



**GRUPO IX
GRUPO DE ESTUDO DE OPERAÇÃO DE SISTEMAS ELÉTRICOS - GOP**

**FERRAMENTA PARA A PREVISÃO DO CARREGAMENTO DE CURTO PRAZO DE LINHAS DE
TRANSMISSÃO ATRAVÉS DE REDES NEURAIAS**

**Cleber Roberto Guirelli
USP***

**Prof. Dr. José Antônio Jardini
USP**

**Luiz Carlos Magrini
USP**

**Jorge Yasuoka
USP**

**Antônio Carlos Campos
CTEEP**

**Mário Bastos
CTEEP**

RESUMO

Foi realizado um estudo conjunto entre a CTEEP Transmissão Paulista e a USP sobre a previsão da carga com o uso de técnicas de inteligência artificial. Foi analisado o uso de redes neurais, tratamento de dados e fatores que afetam o consumo a fim de desenvolver um sistema computacional capaz de prever a curva de carga diária do sistema de transmissão.

O resultado obtido foi um protótipo computacional capaz de prever a curva de carga diária do sistema de transmissão com uma antecedência de quarenta e oito horas, baseado no histórico das medições de potência ativa e em informações meteorológicas através do uso de redes neurais.

PALAVRAS-CHAVE

Previsão de carga, redes neurais, sistemas de transmissão.

1.0 - INTRODUÇÃO

A previsão de carga de curto prazo tem grande importância para a operação e planejamento de um sistema de transmissão de energia elétrica. Melhorando a exatidão da previsão podemos aumentar a segurança do sistema e diminuir seus custos de geração.

No entanto, o problema da previsão é complexo pois o consumo de energia é afetado por fatores diversos como clima, situação econômica, época do ano, etc., que possuem um comportamento não-linear de difícil modelamento.

Com o objetivo de prever a carga de um sistema elétrico, foram desenvolvidas diversas metodologias tais como regressão linear, filtro de Kalman, séries temporais estocásticas, expansão espectral, etc., além do uso da experiência adquirida pelos operadores ao longo dos anos. O surgimento das técnicas de inteligência artificial (IA) deu novo impulso para a previsão da carga pois tornou possível a transferência do conhecimento de especialistas para sistemas computacionais ou ainda aprender o comportamento de um sistema a partir do seu histórico, sem se valer de um modelamento matemático do mesmo.

Com o objetivo de melhorar seu sistema de previsão de carga, a CTEEP Transmissão Paulista desenvolveu em parceria com a USP um sistema para a previsão da carga baseado em redes neurais artificiais (RNAs) [1] capaz de, através de dados armazenados no historiador, fornecer a previsão da curva de carga e da energia diária do sistema com uma antecedência de quarenta e oito horas. A previsão inclui a carga total do sistema bem como suas três componentes que correspondem às cargas das regiões originais da CESP, CPFL e Eletropaulo.

Esse trabalho apresenta a análise e o tratamento de dados, a configuração das RNAs, a estrutura e detalhamento do software e os resultados obtidos.

2.0 - OBTENÇÃO, ANÁLISE E TRATAMENTO DE DADOS

2.1 Carga

A CTEEP dispõe de um sistema historiador de dados capaz de fornecer a carga do sistema com uma amostragem a cada minuto. Como em qualquer conjunto de medições, os dados estão sujeitos a diversos problemas como falhas de medição, problemas na transmissão dos dados, etc., exigindo algum tipo de filtragem. Após a análise de algumas técnicas para a filtragem, foi adotada uma técnica semelhante à utilizada para identificação de dados distorcidos (*bad data*) em estimadores de estado [5]. O método se mostrou eficaz computacionalmente e de fácil implementação. Neste método, medições com problemas podem ser identificadas pelo seu resíduo de medição, definido como:

$$J_i = \frac{(x_{i \text{ medido}} - x_{i \text{ estimado}})^2}{\sigma^2} \quad (1)$$

onde σ é o desvio padrão do conjunto de medição.

Os valores estimados são calculados para um modelamento do conjunto de dados. Aplicado o filtro em blocos de quinze minutos, o uso de um modelamento linear das medições se mostrou eficiente. Os erros de medição obedecem a distribuição χ^2 e os valores muito altos de resíduo indicam medições com grande probabilidade de estarem corrompidas.

Como a frequência de amostragem da carga é de 1 minuto, temos 1440 pontos de carga por dia, o que vai gerar uma quantidade muito grande de dados. Assim, após a filtragem, cada intervalo é substituído por seu valor médio, reduzindo a amostragem para 15 minutos e apenas 96 pontos por dia, o que não representa uma perda significativa de informação. Na Figura 1 e Figura 2 temos um exemplo de uma curva carga amostrada a cada minuto sem a filtragem e a mesma curva filtrada com amostragem a cada 15 minutos.

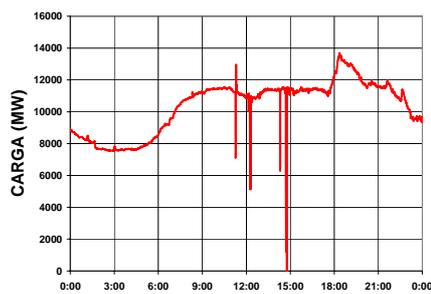


FIGURA 1 - Curva de carga original

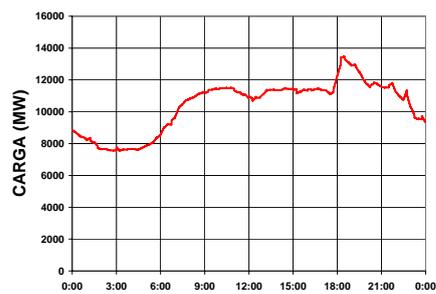


FIGURA2 - Curva de carga filtrada

2.2 Padrões das curvas de carga

Um sistema de previsão baseado em IA apresenta um melhor desempenho com a utilização de grupos de dados com padrões semelhantes. Assim, foi feita uma análise dos perfis das curvas de carga com o auxílio de técnicas de clusterização a fim de se agrupar as curvas semelhantes. A análise das curvas de carga forneceu as seguintes informações:

- Sábados e Domingos possuem perfis distintos enquanto os demais dias da semana possuem perfis extremamente semelhantes.
- Se o dia for um feriado, ponte ou outro dia especial, o seu perfil de carga será diferente do esperado para o dia da semana correspondente.
- O racionamento, ocorrido entre 2001 e 2002 gerou um período de perfis atípicos que foram descartados por não representarem o comportamento atual do sistema elétrico.

Na FIGURA 3 e FIGURA 4 podemos observar as curvas de carga de uma semana típica e de uma com feriado.

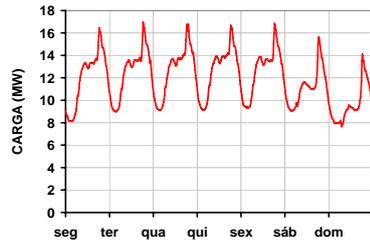


FIGURA 3 - Perfil da carga em uma semana normal

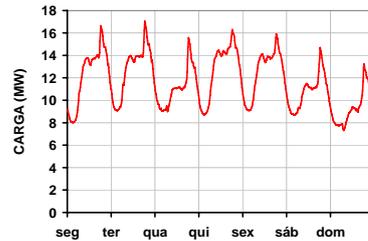


FIGURA 4 – Perfil da carga com feriado

2.3 Temperatura Ambiente

A temperatura ambiente é um dos fatores com maior influência sobre o comportamento da carga. Para auxiliar na previsão da carga, são necessários não apenas o histórico de temperaturas como também a sua previsão para o dia cuja carga desejamos prever.

O problema com o sistema da CTEEP é que ele está espalhado por todo o estado de São Paulo e podemos verificar uma grande variação de temperatura nas diversas regiões do estado. Assim, existe o problema de determinar qual é a temperatura a ser usada na previsão. A solução adotada foi utilizar temperaturas médias para o estado (região da CTEEP) e para as regiões originais da CESP, CPFL e Eletropaulo. A instalação de 9 sensores de temperatura ao longo do estado, conforme indicado na FIGURA 5 forneceria medições de temperatura suficientes para o sistema de previsão.



FIGURA 5 – Locais para medição de temperatura

Como essa estrutura de medição ainda não está disponível, foram utilizados dados obtidos com a estação meteorológica do IAG-USP no bairro da Barra Funda, na cidade de São Paulo, tendo esses dados sido adotados como valores médios para todo o estado. Como a região da grande São Paulo responde por cerca de 60% da carga do estado, o efeito da temperatura nessa região tem grande influencia no sistema.

A previsão de temperatura foi obtida do CPTEC – Centro de Previsão de Tempo e Estudos Climáticos via internet. Alguns testes indicaram que não é necessário o uso de uma curva diária de temperaturas, o uso da temperatura máxima e mínima diárias é suficiente para a previsão da carga.

2.4 Energia

Testes com os dados do sistema da CTEEP mostraram que a energia diária possui um efeito significativo na previsão pois incorpora informações sobre o crescimento do sistema, sua sazonalidade e ainda indica dias especiais, onde temos um consumo que foge ao padrão. A energia é obtida facilmente da integração da curva de carga. Assim como para a curva de carga, a energia diária pode ser agrupada por dias da semana. Feriados e dias especiais podem ser facilmente identificados pois suas energias estão bem distantes da curva média. Como exemplo temos na FIGURA 6 a curva da energia diária para as terças-feiras no período entre 2001 e 2003. Nela podemos observar o crescimento do consumo de energia ao longo do tempo e os dias especiais.

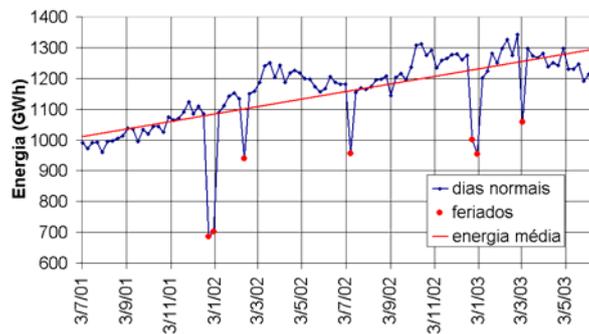


FIGURA 6 - Energia diária da CTEEP para Terças-feiras

3.0 - SOFTWARE

O software desenvolvido foi denominado PCT – Previsão da Carga da Transmissão. O PCT é composto pelo módulo servidor e o módulo de visualização. O servidor faz a aquisição e tratamento dos dados, armazena em uma base de dados local e executa a previsão. O módulo de visualização dispõe de interface gráfica para visualização dos dados, previsões e configuração e manutenção do sistema de previsão. Os módulos servidor e a base de dados local devem estar instalados em um único microcomputador, juntamente com o módulo de visualização, com acesso ao historiador, internet (coleta de informações meteorológicas) e a rede de comunicação de dados. O módulo de visualização poderá ser instalado em qualquer microcomputadores em rede com o servidor, permitindo acesso aos dados e previsões. Na FIGURA 7 vemos um esquema da estrutura do software.

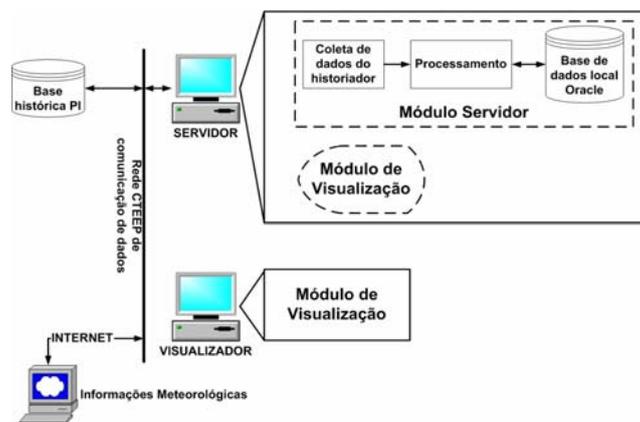


FIGURA 7 - Estrutura do software

O PCT foi desenvolvido em ambiente Windows 2000 em Microsoft Visual Basic para a interface gráfica, Microsoft Visual C++ para o processamento das RNAs e PL-SQL para a manipulação da base de dados Oracle. O historiador CTEEP é o sistema PI System da Osisoft.

3.1 Redes Neurais no Projeto

As redes neurais artificiais são uma técnica de processamento baseada em sistemas nervosos biológicos tais como o cérebro. São compostas de um grande número de unidades processadoras interconectadas denominadas neurônios. Elas utilizam uma técnica semelhante ao aprendizado humano através de exemplos para serem configuradas para resolver problemas específicos. Assim, são capazes de aprender o comportamento de qualquer sistema através de um conjunto de dados entra/saída [6] funcionando como um interpolador universal.

Não há teoria capaz de identificar a melhor estrutura e forma de treinamento de uma RNA para um dado problema, de modo que o melhor processo é a tentativa e erro. A literatura fornece uma série de estruturas de rede e métodos de treinamento.

Ao definir a rede e treiná-la, temos de gerar um sistema capaz de generalizar o comportamento do sistema

evitando o sobre-treinamento, que é quando a rede fica 'viciada' em um conjunto de dados ou o sub-treinamento que ocorre quando a rede não é capaz de aprender o comportamento do sistema.

Existem diversas estruturas de RNAs, formas de treinamento e possibilidade de utilização de dados mas para o protótipo desenvolvido, foi adotada a RNA tipo *MultiLayer Perceptron* (MLP), com treinamento por *backpropagation* utilizando como dados de entrada as curvas de carga, energia diária e temperatura ambiente. Os métodos, estruturas e configurações de redes neurais adotados foram baseados em estudos executados especificamente para o sistema CTEEP.

O PCT permite a configuração da estrutura e dos parâmetros de treinamento para redes MLP. Após inúmeros testes, chegamos a um sistema de previsão que utiliza duas RNAs, uma para a previsão de energia e outra para a previsão da curva de carga. A estrutura do sistema de previsão está na FIGURA 8 e os dados de entrada e saída necessários a cada rede estão na

TABELA 1.

TABELA 1 - Configuração das RNAs		
Rede	Entradas	saídas
Previsão de carga	300 entradas: Curva de carga, temperatura máxima, temperatura mínima e energia dos últimos 3 dias de mesmo tipo (segundas, terças, etc.) Previsão de energia, temperatura máxima e temperatura mínima do dia a ser previsto.	96 saídas: curva de carga prevista.
Previsão de energia	12 entradas: Energia e informação se o dia é comum ou atípico para os 3 últimos dias, informação se o dia é comum ou atípico para o dia a ser previsto e os dois dias seguintes.	1 saída: previsão da energia diária.

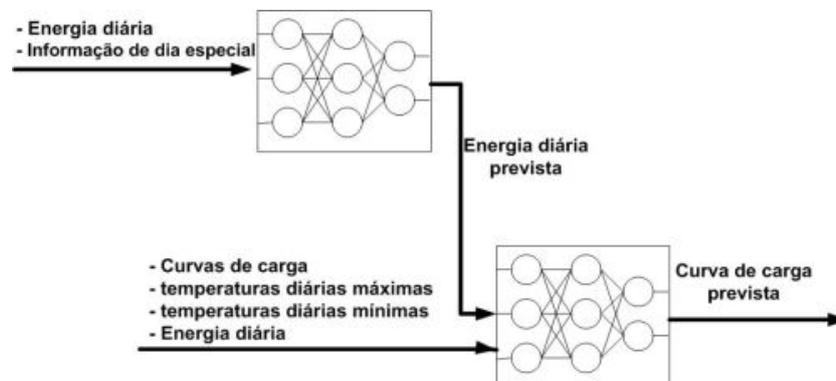


FIGURA 8 - Estrutura de Previsão da Carga

Foram definidas e treinadas redes para cada dia da semana e para cada concessionária para carga e energia, totalizando 56 redes neurais distintas.

3.2 Funcionamento do Software

O PCT executa uma série de funções em seqüência onde cada etapa fornece dados para a seguinte. A indisponibilidade de qualquer um dos dados inviabiliza a previsão. Temos a seguinte seqüência de eventos :

- A cada 15 minutos é feita a leitura da potência ativa do historiador
- Filtra as curvas de carga;
- Reduz a amostragem para 15 minutos;
- Calcula a energia diária após o último valor de carga do dia ser obtido;

- Obtém a previsão de temperatura para o dia seguinte se houver conexão com a Internet disponível ou utiliza uma base de dados histórica de temperatura.
- Quando estiverem disponíveis os dados completos de um dia, executa a previsão da energia diária com dois dias de antecedência;
- Após a previsão da energia, executa a previsão de carga com dois dias de antecedência.

3.3 Interface Gráfica

A interface gráfica do PCT permite a visualização dos dados obtidos do historiador e das previsões e a manutenção da base de dados de redes neurais, incluindo a o retreinamento, criação de novas RNAs e alocação de RNAs específicas para dias especiais. Essas funções são fundamentais para o sistema de previsão pois com o tempo e evolução do sistema, as previsões tendem a piorar e se torna necessário o treinamento das RNAs com dados atualizados do sistema.

Na Figura 9 e Figura 10 temos exemplos das telas do software.

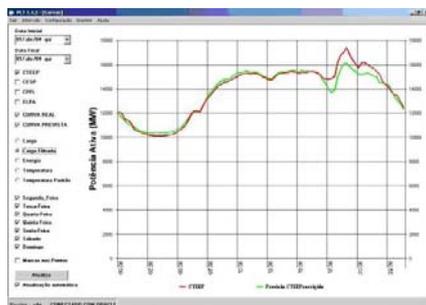


FIGURA 9 – Visualização de curvas

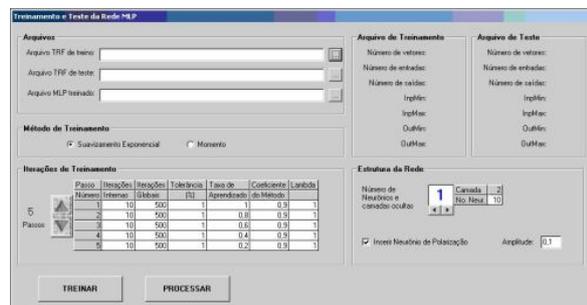


FIGURA 10 - Treinamento de RNAs

3.4 Resultados Obtidos

O protótipo do software desenvolvido e testado inicialmente na USP com dados fornecidos pela CTEEP e posteriormente foi instalado em caráter experimental na CTEEP para validação e avaliação dos resultados.

Os testes em laboratório para as previsões de energia forneceram resultados com erro médio da ordem de 1,7% e as de carga de 2,6%. As redes neurais foram treinadas com dados entre Março de 2002 até Maio de 2003 e processadas as previsões de Junho a Dezembro de 2003. Os erros médios entre as previsões e as curvas reais do período estão na TABELA 2.

TABELA 2 - Previsões do PCT

	Erro percentual	
	Previsão de energia	Previsão de carga
Média	1,7	2,6
Desvio padrão	1,6	1,9

A CTEEP e ONS se valem de experiência de operadores e métodos manuais de previsão sem a utilização de RNAs para executar suas previsões de carga. Comparando as previsões do PCT, CTEEP e ONS com as curvas reais de carga para um mesmo período, chegamos aos resultados da TABELA 3. Verificamos que o protótipo foi capaz de previsões superiores as da ONS e na mesma ordem de erro da atualmente feita por técnicos experientes da CTEEP.

TABELA 3 - Erros da Previsão de carga para a CTEEP

	Erro percentual		
	CTEEP	ONS	PCT
Média	2,3	13,1	2,6
Desvio padrão	2,2	8,3	1,9

Com a evolução do sistema, as previsões tendem a piorar de qualidade, sendo necessário que periodicamente as RNAs sejam retreinadas com dados atualizados a fim de corrigir e aprimorar as previsões do sistema.

4.0 - CONCLUSÃO

A previsão da carga vem se tornando cada vez mais importante e útil no planejamento e operação de sistemas elétricos sendo necessário o seu aprimoramento. As técnicas de inteligência artificial desenvolvidas nos últimos anos têm se mostrado uma ferramenta importante no avanço da previsão da carga, especialmente as redes neurais.

O estudo realizado mostrou que é possível implementar um sistema computacional de previsão de carga baseado em redes neurais capaz de gerar resultados tão bons ou melhores que os obtidos atualmente por meio de outras técnicas de previsão. Verificamos que além do próprio histórico do sistema é necessário que se disponha de informações sobre variáveis exógenas que possuem grande influência sobre as características de consumo. Entre as variáveis exógenas, a temperatura ambiente foi identificada como a de maior influência. Vemos ainda que a eficiência do sistema de previsão com RNAs é dependente não só da disponibilidade de informações mas também de um periódico retreinamento das RNAs a fim de acompanharem a evolução da carga, bem como do seu perfil.

5.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- [1] Lu, C. N., Wu, H. T., Vemuri S. "Neural Network Based Short Term Load Forecasting," *IEEE Transactions on Power Systems*, vol. 8, pp. 336-342, Feb 1993.
- [2] Senjyu, T., et al. "One-hour-ahead load forecasting using neural network," *IEEE Transactions on Power Systems*, vol. 17, pp. 113-118, Feb. 2002.
- [3] Hippert, H. S., Pedreira, C. E. , Souza, R. C. "Neural Networks for short-term Load Forecasting: A Review and Evaluation" *IEEE Transactions on Power Systems*, vol. 16, pp. 4455, Feb 2001.
- [4] Yasuoka, J. , Brittes J. L. P. , Jardini, J. A. "ANN-based Real-Time Short-Term Load Forecasting in Distribution Substations," "IEEE/PES Transmission & Distribution Latin America 2002, São Paulo, Brasil, March 2002.
- [5] Wood, A. J. , Wollenberg, B. F. "Power Generation, Operation and Control", New York, John Wiley & Sons, 1984.
- [6] Wasserman, P. D. "Neural Computing – Theory and Practice", Van Nostrand Reinhold, 1989.