



**XXI SNTPEE  
SEMINÁRIO NACIONAL  
DE PRODUÇÃO E  
TRANSMISSÃO DE  
ENERGIA ELÉTRICA**

Versão 1.0  
23 a 26 de Outubro de 2011  
Florianópolis - SC

**GRUPO - GOP**

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

**UMA ABORDAGEM RÁPIDA E EFICIENTE PARA PREVISÃO DE CARGA POR BARRAMENTO**

**Ricardo Menezes Salgado(\*)**  
Unifal-MG

**Takaaki Ohishi**  
Unicamp

**Rosangela Ballini**  
Unicamp

**RESUMO**

Este artigo apresenta uma abordagem rápida e eficiente para resolver o problema de previsão de carga por barramento. O modelo proposto utiliza um algoritmo de agrupamento para criar grupos de barramentos com comportamentos similares e então realiza a previsão para cada grupo. Esta metodologia foi aplicada em um sistema elétrico com 73 barramentos pertencentes à região nordeste do Brasil. Os resultados foram medidos em termos de erro percentual médio no qual o modelo proposto encontrou erros na ordem de 2% a 3%, estando de acordo com a faixa de segurança adotada no setor elétrico brasileiro.

**PALAVRAS-CHAVE**

Previsão de Carga por Barramento, Previsão de Carga, Planejamento da Operação, Planejamento Energético, Inteligência Artificial.

**1.0 - INTRODUÇÃO**

O conceito de demanda por barramento, como também a sua principal aplicação estão relacionados com os sistemas de transmissão e de distribuição de energia elétrica. Estes sistemas podem ser modelados como grafos, levando em consideração algumas restrições específicas, e como são constituídos de ramos e nós, respeitam as leis básicas de um grafo, como, por exemplo, o balanço de fluxos (1). Os ramos incluem as linhas de transmissão, os diversos tipos de transformadores e dispositivos de controle. Os nós, denominados de barramentos, são as interligações destes ramos e podem ser classificados em barramentos de geração, interligados aos geradores (usinas); barramentos de interligação, que só realizam conexões entre ramos oriundos de barramentos vizinhos; e barramentos de carga, a cada um dos quais está conectado um conjunto de consumidores. O comportamento do consumo de energia elétrica por barramento é bastante diversificado, pois há barramentos que atendem milhares de consumidores residenciais e comerciais e há outros barramentos que atendem um único grande consumidor. Em função disso, as séries temporais que representam os seus históricos de consumo são muito diferentes, tanto em nível como em perfil de consumo, e apresentam uma maior variação (desvio padrão) em relação à demanda global, pois o consumo em cada nó depende de um número menor de consumidores.

A principal aplicação das previsões de carga por barramento são os estudos relacionados com os sistemas de transmissão e de distribuição de energia elétrica (2). Em qualquer estudo nesta área um dado necessário é uma estimativa do consumo por barramento, pois o nível de consumo em um dado ponto influencia os fluxos nas linhas a ele interligado; para um barramento de alto consumo, os fluxos em seu torno tendem a serem maiores do que em outro de menor consumo. Por isso é importante uma boa estimativa da distribuição da carga na rede, pois do contrário as análises podem distorcer muito a operação do sistema, podendo levar a uma operação menos eficiente e até a problemas de segurança operativa.

A energia elétrica no Brasil é produzida na sua grande parte distante dos centros de consumo e por isso precisa de um extenso sistema de transmissão e distribuição de energia elétrica para interligar os consumidores com as fontes de produção. Além de constituir um sistema de escoamento da produção de energia elétrica, o sistema de transmissão brasileiro tem também uma outra importante função no aproveitamento da diversidade hidrológica

(\*) Instituto de Ciências Exatas, Rua Gabriel Monteiro da Silva, n° 700  
Sala 309 – Bloco D – CEP 37.130-000 Alfenas, MG – Brasil  
Tel: (+55 35) 3299-1388 – Fax: (+55 35) 3299-1383 – Email: [ricardomenezes@ieee.org](mailto:ricardomenezes@ieee.org)

brasileira, possibilitando gerar em regiões hidrologicamente favoráveis e atender mercados em outras regiões com condições menos favoráveis (3) e (4). Porém, a introdução de um sistema de transmissão de grande porte acrescenta uma grande complexidade desde o seu planejamento até a operação em tempo real do sistema. Boa parte das interrupções no fornecimento de energia elétrica é consequência de problemas operacionais dos sistemas de transmissão e de distribuição, tais como falhas em equipamentos (2).

Para minimizar estes casos são realizados estudos da operação dos sistemas elétricos desde a fase de análise de expansões, tanto no sistema de geração como no de transmissão, pois estas decisões devem assegurar uma operação segura para as condições futuras previstas. Porém, é na operação de curto prazo, incluindo as etapas de programação da operação que considera a operação do sistema alguns dias à frente, até a operação em tempo real do sistema, que os estudos elétricos passam a ter uma grande importância (1) e (2). À medida que se aproxima da operação faz-se necessário um detalhamento da operação do sistema para assegurar o atendimento dos requisitos operativos e de segurança, que são os grandes focos da operação em tempo real do sistema. Nesta área são utilizados modelos detalhados da rede elétrica, tais como os modelos de Fluxo de Carga AC e DC, Fluxo de Potência Ótimo, Análises de Segurança, Análises de Estabilidade e outros, que analisam diferentes aspectos da operação da rede e são ferramentas de apoio a muitas decisões operativas (5), (6) e (2). Em termos de detalhamento, chega-se ao nível de equipamentos, como por exemplo a decisão sobre a escala de partidas e paradas de unidades geradoras (conjunto turbina/gerador) nas unidades de produção de energia elétrica e decisões sobre manobras no sistema de transmissão ao longo das próximas 24 horas. Por se tratar de decisões de curto prazo, a urgência nas decisões é grande e isto obriga que as análises sejam efetuadas em alguns pontos operativos específicos, como as cargas máximas, médias e mínimas por barramento. Enfim, a carga por barramento é uma componente essencial dos estudos elétricos em sistemas de energia elétrica (1), (5) e (6).

Do ponto de vista da previsão, a carga de um dado barramento pode ser tratada como uma série histórica similares às séries de demandas globais, e assim pode ser estimada de forma similar à previsão de carga global. Nesta perspectiva cada ponto deverá ter o seu modelo de previsão, que poderiam se basear na vasta experiência acumulada na área de previsão global, incluindo os modelos estatísticos (12), de redes neurais artificiais (10) e (13), em *neurofuzzy* (11), *SVMs* (14), e assim por diante. Porém, há ainda dois aspectos importantes que o diferenciam de uma previsão global, que é o número de barramentos e as especificidades de cada um destes. Em relação às especificidades dos barramentos, como cada nó atende um número menor de consumidores, a influência da demanda de cada consumidor tende a ser maior na demanda por barramento. Isto faz com que a série temporal apresente uma variância maior do que as séries de demandas globais. Além disso, em determinados casos pode haver um consumidor que é responsável por parte significativa da demanda local, fazendo com que o seu comportamento influencie na previsão de sua demanda.

Há outros casos associado com manobras de rede, que podem resultar em uma “transferência” de parte da demanda de um barramento para outro (2), (5) e (6). Neste último caso, a demanda do nó fica dependendo também da configuração da rede. As especificidades dos barramentos são em geral importantes no cálculo de suas previsões e nesse sentido é interessante que também sejam incorporados nos modelos de previsão. Em relação ao número de barramentos de carga, no caso brasileiro no Sistema Interligado Nacional este número está em torno de 5000 barramentos. Então, supondo-se apenas um modelo de previsão por barramento, tem-se aí algo em torno de 5000 modelos de previsão. Como o tempo é curto, torna-se difícil analisar o resultado de todos os modelos; torna-se também custoso a sua manutenção, como retreinamentos periódicos e avaliação de seu desempenho (6). A conclusão aqui é de que na previsão por barramento, além dos modelos de previsão, é importante outros aspectos como um sistema de suporte à previsão e sistema de consistência de dados, para facilitar todo o processo desde a aquisição e tratamento de dados, a fase de previsão e a fase de análise de resultados.

Dentro desta ótica, este artigo apresenta uma metodologia de previsão de carga de curto prazo por barramento baseado em técnicas de agrupamento e em modelos de previsão. A idéia inicialmente é utilizar técnicas de agrupamento para identificar barramentos com perfis de consumo diário similares e para cada um desses grupos implementar um modelo de previsão que calcula individualmente a previsão de cada barra do grupo.

## 2.0 - METODOLOGIA DE PREVISAO DE CARGA DE CURTO PRAZO POR BARRAMENTO

A metodologia proposta neste trabalho tem por objetivo utilizar um número menor de modelos de previsão, reduzindo com isso o tempo computacional para o cálculo das previsões, facilitando o gerenciamento de modelos em termos de suas atualizações e análises de desempenho. O processo de previsão é dividido em duas etapas. Na primeira, denominada de **Fase de Agrupamento**, os barramentos são classificados em grupos que apresentam similaridades no perfil de consumo diário. Na segunda etapa, denominada de **Fase de Previsão**, são implementados os modelos de previsão de carga, sendo um único previsor para cada grupo de barramentos. A idéia de utilizar um modelo por grupo objetiva de um lado diminuir o número de modelos, e ao mesmo tempo preservar as especificidades de cada barramento.

### 2.1 Fase de Agrupamento

Existem várias técnicas de agrupamento, tais como os baseados em redes neurais (Kohonen) (7), em *fuzzy c-means* (FCM) (8), entre outras. Neste artigo foi utilizado o algoritmo *subtractive clustering* (9), pelo fato deste

método determinar automaticamente o número de grupos em um conjunto de dados inicialmente desconhecido. Como o objetivo desta etapa é identificar os barramentos com perfis de consumo diário similares, independente do nível de consumo, inicialmente as curvas de carga são normalizadas, como no exemplo mostrado na Figura 1. Observa-se que as curvas originais são muito diferentes em termos de consumo médio (Figura 1.a), mas após a sua normalização, verifica-se que estas apresentam perfis de consumo diário muito similares (Figura 1.b).




FIGURA 1 – Motivação Normalização dos Barramentos.

## 2.2 Fase de Previsão

Nesta etapa é configurado o modelo de previsão para cada grupo obtido na fase anterior. Neste artigo estes modelos foram baseados em redes neurais artificiais tipo *MLP* (10), mas outras técnicas poderiam ser utilizadas tais como os modelos baseados em *neurofuzzy* (11), auto-regressivas (12) ou *SVMs* (14), por exemplo. A idéia proposta é trabalhar com menos modelos, mas preservar ao mesmo tempo as características específicas de cada barramento no grupo. Para isso, desde a escolha das variáveis de entrada até a estrutura são baseadas em informações individuais dos barramentos. Embora o modelo seja um único para todos os elementos do grupo, a sua estrutura mantém as informações específicas de cada barramento.

### 2.2.1 Definição das Variáveis de Entrada

Para ilustrar o processo de definição de um modelo, um exemplo simples baseado em dois barramentos será apresentado. Seja um grupo formado por dois barramentos #40 e #33. Se cada um desses barramentos fosse tratado via um modelo de previsão específico, o primeiro passo seria a seleção das entradas de cada um dos modelos. Suponha, por exemplo, que estas sejam selecionadas baseadas em análises de autocorrelação parcial, e que neste caso específico as entradas selecionadas para o barramento #40 fossem as cargas de intervalos de tempo anteriores,  $D_{40}(t-1)$  e  $D_{40}(t-24)$ , e para o barramento #33 a entrada fosse  $D_{33}(t-1)$ . Em geral, devido a característica de cada barramento, o número de entradas por barra não é o mesmo.

### 2.2.2 Arquitetura do Modelo

Para manter a especificidade de cada elemento, o modelo proposto utiliza uma estrutura que preserva as entradas selecionadas para cada elemento do grupo. No caso do exemplo, o modelo proposto terá três entradas, como especificado na Figura 2. Neste modelo, as duas primeiras entradas são reservadas exclusivamente para o barramento #40 e a última representa o barramento #33. Com isso, as particularidades em termos de entradas de cada barramento são preservadas.




FIGURA 2 – Exemplo de Arquitetura do Modelo Proposto.

### 2.2.3 Fase de Treinamento do Previsor

O modelo apresentado anteriormente tem um processo de treinamento específico. Usualmente, a cada passo do processo de treinamento, um conjunto de dados de entrada são apresentados ao modelo e a partir de um processo recursivo os parâmetros do modelo são atualizados. No modelo proposto, o processo de treinamento individual que leva em consideração a informação de cada barra é mantido. Ou seja, a cada passo do treinamento, são apresentadas as entradas de um barramento em particular. Por exemplo, a Figura 3 mostra o processo de treinamento quando são apresentadas ao modelo as entradas relativas ao barramento #40. Note que somente as entradas relativas a esse barramento foram ativadas. Já a Figura 4 mostra o processo de treinamento para os dados do elemento #33, quando somente as duas últimas entradas são consideradas. Esse processo de treinamento preserva o treinamento individual, que será importante no processo de previsão propriamente dito.




FIGURA 3 – Processo de Treinamento Barramento #40.




FIGURA 4 – Processo de Treinamento Barramento #33.

### 3.0 - ESTUDO DE CASO

Para validar o modelo proposto foi utilizado um conjunto dados reais de 73 barramentos localizados no sistema elétrico do Nordeste do Brasil. Neste conjunto, as medições de carga, em base horária, foram coletadas no período de 06 de junho a 03 de outubro de 2001 (período do racionamento de energia), totalizando 125 dias com 3000 horas de medição em cada um dos barramentos. No sistema em análise, os barramentos possuem tensões variando entre 38 a 230KV. *Infelizmente, as informações de localização geográfica dos barramentos não foram disponibilizadas, o que inviabilizou o acesso e consequentemente a utilização de variáveis climáticas nas simulações de previsão.* Devido a esta indisponibilidade de informações, os estudos de previsão apresentados neste trabalho utilizarão exclusivamente as medições de carga horária, sendo esta a principal fonte de informações para as simulações realizadas ao longo do trabalho.

#### 3.1 Agrupamento

O conjunto de 73 barramentos foi classificado através do método *subtract clustering*, o qual gerou 34 grupos, dos quais 14 grupos foram formados com dois ou mais elementos. Muitos barramentos foram classificados isoladamente em grupos com um único elemento, pois não se identificou outros elementos com perfis de consumo diário similares. A Tabela 1 mostra os 14 grupos com vários barramentos obtidos pelo algoritmo. Pelos resultados pode-se perceber que os grupos com dois ou mais barramentos totalizaram 88.3% da carga neste dia. Para os barramentos que apresentaram perfis específicos, isto é não foram agrupados, é recomendada a utilização de um modelo de previsão diferenciado.

Tabela 1 – Grupos de Barramentos

| Grupo | Número de Barras | Carga Total | Carga (%) | Desvio Padrão (PU) |
|-------|------------------|-------------|-----------|--------------------|
| 1     | 2                | 3,75        | 0,04%     | 0,0041             |
| 2     | 2                | 218,76      | 2,42%     | 0,0074             |
| 3     | 2                | 170,37      | 1,89%     | 0,0064             |
| 4     | 2                | 31,80       | 0,35%     | 0,0055             |
| 5     | 2                | 82,89       | 0,92%     | 0,0063             |
| 6     | 2                | 221,93      | 2,46%     | 0,0091             |
| 7     | 3                | 68,46       | 0,76%     | 0,0059             |
| 8     | 3                | 54,29       | 0,60%     | 0,0088             |
| 9     | 3                | 431,87      | 4,79%     | 0,0088             |
| 10    | 4                | 278,82      | 3,09%     | 0,0070             |
| 11    | 5                | 399,39      | 4,43%     | 0,0061             |
| 12    | 5                | 145,66      | 1,61%     | 0,0058             |
| 13    | 7                | 877,80      | 9,73%     | 0,0077             |
| 14    | 11               | 4983,44     | 55,22%    | 0,0043             |

Na Figura 5, é possível observar alguns dos 14 grupos mostrados na Tabela 1. Pode-se perceber que o padrão de carga dos grupos é heterogêneo, mostrando a variação de consumidores na região analisada. A diversidade nos padrões de carga comentada, no início deste artigo, podem ser vista nesta figura, na qual é possível compreender a necessidade de modelos efetivos para representar o comportamento de cada grupo de barramentos.

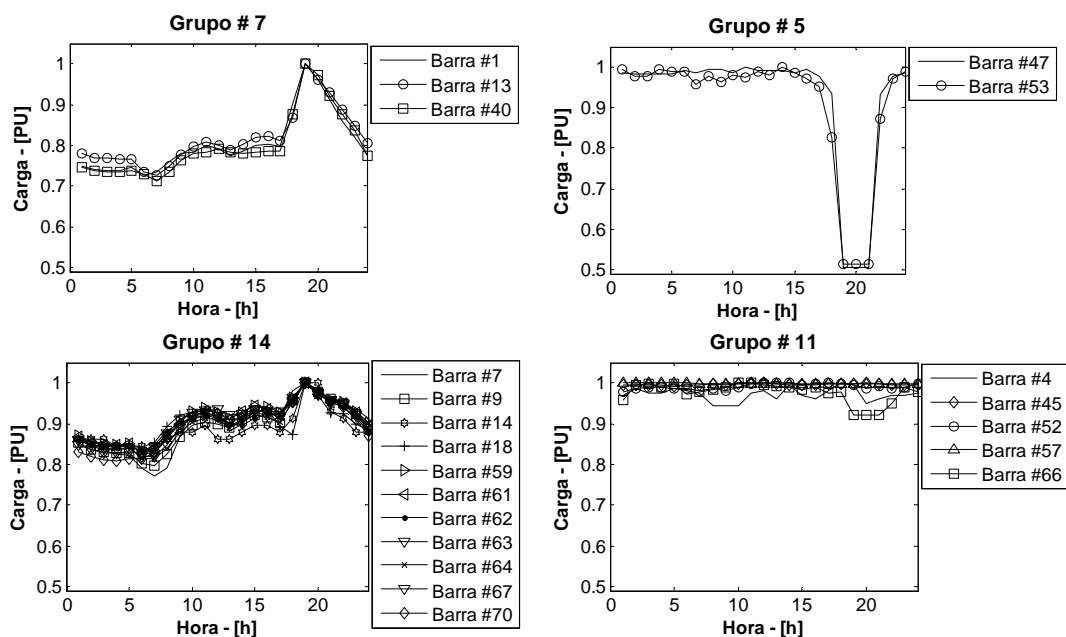


FIGURA 5 – Grupos com 2 ou mais Barramentos.

### 3.2 Previsão de Carga Por Barramento

Para obter uma medida de comparação e avaliar o desempenho do modelo proposto, aplicou-se um modelo convencional de previsão de carga global em cada um dos 73 barramentos, com isso foi possível avaliar a taxa de acertos bem como o nível de erro obtido pelo modelo proposto. Para facilitar a identificação os modelos foram chamados: **1- PG**: previsão global convencional aplicada isoladamente aos dados de cada barramento; **1- PB**: abordagem de previsão por barramento proposta neste trabalho.

Ambos os modelos (**PG e PB**) foram configurados para realizar a previsão das 24h da terça-feira dia 25 de setembro de 2001. Para determinar a curva do próximo dia os modelos foram ajustados hora-a-hora. A Tabela 2 mostra os resultados de previsão obtidos através dos modelos **PG e PB**. Observando os resultados é possível verificar que os modelos apresentaram desempenhos similares com baixa variação em seus erros, o que consequentemente ocasionou similaridade em nível de erro médio.

Tabela 2 – Erro Percentual Médio por Grupo.

| Grupo             | PG          | PB          |
|-------------------|-------------|-------------|
| 1                 | 3,67        | 3,83        |
| 2                 | 3,30        | 3,50        |
| 3                 | 3,67        | 3,77        |
| 4                 | 7,13        | 7,32        |
| 5                 | 1,87        | 1,90        |
| 6                 | 2,94        | 2,83        |
| 7                 | 3,96        | 3,70        |
| 8                 | 2,59        | 2,48        |
| 9                 | 1,97        | 1,89        |
| 10                | 2,36        | 2,34        |
| 11                | 3,42        | 3,91        |
| 12                | 3,59        | 3,68        |
| 13                | 4,59        | 2,96        |
| 14                | 3,26        | 3,45        |
| <b>Erro médio</b> | <b>3,45</b> | <b>3,40</b> |

A Figura 6 apresenta o erro percentual absoluto médio (MAPE), ao longo do dia 25/09/2001, para os barramentos dos grupos #8 e #14. De maneira pragmática, em relação ao grupo #8, é possível ver que a metodologia **PB** apresentou melhores resultados em todos os barramentos. Vale ressaltar que os resultados da metodologia **PB**, mesmo com maior nível de erro, não apresentaram grandes diferenças em relação ao modelo **PG**, mostrando que, na maioria dos casos mostrados, estas metodologias têm desempenho compatível se o critério analisado for o nível de erro. Observando os resultados do grupo #14, é possível verificar que a metodologia proposta obteve melhores níveis de erro em 8 dos 11 barramentos pertencentes a este grupo. Desta forma, para este estudo de previsão a

metodologia proposta se mostrou competitiva, provendo resultados de boa qualidade e, na maioria dos casos, superiores às demais abordagens avaliadas.




FIGURA 6 – Erro Percentual Médio (MAPE) Grupos #8 e #14.

Quando se tem uma abordagem de previsão, é importante verificar seu desempenho em barramentos que são fundamentais para o funcionamento do sistema elétrico. Em termos de nível de carga, um dos barramentos mais importantes do subsistema em análise é o barramento #59, que possui uma carga horária média de aproximadamente 1510.3MW. A Figura 7 apresenta as curvas de carga verificada e prevista para o barramento #59 no dia 25 de setembro de 2001. Observando a evolução das cargas, é possível verificar que as metodologias **PG** e **PB** apresentaram comportamento com alto grau de precisão e similaridade. Ainda na Figura 7 pode-se observar o erro do barramento #59 especificamente para as metodologias **PG** e **PB**. O nível de erro, neste caso, tem um comportamento comum seguido pelas metodologias levando em consideração a intensidade e a direção no erro. Em algumas horas por exemplo, 7 e 19, os modelos divergem bruscamente nas suas previsões. Entretanto, na maioria dos casos, os resultados dos modelos são extremamente similares e, conforme comentário descrito no parágrafo anterior, na média o nível de erro dos modelos são praticamente idênticos.




FIGURA 7 – Carga Verificada e Prevista Barramento #59 – 25/09/2001.

### 3.3 Comentários

O modelo proposto apresenta resultados altamente competitivos em relação um modelo global aplicado individualmente em cada barramento. Entretanto, o nível de erro apresentado no modelo **PB**, apesar de ser mais vantajoso em alguns casos, na média não apresenta grandes variações em relação ao modelo **PG**. O diferencial da

metodologia apresentada neste trabalho é o fato desta proporcionar a obtenção dos resultados em um tempo de processamento reduzido se comparado a aplicação do modelo **PG**. Nos estudos de previsão realizados anteriormente a metodologia **PB** foi aproximadamente 15 vezes mais rápida que a abordagem **PG**. A rapidez na obtenção de modelos de previsão rápidos e efetivos é uma necessidade real ajustados é verificada no caso brasileiro reportado pelo Operador do Nacional do Sistema. Esta necessidade é verificada pela diversidade de perfis, conforme mostrado na Figura 8 bem como na mudança de padrões conforme destacado na barra #47 no qual existe a real necessidade da atualização do modelo de previsão que deve ser treinado para este novo cenário.




FIGURA 8 – Perfis de Consumo e Mudança de Padrão.

#### 4.0 - CONCLUSÃO

A operação de um sistema elétrico é um processo extremamente complexo que exige um grande conjunto de ferramentas e modelos apropriados para realizar estudos e simulações que auxiliem a tomada de decisão. Como observado anteriormente, a previsão de carga por barramento é um insumo essencial na tomada de decisões de curto prazo em sistemas de energia elétrica. Neste sentido, este trabalho apresentou uma proposta para resolver o problema de previsão de carga por barramento.

O modelo proposto contém dois pontos a serem destacados: 1) apresentou robustez, boa capacidade de generalização e baixos erros na maioria dos barramentos, sendo eficaz para resolver o problema com um desempenho equivalente ou superior ao das abordagens convencionais de previsão de carga. 2) mostrou-se rápido em relação aos modelos convencionais de previsão de carga. Assim, com as características apresentadas (bons resultados, e rapidez), a técnica proposta surge como uma alternativa promissora para o tratamento do problema de previsão de carga por barramento no planejamento da operação de sistemas elétricos no Brasil.

De maneira geral, as contribuições deste trabalho trazem grandes avanços à área de previsão de carga por barramento. Entretanto, mesmo com os resultados promissores, acredita-se que este podem ser melhorados através da inclusão de variáveis climáticas e outras informações exógenas em relação aos barramentos. Perspectivas para futuras pesquisas, englobam testes exaustivos no modelo proposto, a aplicação desta técnica na previsão de horizontes diferentes (médio e longo prazo) ou outros tipos de dados (tais como: vazão e vento).

#### 4.1 Agradecimentos

Os autores agradecem a Fundação de Amparo à Pesquisa do Estado de São Paulo pelo financiamento concedido através dos processos #04-07879-9 e #02-06733-5. Os autores também agradecem a Eng<sup>a</sup>. Maria da Conceição Guedes Alcoforado (ONS/NE) pela concessão da base de dados de carga por barramento.

#### 5.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) R. L. Sullivan, *Power System Planning*. New York: McGraw-Hill Inc, 1977.
- (2) R. Billinton e R. N. Allan, *Reliability Evaluation of Power Systems*, 2nd ed. New York: Plenum, 1996.
- (3) L. Martinez e S. Soares, "Comparison between Closed-Loop and Partial Open-Loop Feedback Control Policies in Long Term Hydrothermal Scheduling", *IEEE Transactions on Power Systems*, Vol 17, No 2, 2002.

- (4) S. Soares e A. A. F. M. Carneiro, "Optimal Operation of Reservoirs for Electric Generation". IEEE Transactions on Power Delivery, vol. 6, n. 3, pp. 1101- 1107, 1991.
- (5) R. M. Salgado, R. Ballini e T. Ohishi, "An hybrid aggregate model applied to the short-term bus load forecasting problem" PowerTech, 2009 IEEE Bucharest , vol., no., pp.1-8, June 28 2009-July 2 2009
- (6) R. M. Salgado, R. Ballini, T. Ohishi, "An aggregate model applied to the short-term bus load forecasting problem," Power Systems Conference and Exposition, 2009. PSCE '09. IEEE/PES , vol., no., pp.1-8, 15-18 March 2009.
- (7) T. Kohonen, "Self-organized formation of topologically correct feature maps," Proceedings of the Biological Cybernetics, vol. 43, pp. 59–69, 1982.
- (8) J. Bezdek, Pattern Recognition with Fuzzy Objective Function Algorithms. New York: Plenum Press, 1981.
- (9) S. Chiu, "Fuzzy model identification based on cluster estimation," Journal of Intelligent & Fuzzy Systems, vol. 2, no. 3, Sept 1994.
- (10) D. Rumelhart, G. Hinton e R. Williams, Learning internal representation by error propagation, parallel distributed processing: Explorations in the Microstruture of Cognition, Vol. 1, MIT Press, Cambridge, 1986.
- (11) R. Ballini and F. Gomide, "Learning in recurrent, hybrid neurofuzzy networks," 10 th Inter International Conference on Fuzzy Systems, vol. 2, pp. 120–124, 2001.
- (12) G. Box, G. Jenkins, e G. Reinsel, Time Series Analysis: Forecasting and Control, 2nd ed. Holden Day, 1994.
- (13) K. Ho, Y. Hsu, e C. Yang, "Short-term load forecasting using a multi-layer neural network with an adaptative learning algorithm," IEEE Transactions on Power Systems, vol. 7, pp. 141–149, 1992.
- (14) R. M. Salgado, J. Pereira, T. Ohishi, R. Ballini, C. Lima, e F. VonZuben, "A hybrid ensemble model applied to the short-term load forecasting problem," Proceedings of the International Joint Conference on Neural Networks, pp. 4934–4941, July 2006.

## 6.0 - DADOS BIOGRÁFICOS



**Ricardo Menezes Salgado** é Bacharel em Matemática pela Universidade Federal de Viçosa (2002), mestre (2004) e doutor (2009) em Engenharia Elétrica pela Universidade Estadual de Campinas . Atualmente é professor da Universidade Federal de Alfenas, lotado no curso de Ciência da Computação. Atua na área inteligência computacional, sendo consultor e executor de diversos projetos em grandes corporações. Tem experiência como desenvolvedor de sistemas inteligentes de suporte a decisão (plataforma JAVASE) e em análise de dados com ênfase em séries temporais. Ao longo de sua carreira tem atuado principalmente nos seguintes temas: inteligência computacional, previsão de séries temporais, mineração de dados, otimização e reconhecimento de padrões aplicados em diversos setores.



**Takaaki Ohishi** possui graduação em Engenharia Elétrica pela Universidade de São Paulo (1978) e doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas (1990). Atualmente é Professor Livre Docente da Universidade Estadual de Campinas. Tem experiência na área de Engenharia Elétrica, com ênfase em Sistemas Elétricos de Potência. Atuando principalmente nos seguintes temas: Planejamento, Curto Prazo, Sistemas Hidrotérmicos.



**Rosangela Ballini** possui graduação em Bacharelado em Matemática pela Universidade Federal de São Carlos (1994), mestrado em Ciências da Computação e Matemática Computacional pela Universidade de São Paulo (1996) e doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas (2000). Atualmente é professora no Instituto de Economia da Universidade Estadual de Campinas. Tem experiência na área de quantitativa, com ênfase em Métodos e Modelos Matemáticos e Econométricos, atuando principalmente nos seguintes temas: previsão de séries temporais, redes neurais, sistemas nebulosos, redes neurais nebulosas.