

destacar para o caso de determinação de perfis de consumo típicos de carga os métodos estatísticos de Bayes [1], as redes neurais artificiais [2-3], lógica difusa [3] e algoritmos híbridos utilizando computação flexível e estatística [1]. A que mais se destaca, inclusive como técnica de mineração de dados é o Mapa Auto-Organizável de Kohonen (MAOK) e suas variações [4].

Este trabalho apresenta um MAOK para classificar e agrupar perfis de carga de consumidores de energia elétrica para ser utilizado como ferramenta de gestão energética. Uma vez determinados os perfis de consumo desta instalação é possível determinar correlações entre a curva de carga e os fatores que a determinam como a influência de variáveis climáticas na mesma.

Alguns resultados foram obtidos utilizando dados de consumo de uma instalação educacional monitorados durante oito meses, podendo ser detectados vários aspectos relacionados à sazonalidade e uso das instalações desta unidade consumidora.

2.0 – GESTÃO ENERGÉTICA

Com o constante aumento das tarifas de energia elétrica e cotas de consumo definidas quando há o racionamento de energia, tornou-se fundamental o controle do custo da energia elétrica e gestão financeira de todos os consumidores. Conhecendo o comportamento do consumo de energia elétrica o consumidor tem a capacidade de tomar uma postura para otimizar seu uso administrando com eficiência os contratos de compra e venda de energia.

Neste contexto, a Gestão Energética (GE) pode ser definida como um conjunto de princípios, técnicas, estudos, normas e ações que objetivam o uso eficiente da energia e outros recursos naturais nas unidades consumidoras.

Para se fazer a GE nas instituições, faz-se necessária à implantação de um Programa de Gestão Energética (PGE) que irá gerenciar as diferentes atividades desenvolvidas levantando informações e as organizando com o objetivo de identificar áreas com potencial de redução de consumo de energia sem perda da qualidade do serviço ofertado e também implementar novas atividades com qualidade ambiental e eficiência energética [5].

Dentre as atividades de um PGE podemos destacar:

- Conhecer o comportamento da curva de carga da unidade consumidora;
- Realizar diagnósticos energéticos das instalações internas e externas;
- Desenvolvimento de campanhas conservacionistas;
- Mapeamento de formas de financiamento de investimentos;
- Avaliações contratuais da aquisição de energia;
- Disseminação dos resultados alcançados;
- Realização de programas de treinamento e educação de pessoal;
- Realização de programas de estímulo, como concursos, premiações, etc;

- Difusão do conhecimento da importância do uso eficiente de energia;
- Busca pelo consenso para a continuidade do programa mostrando que o sucesso depende da participação.

A GE não se limita à troca de velhos equipamentos desperdiçadores de energia, por outros mais eficientes. Administrar o uso e a compra de energia elétrica exige do gestor um conhecimento maior do processo produtivo da empresa, da maneira como a energia é usada.

É necessário dominar metodologias de gestão corporativa tanto para pequenos, como para grandes empreendimentos. Para isto é necessário fazer levantamento de dados para determinar índices de produtividade (através dos quais poderá ser avaliada a eficácia dos métodos adotados), especificar normas de compras de equipamentos, lançar mão de metodologias e ações que visem implementar nas empresas uma real cultura de eficiência do uso da energia elétrica, nos moldes das ISO 9.000 e 14.000.

Destacamos que o conhecimento da curva de carga é uma das atividades da GE e de vital importância.

3.0 – AGRUPAMENTO DE CURVAS DE CARGA

3.1 – Considerações Gerais

O conhecimento do perfil de consumo pode ser realizado através da análise das curvas de carga. Estas podem ser obtidas através de medição “*in loco*” no medidor da concessionária, ou nos quadros de distribuição de circuitos de força e luz, no caso de consumidores com edificações que desempenham funções diferentes, nas várias edificações e instalações que compõem esta unidade consumidora.

Ultimamente, as instituições têm utilizado sistemas de monitoramento de energia elétrica, fazendo a aquisição de dados em intervalos de 15 minutos conforme determina a Resolução 456/2000 da ANEEL.

Estes sistemas de informação de energia (SIE) permitem ao gestor de energia acompanhar o consumo, demanda (energia ativa e reativa) e interrupções de fornecimento de energia elétrica. Tendo estes dados disponíveis torna-se necessária o agrupamento das curvas de carga para conhecimento.

Existe uma diferença básica entre classificação e agrupamento (“clustering”). No agrupamento, não se tem conhecimento prévio dos padrões de consumo. A técnica de agrupamento deve realizar a separação ou estratificação dos dados sem a intervenção do gestor. No caso da classificação, as classes são pré-determinadas segundo alguns atributos definidos “*a priori*”.

3.2 - Mapas Auto-Organizáveis de Kohonen

As arquiteturas auto-organizadas, como inicialmente propostas por *Kohonen* [4,6], 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 (SOM – do inglês “Self-Organizing Map”) de Kohonen fazem parte de um grupo de redes neurais artificiais chamadas “redes baseadas em competição” [3,4]. 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”.

A grande importância do trabalho de Kohonen foi ter introduzido um novo paradigma no estudo das Redes Neurais: o aprendizado não-supervisionado, segundo o qual a rede não precisa ficar sendo comparada constantemente a um valor de saída durante a fase de aprendizado.

O SOM possui uma unidade de entrada para cada componente do vetor de entradas. Cada unidade de saída representa um grupo. O número de grupos é limitado ao número de unidades de saída. Durante o processo de treinamento, a rede determina a unidade de saída (ou neurônio de saída) que mais se “aproxima” do vetor de entrada. As Figuras 1 e 2 apresentam arquiteturas típicas do SOM.

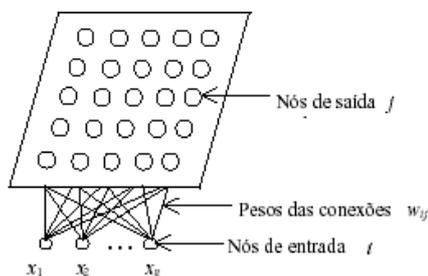


FIGURA 1 - SOM BI-DIMENSIONAL

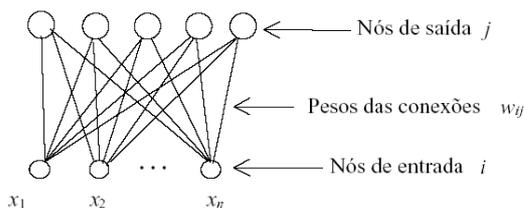


FIGURA 2 – SOM UNI-DIMENSIONAL

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 [7].

Para o agrupamento de curvas de carga, Lima *et al* [8,9], analisaram a correlação entre os perfis de carga

do Estado de São Paulo e as variáveis climáticas explicativas do comportamento de todos os consumidores do Estado, como subsídio para a previsão de carga.

Neste trabalho optou-se por um SOM uni-dimensional com dimensões fixas, por mostrar-se com desempenho (qualidade topológica) melhor no agrupamento dos dados de carga [10].

3.3 – Algoritmo de Treinamento

O treinamento do MAOK inicia-se através da apresentação de cada curva de carga (1x96 – perfil diária com integralização de 15 minutos) na entrada da rede. Verifica-se qual é o neurônio de saída que apresenta o menor valor (neurônio vencedor).

Após a detecção do neurônio vencedor, que é feita durante a fase de treinamento da rede, o mesmo e seus vizinhos, terão seus pesos sinápticos (ligações entre um neurônio de entrada e um neurônio de saída) ajustados. O ajuste dos pesos sinápticos acontece da seguinte forma, primeiro procura-se descobrir qual é o neurônio vencedor para a entrada apresentada, ou seja, qual é o neurônio que possui a menor distância Euclidiana dos dados de entrada:

$$d_i(t) = \sum_{j=1}^N (x_j(t) - w_{ij}(t))^2 \quad (1)$$

Onde:

- t - instante t no tempo;
- i - indexação do neurônio de entrada;
- j - indexação das entradas e dos pesos;
- N - número de entradas (quantidade de x e, respectivamente, quantidade de w por neurônio);
- $x_j(t)$ - entrada j no tempo t ;
- $w_{ij}(t)$ - peso j do neurônio i no tempo t ;
- $d_j(t)$ - distância do neurônio no tempo t .

Em cada passo do aprendizado, o neurônio que melhor responder deverá ser ajustado para aproximar-se ainda mais àquela entrada, e, conjuntamente, todos os neurônios dentro da vizinhança V_i serão alterados. Os neurônios que estiverem fora do subconjunto de vizinhança não serão ajustados.

A adaptação dos neurônios consiste em pegar a diferença entre os dois vetores (x , entrada; e w , pesos) e somar uma fração desta diferença ao vetor de pesos original (w):

$$w_i(t+1) = \begin{cases} w_i(t) + \alpha(t)[x(t) - w_i(t)] & \text{se } i \in V_n(t) \\ w_i(t) & \text{se } i \notin V_n(t) \end{cases} \quad (2)$$

Onde:

- $\alpha(t)$ - coeficiente de aprendizado no tempo t .

A rede é considerada treinada depois de todo o conjunto de treinamento ter sido apresentado à rede, e os critérios de treinamento terem sido satisfeitos.

Seguindo a fase de treinamento, temos a fase de teste da rede neural (MAOK). Essa fase é semelhante à fase

de treinamento. Entretanto, não serão mais alterados os pesos dos neurônios. Para que o teste seja mais apurado, a rede poderá receber, como entrada, além dos padrões que foram apresentados durante o treinamento, outros que não fizeram parte do conjunto de treinamento. Reconhecendo as entradas do teste de forma adequada a rede é considerada treinada com sucesso.

A seguir apresentamos um resumo do algoritmo de treinamento:

- Passo 1 - Inicialização dos pesos da rede com valores baixos (0,01 a 0,1) escolhidos aleatoriamente. Ajuste inicial do raio de vizinhança, que poderá começar com a metade do número de saídas do MAOK e ir diminuindo linearmente;
- Passo 2 - Inserção do padrão de entrada;
- Passo 3 - Cálculo das distâncias Euclidianas de cada saída de acordo com a eq.1;
- Passo 4 - Seleção da menor distância (neurônio vencedor);
- Passo 5 - Atualização dos pesos do neurônio com a menor distância (neurônio vencedor) e seus vizinhos, definidos pelo raio de vizinhança. Isto é feito segundo a eq.2. Os neurônios que não pertencem à vizinhança do vencedor não devem ter seus pesos atualizados;
- Passo 6 - Repetir a partir do passo 2.

4.0 – ESTUDO DAS CURVAS DE CARGA

Foi implementado para este estudo um MAOK para detectar padrões (cargas) semelhantes e fazer o seu agrupamento. Os dados de carga são do Instituto de Química da Universidade Federal de Goiás, em Goiânia. O histórico de dados de carga compreendem o período de 1 de fevereiro a 31 de julho de 2002. Foram utilizados neste trabalho, apenas os dados de demanda média (a cada quinze minutos). Utilizou-se um registrador de pulsos acoplado ao medidor de energia da CELG para obtenção dos dados.

No MAOK uni-dimensional utilizado, os pesos sinápticos são iniciados com valores aleatoriamente baixos (obtidos randomicamente) entre 0 e 1. Estes formam uma matriz de pesos $1 \times 100 \times 96$ (MAOK de dimensão 100). Ou seja, utilizou-se a hipótese de existirem no máximo 100 grupos de carga semelhantes no conjunto de dados do treinamento com 181 perfis de carga (formando uma matriz de dados 181×96).

A vizinhança do neurônio é um ponto importante na definição da rede. No início, o conjunto de vizinhos é extenso e não muito bem definido. A melhor auto-organização ocorre quando o conjunto de vizinhos começa extenso e diminui com as iterações durante o treinamento.

Foi usada uma taxa de aprendizagem no qual iniciava-se com o valor 0,5 e conforme as iterações se seguiam, esta era alterada para $\square_{t+1} = (1/t)\square_t$.

Primeiramente foi feito um agrupamento dos perfis de carga e avaliação da coerência da metodologia utilizada (SOM-unidimensional) com os tipos de cargas existentes durante a semana (sábados, domingos, segundas-feiras, dias de semana e feriados). A Figura 3 mostra as curvas de carga de 15 em 15 minutos de maio de 2002 do IQ/UGF.

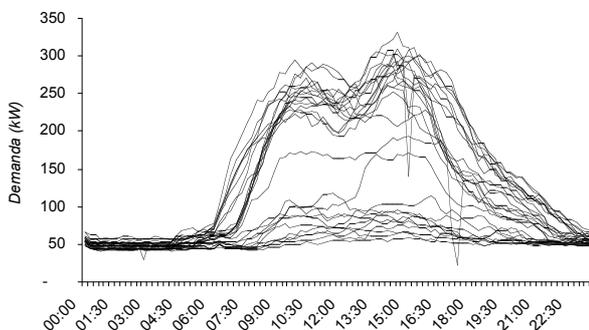


FIGURA 4 – DEMANDA ATIVA - IQ/UGF – FEV/2002

Com um mapa unidimensional de dimensão igual a 15 (número máximo de padrões) foram determinados 13 grupos, agrupados segundo a Tabela 1 e Figura 5, a seguir.

TABELA 1 – AGRUPAMENTO DAS CURVAS DE CARGA DE FEVEREIRO DE 2002 – IQ/UGF

Grupo	Dia da semana	Observação
1	Dom(3)	Domingo
2	Ter(12), Dom(17)	Vestibular(17), carnaval
3	Seg(18)	Vestibular(18)
4	Qui(14), Sex(8,15)	Antes e pós-carnaval
6	Seg(4), Ter(5), Qua(6), Qui(7), Sex(1)	1ª. semana
7	Seg(25), Sex(22)	3ª. e 4ª. semana
8	Ter(19,26), Qui(28)	3ª. e 4ª. Semana
9	Qua(20,27), Qui(21)	3ª. e 4ª. Semana
11	Qua(13)	Carnaval
12	Sab(23)	Sábado
13	Seg(11), Sab(2,16)	Sábado, carnaval
14	Sab(9)	Sábado
15	Dom(10,24)	Domingo

Obs.: 2000 iterações; alfa = 0,9; raio viz. = 6 (inicial)

A Tabela 1 e a Figura 5 mostram o agrupamento realizado pelo MAOK. Observa-se a formação de 13 grupos. Nota-se uma clara separação dos dias da semana. O dia 13/fev, uma quarta-feira, e o dia 11/fev, uma segunda-feira, foram agrupados nos grupos que representam o "sábado". Estes perfis ocorrem durante o carnaval. De maneira análoga isto acontece no "domingo".

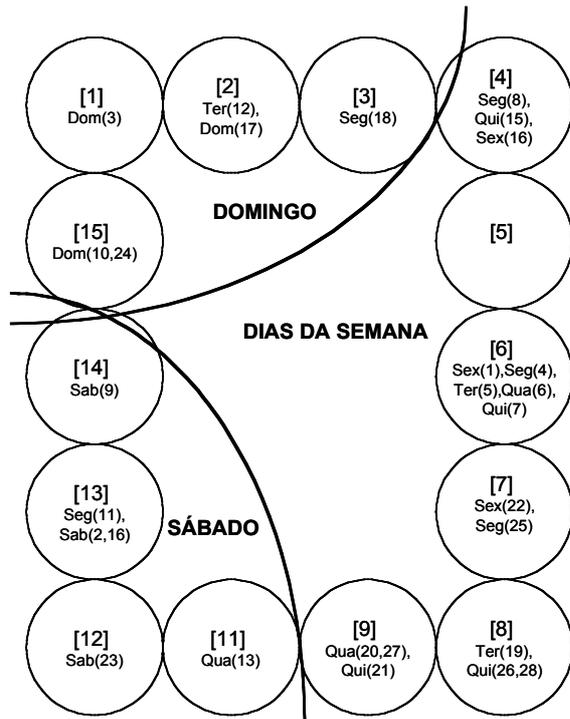


FIGURA 5 – REPRESENTAÇÃO GRÁFICA DO AGRUPAMENTO DAS CURVAS DE CARGA DE FEVEREIRO DE 2002 – IQ/UFG

Mesmo que os grupos 12, 13, e 14 representem o sábado, os perfis destes sábados não são exatamente os mesmos, como mostra a Figura 6 abaixo.

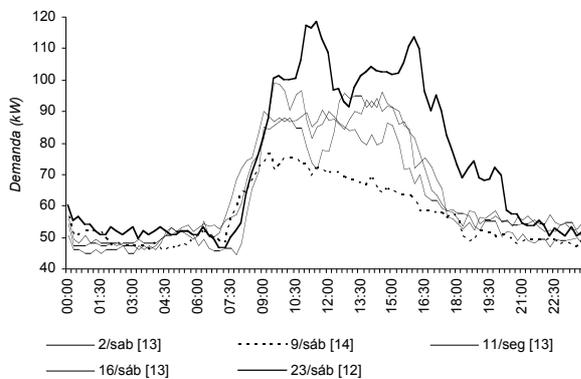


FIGURA 6 – GRUPOS 12, 13 E 14 - CURVAS DE CARGA DE FEVEREIRO DE 2002 – IQ/UFG

Estas diferenças são razoavelmente absorvidas pelo MAOK e separadas entre si, sendo agrupadas em grupos vizinhos.

Da Tabela 1, pode-se ainda observar a separação das curvas da primeira semana de fevereiro, das curvas da terceira e quarta semana do mês, apontando as diferenças das curvas de carga segundo a sazonalidade das mesmas em cada período do ano.

Um outro agrupamento pode ser realizado utilizando-se os dados históricos de um período de 6 meses (fevereiro a julho). Limitou-se o número de grupos a 20 durante o processo de treinamento.

O MAOK gerou 16 grupos. A Tabela 2 abaixo, apresenta o grau de pertinência dos dias da semana segundo o grupo.

TABELA 2 – GRAU DE PERTINÊNCIA DOS DIAS DA SEMANA POR GRUPO

Grupo	Dom	Seg	Ter	Qua	Qui	Sex	Sáb
1	0%	0%	50%	0%	0%	50%	0%
3	0%	25%	18%	33%	18%	8%	0%
4	0%	18%	32%	11%	25%	14%	0%
5	0%	25%	0%	0%	25%	50%	0%
7	0%	0%	0%	0%	0%	100%	0%
8	0%	50%	0%	25%	0%	25%	0%
9	0%	0%	100%	0%	0%	0%	0%
10	0%	33%	33%	0%	33%	0%	0%
11	0%	0%	0%	0%	0%	100%	0%
12	0%	0%	0%	0%	0%	0%	100%
13	46%	2%	2%	2%	2%	4%	43%
14	50%	0%	0%	0%	0%	0%	50%
16	0%	0%	0%	50%	0%	50%	0%
17	0%	33%	0%	33%	33%	0%	0%
19	0%	0%	0%	0%	100%	0%	0%
20	0%	17%	20%	17%	20%	27%	0%

Observa-se que os grupos 12, 13 e 14 contêm sábados e os grupos 13 e 14 representam os domingos. As segunda-feiras são melhor representadas nos grupos 3, 4, 5, 8, 10, 17 e 20. Outro fator interessante é a concentração das terças-feiras nos grupos 1 a 10 e 20.

Outra análise pode ser realizada com os mesmos resultados, avaliando-se o grau de pertinências das curvas segundo o mês de ocorrência da mesma, conforme apresentado na Tabela 3.

As curvas dos grupos 3 e 4 (dias da semana) concentram-se nos meses de fevereiro a abril. O grupo 20 representa as curvas dos dias da semana nos meses de junho e julho.

Desta forma podemos determinar curvas típicas de consumo da instalação em períodos do ano, ou mesmo detectar anomalias das curvas que não se adaptam a grupo específico.

Um estudo mais apurado das correlações das curvas de carga com variáveis climáticas como temperatura, nebulosidade e pluviosidade, poderiam classificar de maneira mais adequada os perfis de demanda da instalação.

A última coluna da Tabela 3 apresenta o número de curvas de carga por grupo. Analisando os dados da Tabela 2 e 3 conjuntamente, notamos que os grupos 3 e 4 representam os dias da semana de fevereiro a maio. O grupo 20 representa os dias da semana de junho e julho, enquanto o grupo 13 representa os finais de semana de fevereiro a julho. Estes grupos reunidos perfazem um total de 84% dos perfis de carga, sendo estes os mais representativos do conjunto.

TABELA 3 – GRAU DE PERTINÊNCIA DOS MESES POR GRUPO

Grupo	Fev	Mar	Abr	Mai	Jun	Jul	Tot
1	0%	0%	50%	50%	0%	0%	2
3	20%	33%	25%	15%	5%	3%	40
4	21%	14%	18%	25%	14%	7%	28
5	50%	25%	0%	0%	25%	0%	4
7	0%	0%	0%	100%	0%	0%	1
8	25%	0%	25%	0%	0%	50%	4
9	0%	0%	0%	0%	0%	100%	1
10	0%	0%	0%	0%	0%	100%	3
11	0%	0%	0%	0%	0%	100%	2
12	50%	50%	0%	0%	0%	0%	2
13	17%	19%	15%	20%	19%	11%	54
14	0%	0%	0%	0%	0%	100%	2
16	25%	0%	0%	25%	50%	0%	4
17	0%	0%	0%	0%	33%	67%	3
19	0%	100%	0%	0%	0%	0%	1
20	0%	3%	17%	13%	33%	33%	30

6.0 - CONCLUSÃO

Este trabalho apresentou uma metodologia para o estudo do perfil de consumo de energia elétrica de um consumidor.

Os resultados mostram a robustez do modelo e a facilidade de sua implantação em sistemas de gerenciamento energético, bem como, em um sistema de apoio à gestão energética.

Dentre as utilizações de um modelo de agrupamento, podemos destacar:

- Suporte à contratação de energia elétrica;
- Subsídios à programas de conservação de energia;
- Gerenciamento de cargas;
- Sistema de alarmes para gerenciamento de cargas;
- Detecção de interrupções e perfis anômalos;
- Previsão de consumo de energia elétrica;
- Identificação de hábitos de consumo através de técnicas não-intrusivas;
- Identificação de correlação de variáveis climáticas com os perfis de consumo.

A desvantagem do modelo é a necessidade de calibração dos parâmetros do MAOK. Outras arquiteturas do MAOK estão sendo testadas, além de uma metodologia de rotulação dos grupos mais abrangente e consistida, ou seja, identificar os padrões de carga e suas relações com outros dados, como clima, datas, ocorrências, entre outras.

7.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) J. SCHURMANN, "Pattern Classification – A unified view of statistical and neural approaches". Wiley-Interscience. 372 p. 1995.
- (2) W. S. LIMA, "Previsão de Carga no Período de Demanda de Ponta Utilizando Redes Neurais Artificiais". Dissertação de mestrado. UNICAMP. 144p., Campinas, SP. Agosto de 1996.
- (3) S. HAYKIN, "Neural Networks A Comprehensive Foundation", 2nd. Edição, Prentice Hall, 1999.
- (4) T. KOHONEN, "Self-Organized Formation of Topologically Correct Feature Maps". Biological Cybernetics, 43, pp. 59-69, 1982.
- (5) L. B. DOS REIS, et al. "Energia elétrica para o desenvolvimento sustentável". 1. ed. São Paulo: EDUSP, 2000. 284 p.
- (6) Y. Y. HSU, C. C. YANG, "Design of Neural Networks for Short-Term Load Forecasting. Part I: Self-Organising Feature Maps for Day Type Identification". IEE Proceedings-C, vol.138, no.05, pp. 407-413. Set/91.
- (7) 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.
- (8) W. S. LIMA, T. OHISHI, L. N. DE CASTRO, "Mapas Auto-Organizáveis Não-Paramétricos Para Análise da Influência Climática em Curvas de Carga". XV SNPTEE – Seminário Nacional de Produção e Transmissão de Energia Elétrica. Anais em CD-ROM, Foz do Iguaçu, Paraná. 1999.
- (9) 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.
- (10) D. Z. MARQUES, "Mineração de Dados Aplicada à Análise de Curvas de Carga". Texto para qualificação de mestrado. 78 p. 2002. Escola de Engenharia Elétrica. Universidade Federal de Goiás. Goiânia – GO.

AGRADECIMENTOS

Agradecemos a CELG pelo suporte financeiro dado ao projeto, no âmbito do Programa de Pesquisa e Desenvolvimento Ciclo 2000/2001 da empresa, e à Fundação de Apoio à Pesquisa da UFG (FUNAPE).