



GRUPO IX

Grupo de Estudo de Operação de Sistemas Elétricos (GOP)

MAPAS AUTO-ORGANIZÁVEIS NÃO-PARAMÉTRICOS PARA ANÁLISE DA INFLUÊNCIA CLIMÁTICA EM CURVAS DE CARGA

Wagner da Silva Lima*
wagner@eee.ufg.br
Escola de Engenharia Elétrica
UFG

Leandro Nunes de Castro
lnunes@dca.fee.unicamp.br
DCA-FEEC
UNICAMP

Takaaki Ohishi
taka@densis.fee.unicamp.br
DENSIS-FEEC
UNICAMP

RESUMO

Neste trabalho avaliou-se o desempenho de classificadores neurais baseados em Mapas Auto-Organizáveis Não-Paramétricos de Kohonen (PSOM), para análise e classificação dos perfis de curvas de carga com influência climática. Com a utilização dos PSOMs e de dados climáticos como nebulosidade, temperatura e insolação realizaram-se diversas classificações das curvas de carga próprias do Estado de São Paulo no intuito de identificar o grau de influência destas variáveis no formato das curvas em diversos períodos do dia, sobretudo no horário de ponta.

PALAVRAS-CHAVE

Previsão de Carga, Redes Neurais, Mapas de Kohonen, Programação da Operação.

1.0 - INTRODUÇÃO

A importância da previsão de carga no Setor Elétrico Brasileiro (SEB) têm crescido ultimamente principalmente devido a implantação do Mercado Atacadista de Energia (MAE). No âmbito do MAE é necessário ao Operador Nacional do Sistema (ONS) realizar a previsão de curto-prazo (24 horas a frente) do perfil de carga diário do sistema para a definição do preço *spot* da energia elétrica em cada hora do dia seguinte. Além disso, há várias outras funções a serem feitas pelo ONS utilizando a previsão de carga a curto-prazo, como o despacho das usinas, avaliação de intercâmbios de energia e análise de contingência e confiabilidade do sistema.

Outra aplicação da previsão a curto-prazo, é o acompanhamento on-line do comportamento da carga pelos operadores no Centro de Operação do Sistema (COS). Um sistema de previsão de carga satisfatório para a operação *on-line* (com horizonte de previsão de um a vários minutos a frente) precisa automaticamente adaptar-se às variações climáticas não previstas anteriormente, mas que agora influenciam no comportamento da carga.

Dentre as variáveis climáticas que mais influenciam a carga podemos citar a conjugação da insolação (número de horas do brilho solar direto), pluviosidade (presença ou ausência de chuva no período) e nebulosidade (dias nublados e parcialmente nublados). Estes fatores podem ser observados na Figura 1.

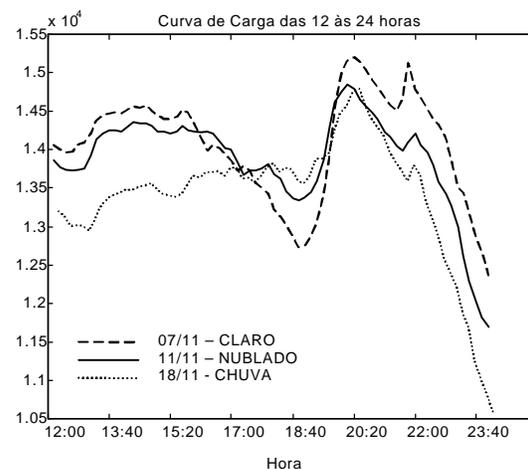


FIGURA 1 - Curvas de carga das 12 às 24 horas em dias com diferentes condições climáticas.

Para a previsão de carga a curto-prazo, o comportamento do perfil no horizonte considerado constitui uma das informações mais relevantes a ser utilizada por uma abordagem de sistemas inteligentes. A precisão do modelo de previsão dependerá fortemente de como a modelagem de carga será feita considerando as variáveis climáticas que alteram o comportamento da carga. Portanto é necessária a análise da influência climática sobre as curvas de carga.

Para os operadores do sistema este comportamento é facilmente determinado devido a experiência e empirismo. Contudo, tal influência não é tão fácil de ser observada em modelos matemáticos. Muitos modelos de previsão de carga a curto-prazo têm sido propostos na literatura, utilizando Redes Neurais Artificiais (RNAs) (1-5,8,9) e Lógica Fuzzy (LF) (6,7).

Geralmente estes modelos utilizam uma RNA com dados de entrada de carga e variáveis climáticas, tendo na saída a carga prevista para aquele intervalo. Entretanto, estes modelos encontram dificuldade em modelar a influência climática que modifica os perfis de carga em vários períodos do dia.

Mohamed et. al. (7) sugerem o emprego de RNA's especializadas para cada dia da semana e para cada estação do ano. Portanto estas redes teriam em seu conjunto de treinamento apenas dias com perfis de carga similares.

Entretanto, pouco se trabalhou com a questão da influência climática na definição do perfil de carga desejado para um determinado trecho da curva de carga diária. Esta curva de carga para algumas regiões geo-elétricas do SEB, por exemplo, possuem características peculiares que ocorrem devido a influência de variáveis diversas. No caso do Estado de São Paulo, as variáveis que mais influenciam a carga são o tipo de dia (dia útil, feriado, fim de semana), o mês e estação do ano, a hora do pôr-do-sol, a temperatura, a nebulosidade, a insolação e a pluviosidade, como pôde ser observado na Figura 1.

Neste trabalho propomos a utilização de um *mapa auto-organizável não-paramétrico* (11) (PSOM – do inglês *pruning self-organizing map*) para a determinação da correlação entre as variáveis climáticas e o comportamento do sistema, e a verificação da influência de algumas destas variáveis climáticas nos diversos intervalos do dia.

2.0 – DADOS HISTÓRICOS

O histórico de cargas utilizado neste trabalho é constituído das curvas de carga diárias, fornecidos pela CESP, de junho a dezembro de 1997 em patamares de 1 em 1 minuto. Estes dados foram integralizados em intervalos de 10 em 10 minutos de forma a não perderem as características de cada curva. Isto foi observado fazendo-se a classificação das curvas em patamares de 1, 5 e 10 minutos e verificando-se que as classificações eram redundantes.

Os dados climáticos são observações realizadas na estação meteorológica Fontes do Ipiranga pertencente ao Instituto Astronômico e Geofísico da USP na região do Parque do Estado, zona sul da cidade de São Paulo. Os dados de insolação referem-se a duração do brilho solar durante o dia. Os dados de pluviosidade correspondem a duração da chuva em base horária durante o dia.

Com os dados acima foi possível montar um histórico cujos dados climáticos correspondem às condições de insolação, nebulosidade e pluviosidade, como CLARO (céu limpo sem nuvens), BOM (céu claro com nuvens a parcialmente nublado), NUBLADO (céu nublado sem brilho solar) e CHUVA (nublado com chuva). Os dados de temperatura não foram considerados na análise da classificação feita pelo PSOM. Estes dados foram fornecidos pela CESP e não são precisos, pois correspondem à temperatura às 15 horas do prédio onde é realizada a programação da operação do sistema CESP na Avenida Angélica região central da cidade de São Paulo.

Os dados de carga referem-se à carga própria de todo o Estado de São Paulo. Entretanto, os dados climáticos são da região da grande São Paulo. Embora o ideal seria que os dados de carga também fossem apenas da Grande São Paulo, a grande proporção que a carga da área metropolitana tem (cerca de 60% da carga total do sistema), justifica os resultados conseguidos.

3.0 – MAPAS AUTO-ORGANIZÁVEIS DE KOHONEN

As arquiteturas auto-organizadas, como inicialmente propostas por *Kohonen* (11), geram mapeamentos de um espaço de dimensão elevada em estruturas cuja dimensão topológica é inferior à original. Estes mapeamentos são capazes de preservar as relações de vizinhança dos dados de entrada. Isto os torna interessantes para aplicações em diversas áreas, como reconhecimento de voz, análise exploratória de dados e otimização combinatória.

Os Mapas Auto-Organizáveis de Kohonen (SOM – do inglês Self-Organizing Map) fazem parte de um grupo de redes neurais artificiais chamadas “redes baseadas em competição” (9). Estas redes combinam competição com uma estratégia de treinamento para o ajuste dos pesos. O treinamento não-supervisionado destas redes detecta a similaridade entre os padrões de entrada, sendo esta uma característica muito importante. O objetivo principal de um SOM é agrupar dados de entrada semelhantes em grupos, denominados *clusters*.

O SOM possui uma unidade de entrada para cada componente do vetor de entradas. Cada unidade de saída representa um grupo ou cluster. O número de clusters é limitado ao número de unidades de saída. Durante o processo de treinamento, a rede determina a unidade de saída que mais se “aproxima” do vetor de entrada. As Figuras 2(a) e 2(b) apresentam arquiteturas típicas do SOM. Neste trabalho optou-se por um PSOM uni-dimensional.

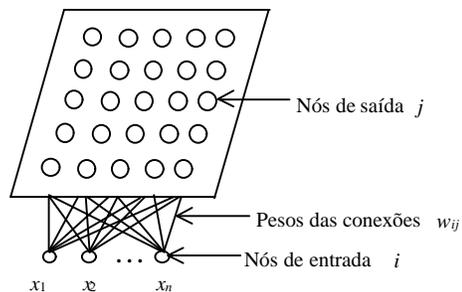


FIGURA 2 - (a) - SOM bi-dimensional

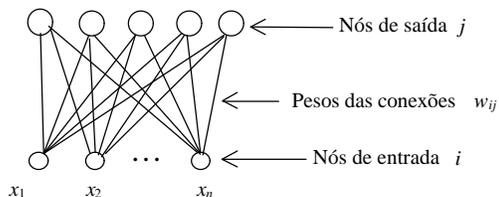


FIGURA 2 - (b) - SOM uni-dimensional

Em termos de aplicação, verificou-se que a utilização de estruturas do tipo auto-organizadas com dimensão arbitrária mas fixa implica em limitações nos mapeamentos resultantes. Um grande número de variações do algoritmo original, com o objetivo de determinação automática de uma arquitetura mais adequada, tem sido apresentado na literatura. Neste trabalho foi utilizado um procedimento de poda para a eliminação de unidades pouco significativas (ou redundantes), proposto em (11) e denominado PSOM.

4.0- ANÁLISE PRELIMINAR

Primeiramente foi feita uma classificação dos perfis de carga e avaliação da coerência da metodologia utilizada (PSOM) com os tipos de carga existentes durante a semana (sábados, domingos, segundas-feiras, dias de semana e feriados). A Figura 3 mostra as curvas de carga de 10 em 10 minutos de setembro de 1997.

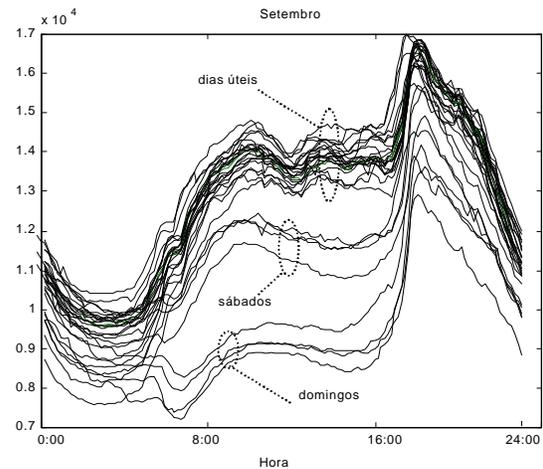


FIGURA 3 - Curvas de carga de setembro de 1997

Como pode ser observado na Figura 4, os 30 padrões de entrada foram classificados em 4 clusters, a saber: dias úteis (DS); sábados (SA); segundas-feiras (SE); e domingos (DO). A classificação obtida foi 100% correta.

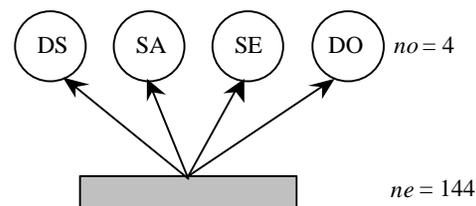


FIGURA 4 - Mapeamentos efetuados por um PSOM para as curvas de carga de setembro de 1997.

Em seguida, foram feitas várias subdivisões na curva de carga diária de cada dia do histórico. Assim, segmentou-se o dia em 7 trechos: madrugada (das 0:00 às 5:20, 27 entradas); alvorada (das 5:20 às 7:10, 12 entradas); manhã (das 7:10 às 12:30, 32 entradas); tarde (das 12:30 às 16:00, 22 entradas); pré-ponta (das 16:00 às 17:30, 10 entradas); ponta (das 17:30 às 21:00, 22 entradas); e pós-ponta (das 21:00 às 23:50, 24 entradas). Estas subdivisões foram feitas com base na curva de variância da carga em cada intervalo para todo o histórico de carga.

Os dados climáticos de insolação e pluviosidade estão disponíveis em base horária das 16 às 24 horas. Portanto, para este trabalho, foram analisados apenas os trechos PRÉ-PONTA, PONTA e PÓS-PONTA.

5.0 – CLASSIFICAÇÃO DAS CURVAS DE CARGA

Após a análise da potencialidade do PSOM para classificação de curvas de carga feita na seção anterior, foi realizada a classificação para cada um dos três trechos supracitados para todos os meses do ano. Abaixo apresentamos os resultados e comentários para a classificação do mês de setembro de 1997.

5.1 – Pré-ponta (das 16:00 às 17:30 horas)

Na Tabela 1 podemos observar que o PSOM separou os dados de carga da PRÉ-PONTA em 5 *clusters*. O *cluster* 1 pode ser considerado sábado com chuva (SA/CHU); o *cluster* 2 dias da semana nublados e chuvosos (SE,DS/NUB), o *cluster* 3 dias da semana bons e claros (SE,DS/CLA,BOM), ou seja, dias claros a parcialmente nublados.

TABELA 1 - Classificação da PRÉ-PONTA de set/97

Cluster	Dias	Clima
1	SA(1)	CHU (1)
2	SE(2), DS(9)	NUB(10), CHU(1)
3	SE(3), DS(8)	BOM(3), CLA(4), NUB(4)
4	SA(2)	NUB(2)
5	DO(4), SA(1)	TODOS

Nota: o número entre (.) refere-se a quantidade de dias deste tipo.

Onde:

- SE - Segunda-feira
- SX - Sexta-feira
- DS - Dias da semana, exceto a Segunda
- DO - Domingo
- AS - Sábado
- CLA - Dia claro sem nuvens, com intenso brilho solar
- BOM - Dia com nuvens e/ou parcialmente nublado, com brilho solar
- NUB - Dia nublado sem brilho solar
- CHU - Dia chuvoso no trecho analisado

A presença de 4 dias nublados neste *cluster* (que deveriam estar no *cluster* 2) mostra que estes dias possuem um padrão intermediário entre dias claros e nublados. Um ajuste nos parâmetros do modelo podem corrigir este erro. Entretanto, devido ao fato dos dados de carga não serem apenas da região onde foram obtidos os dados climáticos, este erro pode não ocorrer caso estes dados fossem apenas da Grande São Paulo.

O *cluster* 4 é formado por sábados nublados (SA/NUB) e o *cluster* 5 por domingos, independente da condição climática (DO) e por um sábado nublado que deveria pertencer ao *cluster* 4. A Figura 5 apresenta os *clusters* formados pelo PSOM para o trecho da PRÉ-PONTA de setembro.

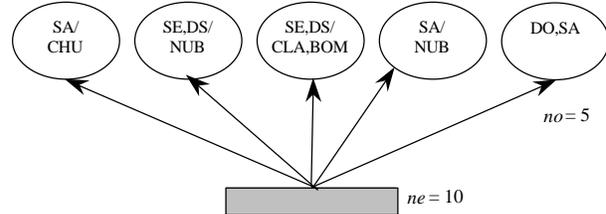


FIGURA 5 - Mapeamentos efetuados por um PSOM para as curvas de carga da PRÉ-PONTA de setembro de 1997.

5.2 – Ponta (das 17:30 às 21:00 horas)

A Tabela 2 mostra que o PSOM realizou a classificação dos dados de carga com 8 *clusters*, indicando que a PONTA tem uma maior variância de perfis de carga do que a PRÉ-PONTA e a PÓS-PONTA. O *cluster* 1 é formado por dias úteis chuvosos geralmente com temperatura baixa (SE,DS/CHU). O *cluster* 2 é formado por um sábado chuvoso (SA/CHU) e uma sexta chuvosa, considerada fora de lugar (deveria estar no *cluster* 1).

TABELA 2 - Classificação da Ponta de set/97

Cluster	Dias	Clima
1	SE(1), DS(3)	CHU (4)
2	DS(1), SA(1)	CHU(2)
3	SE(1), DS(2)	CHU(2), NUB(1)
4	DS(4)	NUB(4), CLA(1)
5	SE(1), DS(1)	CLA(2)
6	DO (2), SA.(1), SE(1), DS(1)	BOM(3), CHU(2)
7	SE(1), DS(4)	CLA(2), BOM(2), NUB(1)
8	DO(2), SA(2)	CLA(2), NUB(2)

O *cluster* 3 é formado por dias úteis nublados (SE,DS/NUB). Apenas um dia deste *cluster* é chuvoso, mesmo assim houve apenas 30 minutos de chuva neste período, não sendo necessário considerar esta classificação como errada. O *cluster* 4 também é formado por dias úteis nublados (DS,NUB), porém não há presença de segundas-feiras. Entretanto há um dia claro neste *cluster*.

O *cluster* 5 é formado por dias úteis bons e claros (SE,DS/CLA,BOM) e o *cluster* 6 por sábados bons e domingos chuvosos (SA,DO). Esta característica é encontrada nas classificações de outros meses. Normalmente domingos chuvosos estão associados no

mesmo *cluster* que sábados bons. A segunda 8 e terça 9 de setembro estão classificadas neste *cluster*, sem haver, a princípio, uma justificativa plausível.

O *cluster* 7 é formado por dias úteis bons e claros (SE,DS/CLA,BOM), exceto o dia 22 que é nublado e deveria estar no *cluster* 3. O *cluster* 8 é formado por sábados nublados (SA/NUB) e domingos claros (DO/CLA).

A Figura 6 apresenta os *clusters* formados pelo PSOM para o trecho da PONTA de setembro

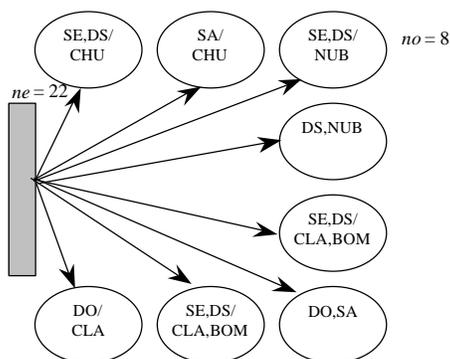


FIGURA 6 - Mapeamentos efetuados por um PSOM para as curvas de carga da ponta de setembro de 1997.

5.3- Pós-ponta (das 21:00 às 24:00 horas)

Na PÓS-PONTA, há apenas 5 *clusters*, demonstrando que a variância neste trecho é menor que na PONTA e em geral do que na PRÉ-PONTA. O *cluster* 1 é formado por segundas-feiras, independente da condição climática (SE) e o *cluster* 2 é formado por todas as sextas-feiras de setembro, também independente da condição climática (SX). Além das sextas-feiras, formam o *cluster* 2 uma terça (dia 9) e um sábado, provavelmente fora de lugar.

TABELA 3 - Classificação da PÓS-PONTA de set/97

Cluster	Dias	Clima
1	SE(2)	CLA(1), NUB(1)
2	SX(4), DS(1), SA(1)	BOM(3), NUB(2), CHU(!)
3	SE(3), DS(12)	TODOS
4	SA(1)	NUB(1)
5	DO(4), SA(2)	CHU(3), NUB(1), CLA(2)

O *cluster* 3 contém os demais dias úteis de setembro (SE,DS), e os *clusters* 4 e 5 os sábados e domingos (SA,DO), todos independentes da condição climática.

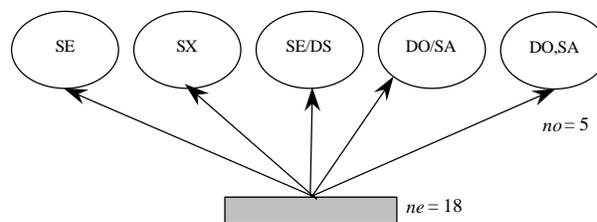


FIGURA 7 - Mapeamentos efetuados por um PSOM para as curvas de carga da PÓS-PONTA de setembro de 1997.

5.4- Performance do PSOM nas classificações

A Tabela 4 apresenta o percentual de classificações corretas durante o período analisado.

TABELA 4 - Classificações corretas realizadas pelo PSOM de junho a dezembro de 1997

MÊS	TRECHO		
	PRÉ-PONTA	PONTA	PÓS-PONTA
Junho	97 %	90 %	87 %
Julho	94 %	94 %	94 %
Agosto	90 %	94 %	87 %
Setembro	87 %	93 %	93 %
Outubro	93 %	81 %	100 %
Novembro	83 %	87 %	93 %
Dezembro	100 %	87 %	94 %

Na análise feita nos demais meses do histórico puderam ser encontradas várias relações entre as cargas de acordo com o trecho e a condição climática ocorrida. De maneira geral nas classificações da PRÉ-PONTA há influência climática considerável.

Os dias úteis são separados em *clusters* nublado/chuva e bom/claro. Sábados e domingos são classificados em *clusters* separados dos demais, e algumas vezes em um único *cluster*. Em alguns meses, como setembro há separação de sábados de acordo com a condição climática.

Na classificação da PONTA constata-se uma grande influência da condição climática, sobretudo três classes de dias: chuvosos, nublados e dias claros com brilho solar. A separação segue em geral o mesmo padrão da PRÉ-PONTA.

A análise feita para o período da PÓS-PONTA demonstra que a separação dos perfis se concentram em dias úteis e finais de semana. Logo não há muita influência da condição climática. Entretanto existe

influência da temperatura neste trecho, havendo separação de dias com menor e maior temperatura.

6.0 - CONCLUSÕES

Foi realizada neste trabalho várias classificações de trechos da curva de carga diária do sistema CESP utilizando PSOMs. A finalidade destas classificações é separar em *clusters* os diversos tipos de perfil de carga e associar as variáveis explicativas destes perfis, para modelagem de carga para modelos de previsão de carga a curto-prazo.

Estas informações são subsídios que servem para determinação das variáveis exógenas do modelo de previsão de carga, bem como definição do perfil adequado para cada trecho da curva de carga.

A análise foi feita para os dados do Estado de São Paulo entre setembro e dezembro de 1997. Devido a escassez de informações climáticas mais precisas e um histórico mais detalhado com informações contínuas, não foi possível avaliar com maior precisão outros períodos do dia como a madrugada, a entrada de carga pela manhã e o resto da manhã até o início da tarde. Apesar desta dificuldade, as condições climáticas têm maior importância no período da ponta, validando a relevância dos estudos desenvolvidos.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) A. G. BAKIRTZIS, V. PETRIDIS, S. J. KLARTZIS, M. C. ALEXLADIS & A. H. MALSSIS, "A Neural Network Short Term Load Forecasting Model for the Greek Power System". IEEE Transactions on Power System, vol. 11, no. 2, pp. 858-863, maio de 1996.
- (2) A. K.HOTANZAD, M. H. DAVIS, A. ABAYE & D. J. MARATUKULAM, "An Artificial Neural Network Hourly Temperature Forecaster with Applications in Load Forecasting". IEEE Transactions on Power System, vol. 11, no. 2, pp. 870-876, maio de 1996.
- (3) C. STROEMICH & M. THOMAAS, "A Short Term Load Forecasting System Using Adaptive Logic Networks". Proceedings of the American Power Conference, abril de 1997.
- (4) J. VERMAAK & E. C. BOTHA, "Recurrent Neural Networks for Short-Term Load Forecasting". IEEE Transactions on Power Systems, vol. 13, no. 1, pp. 126-132, fevereiro de 1998.
- (5) W. S. LIMA & T. OHISHI, "Uso de Variáveis Climáticas em Previsão de Carga no Período de Demanda de Ponta utilizando Redes Neurais Artificiais". XIV SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica. Anais em CD-ROM, Belém, Pará. 1997.
- (6) H-T. YANG & C-M. HUANG, "A New Short-Term Load Forecasting Approach Using Self-Organizing Fuzzy ARMAX Models". IEEE Transactions on Power Systems, vol. 13, no. 1, pp. 217-225, fevereiro de 1998.
- (7) O. MOHAMED, D. PARK, R. MERCHANT, T. DINH, C. TONG, A. AZEEM, J. FARAH & C. DRAKE, "Practical Experiences with an Adaptive Neural Network Short-Term Load Forecasting System". IEEE Transactions on Power Systems, vol. 10, no. 1, fevereiro de 1995.
- (8) W. S. LIMA, "Previsão de Carga no Período de Demanda de Ponta Utilizando Redes Neurais Artificiais". Tese de mestrado. UNICAMP. 144p., agosto de 1996.
- (9) S. HAYKIN, "Neural Networks A Comprehensive Foundation", 2nd. Edição, Prentice Hall, 1999.
- (10) T. KOHONEN, "Self-Organized Formation of Topologically Correct Feature Maps". Biological Cybernetics, 43, pp. 59-69, 1982.
- (11) L. N. de CASTRO & F. J Von ZUBEN, "An Improving Pruning Technique with Restart for the Kohonen Self-Organising Feature Map". IEEE International Joint Conference on Neural Networks IJCNN'99, Washington D.C./USA, julho de 1999.

AGRADECIMENTOS

Agradecemos à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) e à Fundação de Apoio à Pesquisa da UFG (FUNAPE) pelo suporte financeiro dado a esta pesquisa. Queremos também agradecer à CESP pelo fornecimento dos dados de carga e ao Instituto de Astronômico e Geofísica (IAG) da USP pelos dados climáticos fornecidos.