para as mesmas condições de tempo, então parte do ponto de carga já foi consumida. Da mesma forma, se a carga as 8:00 am for menor que a carga padrão então, possivelmente o ponto de carga será aumentado. Esta forma de carga residual é aplicável em previsão de carga para até 3 horas a frente da previsão

A inércia térmica deverá ter dificuldade na mudança de uma temperatura de melhor para pior. Por exemplo, se a temperatura média no inverno para o último dia era  $-5^{\circ}\text{C}$ , e hoje é de  $-20^{\circ}\text{C}$ , a carga aumentará devido a diferença de temperatura mais uma certa inércia térmica. Se pelo próximo dia, a temperatura permanece em  $-20^{\circ}\text{C}$ , este componente inercial diminuirá ou transformará-se em nada. No Canadá, por exemplo, este fator é muito importante devido a faixas de temperatura excessivas. Esta forma

de carga residual é principalmente aplicável para previsão de carga 24 horas a frente.

#### IV. EXEMPLO ILUSTRATIVO

Este exemplo utiliza dados da Hydro-Quebec Power System, Canadá. Os dados numéricos vão de Abril/1984 a Julho/1988 e contêm informações relacionadas aos fluxos de potência real nas linhas 1288 e 1289, bem como condições de tempo tais como temperatura de bulbo seco, temperatura de bulbo úmido, humidade relativa, velocidade e direção do vento. Estes parâmetros foram medidos por hora. O desempenho mostrado neste item é função da adição destas duas linhas porque elas têm funcionado em paralelo. A estação usada neste exemplo foi o inverno, e o objetivo era computar a carga prevista em 20 de Janeiro de 1988, às 10 e 11 horas.

Para isto, foi usada a estrutura proposta no item anterior. Esta estrutura permitiu treinar uma rede neural para muitos "inputs". Os "inputs" e padrões de treinamento devem ter valores numéricos entre 0 e 1, logo pode-se fazer uma normalização destes conjuntos usando-se valores mínimos e máximos. O Apêndice apresenta algumas redes neurais treinadas para diferentes conjuntos de "input". São apresentados os "inputs" usados, os pesos e a ativação interna para cada neurônio. Por exemplo, no exemplo 1 (tabela 1) os "inputs" são:

P(9) - potência real as 9 horas

Θ(9) - temperatura de bulbo seco as 9 horas

H(9) - umidade relativa as 9 horas

Θ(10) - temperatura de bulbo seco as 10 horas

H(10) - umidade relativa as 10 horas

O número de neurônios na "hidden" foi o mesmo do "input" usado. Após o treinamento das redes neurais podemos encontrar os valores de previsão de carga usando os valores de 20 de janeiro como dados de "input". Os valores alvo são 165[MW] e 170[MW] as 10 e 11 horas, respectivamente. A tabela abaixo apresenta estes valores para cada exemplo.

#### V. CONCLUSÃO

Foi desenvolvida uma abordagem alternativa para computação do valor de previsão de carga usando-se técnicas de rede neural. Esta abordagem utiliza a técnica da retropropagação do erro para fazer

o aprendizado da rede. A carga prevista obtida é tratada por um sistema especialista e o resultado é superior aos métodos correntes em sistemas de potência. Outra vantagem deste sistema é sua velocidade em encontrar o valor previsto.

Tabela - Resultado de Diversas Redes

Exemplc	10 horas	Erro (%)	11 horas	Erro (%)
1	165,6	0,36	-	-
2	169,1	2,48	-	-
3	158,8	-3,76	-	-
4	164,3	-0,42	-	-
5	165,1	0,09	166,5	-2,06
6	162,4	-1,57	167,0	-1,75

#### VI. AGRADECIMENTOS

Os autores agradecem o Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte financeiro no desenvolvimento deste trabalho.

#### VII. REFERÊNCIAS

- [1] G. Lambert-Torres, B. Valiquette & D. Mukhedkar - "Bus Load Forecasting using Fuzzy Techniques", CEA Engineering and Operating Transactions, Vol. 29, Part IV, 1990.
- [2] M.S. Abu-Hussien *et al.* - "An Accurate Model for Short-term Load Forecasting", IEEE Trans. on Power Apparatus System, Vol. PAS-100, No.9, 1981, pp.4158-4165.
- [3] G. Gross & F.D. Galiana - "Short-term Load Forecasting", Proceedings of IEEE, Vol. 75, No. 12, 1987, pp. 1558-1573.
- [4] G. Lambert-Torres, B. Valiquette & D. Mukhedkar - "Short-term Feeder Load Forecasting: An Expert System using Fuzzy Logic", International Symposium on Power Systems and Power Plant Control. IFAC. Korea, Aug. 22-25, 1989, pp. 317-322.
- [5] I. Moghran & S. Rahman - "Analysis and Evaluation of Five Short-Term Load Forecasting Techniques", IEEE Winter Meet., 89WM171-0 PWRs, 1989.

APÊNDICE

Exemplo 4

Exemplo 1

Inputs: P(9),  $\theta(9)$ , H(9),  $\theta(10)$ , H(10)  
Output: P(10)

	Weight					Threshold
h1	-5.978927	-1.653212	-2.548971	0.332980	-0.147354	2.936591
h2	-0.114415	-0.654037	0.335414	-0.768783	-0.110014	0.067189
h3	-1.005803	0.576769	1.103390	1.669233	0.716206	0.981162
h4	-1.784045	-1.827001	-1.579652	-2.149607	-1.492007	-0.693183
h5	-3.573369	1.045426	1.434333	0.637234	-0.653510	-1.586497
o1	-6.679025	-0.988277	-1.749346	3.127510	3.903967	-0.607988

Inputs: P(9),  $\theta(9)$ ,  $\theta(10)$   
Output: P(10)

	Weight			Threshold
h1	-6.120185	-1.318901	-0.906765	1.556140
h2	-1.370013	3.436532	3.497077	1.550174
h3	8.038928	0.770676	1.238047	-1.853936
o1	-5.505402	-5.062915	6.317791	-0.159464

Exemplo 5

Inputs: P(9),  $\theta(9)$ , H(9),  $\theta(10)$ , H(10),  $\theta(11)$ , H(11)  
Output: P(10), P(11)

	Weight					Threshold
h1	-2.850067	0.064379	-1.867121	0.949502	-3.003542	1.440434
	1.033283	-0.010479				
h2	-0.290933	-0.813180	-0.616699	-0.552074	0.201466	0.393604
	-0.221277	1.467901				
h3	1.286221	-1.622224	-0.696168	-0.988542	-0.837983	-0.534564
	-1.603588	-1.028042				
h4	1.120457	-0.044474	1.053302	0.508672	1.160000	-0.597308
	-0.451046	-0.410352				
h5	0.700442	-0.409511	0.161902	-1.100542	-0.017419	-0.179351
	-0.446406	0.291033				
h6	3.139088	0.800937	1.169884	0.748396	2.949975	-1.470714
	-1.142437	-2.465890				
h7	-1.853428	1.738360	0.830380	1.488542	1.120508	0.604597
	2.205424	0.560077				
o1	-3.034061	-1.803710	2.203408	1.419467	-0.528269	-0.069237
	4.697513	-3.548041				
o2	-3.836864	0.420621	1.148244	1.296347	1.080802	0.003898
	1.605404	-2.559558				

Exemplo 2

Inputs: P(9),  $\theta(9)$ , M(9), H(9),  $\theta(10)$ , M(10), H(10)  
Output: P(10)

	Weight					Threshold
h1	0.876312	-1.063275	-1.686141	-0.336451	-1.038807	-0.211819
	-1.096977	-0.853785				
h2	1.220775	0.336993	-0.971611	0.618897	0.767455	0.340267
	-0.528810	1.007709				
h3	0.820547	-0.835026	-0.853673	-0.435869	-1.129255	-0.436630
	-0.889814	-0.885352				
h4	-0.942197	-1.024489	1.156638	-0.298165	-0.396664	-0.143552
	0.088166	-0.452388				
h5	-1.076023	-0.372056	0.558461	-0.753959	-0.770369	-0.149251
	0.352035	-0.121903				
h6	1.062982	-0.952319	-1.567257	-0.842092	-0.576939	-0.382589
	-1.469840	-0.477015				
h7	5.240025	-1.401142	2.660011	-2.580875	-0.204704	0.843365
	1.741040	-2.337472				
o1	2.051456	1.705301	1.450081	-1.747807	-1.422895	-0.267822
	2.053566	6.348610				

Exemplo 6

Inputs: P(8),  $\theta(8)$ , H(8), P(9),  $\theta(9)$ , H(9),  $\theta(10)$ , H(10),  $\theta(11)$ , H(11)  
Output: P(10), P(11)

	Weight				Threshold
h1	-1.792827	0.831928	1.794066	-1.088477	-0.405940
	-0.754631	-0.586769	-1.530238	0.339374	-0.065960
h2	-0.934255	-0.026349	1.135989	-0.421337	0.297041
	-0.083328	-0.635903	-1.086967	-0.193668	0.486377
h3	0.177775	0.009621	0.112965	-0.052116	-0.941504
	0.224031	-0.925864	0.843280	-0.585827	1.758739
h4	0.695570	-0.136292	-1.092503	0.405205	-0.627116
	0.523179	-0.429530	1.270333	0.213709	0.319345
h5	-0.729748	-0.420629	0.937431	-0.126993	-0.572058
	-0.280580	-0.433243	-0.053117	0.341390	0.771380
h6	0.303579	-0.031947	-0.430923	0.471736	0.422501
	0.204312	-0.269793	-0.038239	-0.104715	0.113485
h7	-1.474764	0.527824	1.160007	-1.356912	-0.035175
	0.107257	-0.020517	-1.475674	0.310711	-0.561924
h8	1.101532	-0.664641	-1.535768	1.776018	0.379529
	0.930027	0.247574	1.315829	-0.062923	0.067539
h9	1.038968	-1.428416	-0.923639	0.619814	-0.794065
	-1.171629	-0.251820	-0.579720	-0.980323	-0.219754
h10	-0.093055	-1.002639	-0.747140	0.626757	-0.626616
	-0.097610	-0.240395	-0.122497	-0.201901	-0.509798
o1	-3.020203	-1.786724	-0.991701	0.808280	-1.532955
	0.344811	-2.173898	2.457000	1.927562	0.410490
o2	-2.123776	-0.887667	1.722687	1.319648	-0.129423
	-0.095908	-2.434891	0.745597	1.541783	0.742043

Exemplo 3

Inputs: P(9),  $\theta(9)$ , M(9),  $\theta(10)$ , M(10)  
Output: P(10)

	Weight					Threshold
h1	-7.003657	-1.773186	0.610258	-0.307218	-1.059579	2.398821
	-0.522576	-1.149151	0.585113	-0.876102	-0.715830	1.161999
h2	-2.485600	-1.701570	0.812569	-0.267826	-0.682070	0.778366
	2.325455	-1.795726	-2.547008	-2.211357	-2.672765	-0.301740
h3	4.123282	0.794142	-0.056664	0.801774	0.804435	-1.505060
o1	-6.547663	-2.537905	-3.336793	4.175916	3.485125	-1.020323