

# ESTRATÉGIAS DE PREVISÃO DE CARGA E DE CONSUMO DE ENERGIA ELÉTRICA BASEADAS EM MODELOS ESTADÍSTICOS E REDES NEURAIS ARTIFICIAIS: UM ESTUDO DE CASO NAS CONCESSIONÁRIAS DE ENERGIA DO ESTADO DO PARÁ

GUILHERME A. B. CONDE<sup>1</sup>, ÁDAMO L. DE SANTANA<sup>1</sup>, CARLOS RENATO L. FRANCÊS<sup>1</sup>,

CLÁUDIO A. ROCHA<sup>2</sup>, LIVIANE REGO<sup>1</sup>, VANJA GATO<sup>3</sup>

<sup>1</sup>*Programa de Pós-Graduação em Engenharia Elétrica - Universidade Federal do Pará  
Campus Univ. do Guamá, Rua Augusto Córrea, 01 - 66075-110 - Belém - PA - Brasil  
E-mails: {conde, adamo, rfrances, liviane}@ufpa.br  
alex@bcc.unama.br, vanja.gato@redecelpa.com.br*

<sup>2</sup>*Centro de Ciências Exatas e Tecnologia - Universidade da Amazônia  
Av. Alcindo Cacela, 287 - 66060-902 - Belém - PA - Brasil*

<sup>3</sup>*Rede Celpa  
Av. Gov. Magalhães Barata, 209 - 66040-170 - Belém - PA - Brasil*

**Abstract**— One of the most desired aspects for power suppliers is the acquisition/sell of energy in a future time. This paper presents a study for power supply forecasting of the residential class, based on time series methods and neural networks, considering short and long term forecast, both of great importance for power suppliers in order to define the future power consumption of a given region.

**Keywords**— Neural networks, time series, power systems.

**Resumo**— Um dos pontos mais almeçados por concessionárias do setor elétrico é a capacidade de planejamento de aquisição/venda de energia elétrica em um tempo futuro. Este artigo apresenta um estudo para predição do consumo de energia elétrica da classe residencial, realizando um comparativo de qualidade para estimadores baseados em técnicas de séries temporais e redes neurais, considerando tanto uma análise em curto quanto em longo prazo. Ambas as abordagens são de grande importância para as concessionárias no sentido de definir qual o consumo de energia futuro de uma dada região.

**Palavras-chave**— Redes neurais, séries temporais, sistemas elétricos e de potência.

## 1 Introdução

A previsão de carga (via de regra, carga elétrica em MW) é uma estratégia primordial dos sistemas elétricos e é baseada nessa previsão que se planejam e operam esses sistemas de forma confiável e segura [Douglas et al 1998] [Senjyu et al 2002]. Tipicamente, em previsão de carga, pretende-se definir qual o consumo de energia futuro de uma dada região de modo, por exemplo, a projetar ou adequar o sistema elétrico para atender consumidores, quando determinadas demandas se concretizarem em um tempo futuro. Além disso, utilizando as estratégias de prospecções, como as propostas neste trabalho, as concessionárias de energia elétrica podem estimar de maneira satisfatória a compra de energia baseada na demanda futura e nas relações de preços apresentadas pelos fornecedores do Brasil, o que pode levar a uma economia financeira substancial, em função da diminuição da diferença entre a quantidade de energia comprada e consumida.

Em qualquer situação, a previsão de carga deve manipular dados históricos de cargas elétricas registrados em seus bancos de dados. Então, como entra-

da básica dos estudos tem-se os dados históricos de cargas, obtidos em intervalos de coleta convenientes.

O trabalho descrito neste artigo se originou a partir dos estudos propostos para o projeto de pesquisa e desenvolvimento “PREDICT - Ferramenta de Suporte à Decisão para Predição de Cargas de Sistemas Elétricos”, financiado pela “Agência Nacional de Energia Elétrica do Brasil - ANEEL” e que está em curso desde setembro de 2004. Este projeto, realizado em parceria com o governo de estado do Pará e a concessionária de energia elétrica do estado do Pará (CELPA), visa, basicamente, a projetar e implementar um sistema de suporte à decisão, utilizando métodos matemáticos e de inteligência computacional para prever as necessidades de compra de energia no mercado futuro e para realizar inferências sobre a situação do sistema elétrico.

O sistema de suporte à decisão Predict se baseia em duas abordagens: (a) Predição de consumo e carga, por meio de regressão e redes neurais artificiais (RNA); (b) correlação e análise de dependências, por meio de redes Bayesianas [Russel e Norvig 2003]. As abordagens de predição são o alvo deste artigo e serão detalhadas ao longo das próximas seções. As estratégias de correlação, sucintamente, são realizadas através do arranjo e pré-processamento dos da-

dos climáticos, sócio-econômicos e de consumo, disponibilizados pelo Instituto Nacional de Pesquisas Espaciais (INPE), Secretaria Executiva de Estado de Planejamento, Orçamento e Finanças (SEPOF) e CELPA, respectivamente; sendo então submetidos para a técnica de mineração de dados de redes bayesianas para a análise de dependências e correlações e posterior geração de conhecimento (Figura 1).

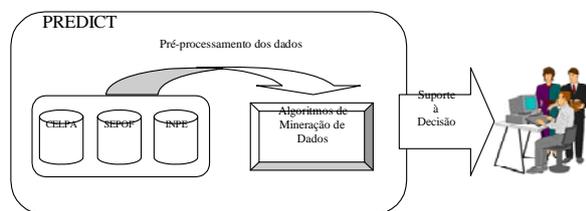


Figura 1. Modelo de correlação instituído.

Neste artigo são abordados como técnicas para predição os modelos de séries temporais por regressão e de RNAs. Os dados trabalhados aqui dizem respeito ao consumo de energia para a classe residencial, umas das classes componentes do consumo total de energia requerida (as outras classes componentes se referem aos consumos industrial, comercial, rural, bem como iluminação pública, entre outras). A classe de consumo residencial se destaca entre as demais por ter o comportamento mais difícil de se estudar e, conseqüentemente, prever; além de influenciar diretamente no comportamento das demais.

Este artigo está organizado da seguinte maneira: na seção 2, é abordada a utilização de métodos de regressão para predição de carga. Na seção 3, é apresentado o modelo de RNA utilizado e a definição dos seus parâmetros. Na seção 4, são explorados alguns resultados e comparativos obtidos com aplicação dos modelos utilizados neste trabalho e em trabalhos anteriores. Na seção 5, as considerações finais deste trabalho são apresentadas.

## 2 Modelo de séries temporais e regressão para a predição de carga

Nesta seção, é apresentado o modelo de regressão utilizado para análise dos dados. Esse modelo é aplicado com o intuito de verificar a tendência dos dados, examinando o comportamento passado para inferir sobre as instâncias futuras, possibilitando assim a realização de previsões.

Os dados utilizados no estudo deste trabalho são referentes ao consumo de energia da classe residencial. O estudo realizado se valeu do histórico de dados disponíveis de consumo de energia no período de janeiro de 1991 a dezembro de 2006. Como discutido em trabalhos anteriores [Rocha et al 2006], a série do consumo é tendenciosa e não-estacionária. A série ainda, estudando seus correlogramas, não atinge estacionariedade em sucessivas diferenciações.

Tendo sido verificado pelo comportamento dos dados que se trata de uma série “explosiva”, e que a mesma, dessa forma, não atingia estacionariedade, observando-a como um todo, utilizou-se uma nova abordagem, conforme a seguir. Seccionou-se a série única de dados, antes mensal, em doze séries anuais, correspondentes aos meses de janeiro a dezembro (Figura 2).

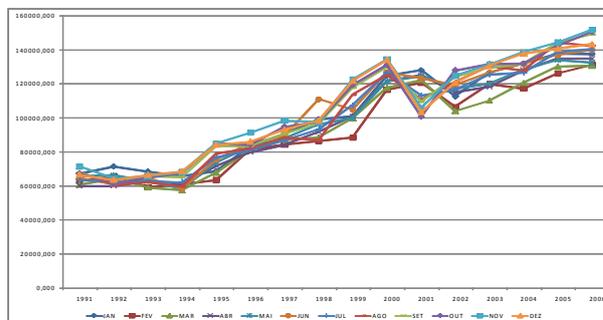


Figura 2. Histórico do consumo de energia residencial de 1991 a 2006.

O estimador estabelecido para realizar a predição dos valores futuros de consumo de energia se utiliza da análise de regressão múltipla (ver [Pindyck e Rubinfeld 1998], [Hair et al 1998], [Rice 1995]), sendo baseada na análise do valor do consumo obtido previamente e de dois termos adicionais. A fórmula geral do modelo de regressão múltipla, utilizada neste trabalho, pode ser especificada da seguinte forma:

$$Y_i = A_0 + A_1 X_{1i} + A_2 X_{2i} + \dots + A_k X_{ki} + u_i \quad (1)$$

O sistema geral de regressão múltipla por sua vez pode ser visto como um sistema matricial e representado da seguinte forma:

$$\begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_n \end{bmatrix} = \begin{bmatrix} 1 & X_{11} & X_{12} & \dots & X_{1k} \\ 1 & X_{21} & X_{22} & \dots & X_{2k} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ 1 & X_{n1} & X_{n2} & \dots & X_{nk} \end{bmatrix} \times \begin{bmatrix} A_0 \\ A_1 \\ \vdots \\ A_k \end{bmatrix} + \begin{bmatrix} u_0 \\ u_1 \\ \vdots \\ u_k \end{bmatrix} \quad (2)$$

Onde:

$Y$  é um vetor coluna, com dimensão  $n \times 1$  de observações ou registros da variável dependente ou variável-alvo  $Y$ ;

$X$  é uma matriz de ordem  $n \times k$ , ou seja,  $n$  observações e  $k$  variáveis, onde a primeira coluna representa o intercepto  $A_0$ ;

$A$  é um vetor coluna com  $k \times 1$  parâmetros desconhecidos;

$u$  é um vetor coluna com  $n \times 1$  perturbações.

Essa especificação objetiva gerar os valores dos parâmetros do vetor  $A$ . Para isto, emprega-se o método dos mínimos quadrados ordinários (MQO). Ele permite gerar estimativas para os coeficientes de tendência da regressão (parâmetros  $A$ ) com menor variância e não-viesados. O método de MQO consis-

te em minimizar a soma dos erros quadrados da regressão estimada.

Como fora apontado, a análise com a série de dados disposta mensalmente é não-estacionária, o que dificulta o seu estudo; razão que motiva a análise de forma anual, seccionando-a em doze séries. No entanto, ao se trabalhar com cada mês individualmente, é factível a perda de conhecimentos decorrentes de eventos ou situações exógenas ao comportamento padrão do sistema que tenham ocorrido no decorrer dos meses que se seguem até a próxima instância do mês analisado, e que por sua vez podem contribuir para a modificação do seu consumo no ano seguinte. Como exemplo de tais eventos, podem ser citadas as relações de perda ou aquisição de contratos pelas concessionárias de energia, projetos ou gestões governamentais, etc.

Desta forma, com o intuito de considerar na análise o impacto de tais eventos no decorrer do ano e assim obter um valor mais ajustável da predição, juntamente com o consumo anterior, foi adicionada uma variável quantificando a tendência anual de acordo com o comportamento apresentado ao seu decorrer. A variável incluída foi obtida por meio de uma análise fatorial (para uma visão mais completa sobre análise fatorial ver [Dillon et al 1984]), de modo a condensar as informações e tendências ocorridas no ano. A análise fatorial em si denota a redução de um conjunto de variáveis de um domínio para um modelo com alguns poucos fatores sempre tentando manter ao máximo a representatividade e relação entre as variáveis originais. A análise fatorial foi realizada sobre as doze séries anuais, obtendo-se na análise um único fator que melhor representa a série (em torno de 99,6%) e, por sua vez, o comportamento anual.

O segundo termo adicionado diz respeito à contenção do impacto exercido por anomalias existentes no histórico do consumo de energia residencial. Aqui abordamos o período anômalo no consumo de energia de junho de 2001 a fevereiro de 2002, caracterizado pela ocorrência da medida de racionamento de energia nacional [ANEEL 2003] e que atuou como um ponto de inflexão no crescimento do consumo de energia, causando, ao seu término, um desvio na tendência de crescimento. Desta forma, foi adicionada às séries mensais uma variável artificial binária para considerar a ocorrência do apagão, indicando a presença ou ausência de um valor impactado diretamente pela ocorrência do apagão, ou ainda que divirja da natureza do restante da série, atribuindo valores 1 ou 0, respectivamente. Não somente o período de vigência da medida de racionamento é trabalhado, mas também alguns meses que o seguiram até que a série voltasse à normalidade, persistindo em uma presença de queda no consumo de energia.

O modelo é aplicado primeiramente de modo a verificar a confiabilidade do estimador, utilizando parte da base de dados histórica existente (Jan/91 a

Dez/06) para teste. Assim, foram aplicados alguns testes em cima do modelo de regressão, para apenas posteriormente realizar a projeção do seu comportamento para os anos de 2007 e 2008.

Os resultados obtidos aqui pela aplicação do modelo de regressão, assim como a sua significância, serão analisados na seção 4.

### 3 Modelo de redes neurais artificiais

Diversos métodos de inteligência artificial têm sido empregados em problemas de previsão de consumo de energia elétrica, com diferentes níveis de sucesso. Entretanto, as RNAs têm sido muito aceitas como técnicas adotadas em sistemas de previsão [Hipper et al 2001],[Adya e Collopy 1998].

As RNAs utilizadas neste trabalho realizam a previsão do consumo de energia residencial, baseado nos registros históricos de consumo. Diversos tipos de arquitetura de RNAs têm sido empregadas em aplicações de previsão de séries temporais [Hipper et al 2001].

Para a construção do modelo de previsão é necessária a definição de três etapas principais: (a) identificação e definição da informação necessária para representar a série e o horizonte de previsão; (b) modelagem da RNA; (c) escolha do algoritmo de aprendizado da RNA capaz de aprender as características da série e realizar a previsão com sucesso.

#### 3.1 Seleção das Entradas

Durante o processo de identificação e definição das variáveis de entrada para o processo de previsão, a variável consumo residencial, que representa a energia requerida mensalmente, foi decomposta em doze séries uma para cada mês do ano, como já fora apontado na seção 2. Além da variável consumo residencial, foram utilizadas as variáveis data e a taxa de crescimento entre anos consecutivos.

Partindo dos estudos realizados na seção 2, empregou-se a técnica de “janelamento” sobre a variável consumo residencial para realizar a previsão com RNAs. Essa técnica consiste em usar seqüências de valores passados (janela de tempo) da variável sobre a qual se deseja realizar a previsão bem como o horizonte de previsão, ou seja, os valores a serem previstos. A Figura 3 ilustra as entradas e saídas selecionadas para modelar as camadas de entrada e saída das RNAs projetadas neste trabalho. Após diversos experimentos com diferentes seqüências dos valores passados da variável consumo, a janela de tempo que apresentou melhores resultados foi a de tamanho 4, ou seja, é passado para a RNA o valor do consumo atual e três valores históricos imediatamente anteriores.

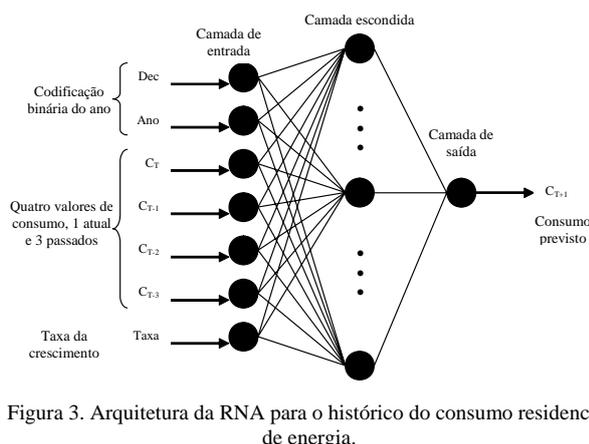


Figura 3. Arquitetura da RNA para o histórico do consumo residencial de energia.

### 3.2 Definição dos Parâmetros das RNAs

Selecionar uma arquitetura apropriada para o problema é o primeiro passo para um sistema de previsão baseado em RNAs. Neste trabalho se optou por utilizar a rede perceptron multicamada feedforward (MLP), com apenas uma camada escondida, devido ao seu amplo emprego em sistemas de previsão [Adya e Collopy 1998].

Nesta etapa do processo de modelagem da rede MLP, o número de neurônios da camada de entrada e saída foram fixados de acordo com a seleção das entradas e saídas descritas no item 3.1. Entretanto, o número de neurônios na camada escondida é determinado dinamicamente durante o processo de treinamento da rede MLP, como será descrito no item 3.3.

As séries históricas mensais foram tratadas de forma independente através da previsão multimodelo [Hipper et al 2001]. Neste tipo de modelo, a previsão de cada série mensal é realizada por uma rede MLP diferente. Desta forma, no final do treinamento, são geradas doze redes MLP.

### 3.3 Treinamento das Redes MLP

O algoritmo de treinamento escolhido para o aprendizado das redes MLP foi o *backpropagation* com algumas modificações para o ajuste dinâmico dos parâmetros de configuração.

Durante a etapa de treinamento da rede MLP, o número de neurônios da camada escondida, a taxa de aprendizado da camada escondida e a taxa de aprendizado da camada de saída são variadas repetidamente, entre um mínimo e máximo definidos pelo usuário. Para cada combinação desses parâmetros é criada uma rede MLP e aplicado separadamente o algoritmo de treinamento *backpropagation* adaptativo. Desta forma, é identificada a melhor combinação de parâmetros (melhor rede MLP) para o conjunto de dados utilizado, que, por sua vez, provêem os resultados com os menores erros de previsão obtidos durante o treinamento. Esse processo é repetido para cada uma das doze séries que representam os consumos mensais residenciais. Após a finalização do pro-

cesso de treinamento, cada série mensal possui a melhor rede MLP encontrada para realizar as previsões de consumo residencial daquele mês.

## 4 Avaliação dos resultados obtidos

A avaliação dos resultados obtidos com a aplicação dos métodos matemáticos e de inteligência computacional foi realizada considerando as duas técnicas empregadas para a previsão de carga: através do uso de métodos de regressão e através da aplicação de RNAs, conforme detalhado a seguir, apontando também um comparativo para a aplicação de ambas. As performances dos modelos serão avaliadas de acordo com o erro percentual médio absoluto (MAPE) (3).

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left( \frac{|y_i - \hat{y}_i|}{y_i} \right) \times 100\% \quad (3)$$

Onde  $N$  representa o número exemplos,  $y$  o valor histórico real e  $\hat{y}$  o valor estimado.

### 4.1 Previsão de Carga com o uso de Métodos de Regressão.

De posse do modelo apresentado foram realizados os estudos de prospecção para cada uma das doze séries, de modo a prever os valores de consumo de energia e, assim, permitindo a estimação em cada série dos valores de consumo de energia para um ponto futuro.

No teste realizado, usado posteriormente também como comparativo com o modelo de rede neural, foi aplicada a regressão utilizando apenas os valores referentes ao intervalo de 1991 até fim de 2004, realizando com base nos mesmos uma estimação dos seus valores para o ano de 2005 e 2006 (Figura 4).

O resultado obtido pela estimação apresentou um erro de aproximadamente 1,76%, valor doravante

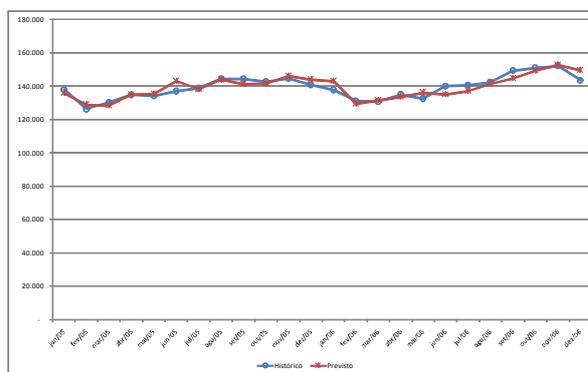


Figura 4. Valores reais e estimados de Jan/05 a Dez/06 do consumo de energia.

considerado não só aceitável, mas também inferior aos obtidos pelos métodos estatísticos utilizados pela concessionária de energia elétrica, os quais giram em torno 4,1%.

Uma vez verificada a efetividade do modelo de estimação baseado em regressão para a série de dados, foi feita uma projeção do seu comportamento para os anos de 2007 e 2008, como pode ser visto na Figura 5.

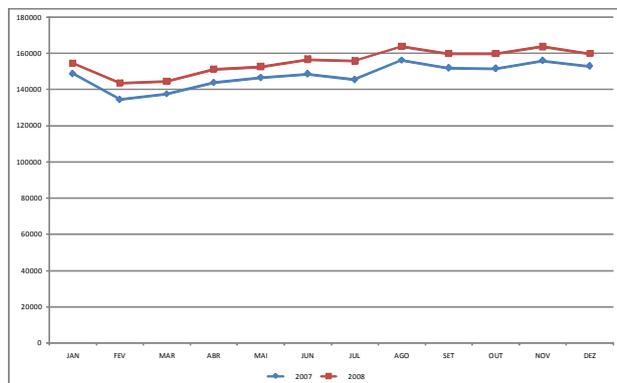


Figura 5. Valores previstos de consumo para os anos de 2007 e 2008.

A seguir serão mostrados os resultados de predição obtidos pelo modelo de redes neurais implementados, assim como um comparativo da qualidade dos resultados obtidos pelas técnicas, da mesma forma considerando as suas adequações aos aspectos de predição a curto e longo prazo.

#### 4.2 Previsão utilizando RNAs.

De acordo com os parâmetros definidos para as RNAs na seção 3, foram realizadas simulações para cada uma das doze séries, identificando e selecionando a melhor rede MLP para cada. As simulações foram realizadas com dois conjuntos de dados, como descrito a seguir.

Primeiramente as redes MLP utilizaram para os conjuntos de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2004 e para os conjuntos de teste os dados referentes a 2005. Após o processo de treinamento foi realizada a estimação dos valores de consumo para os anos de 2005 e 2006 (Figura 6).

Como pôde ser observado, o resultado obtido pela estimação apresentou um erro residual, de aproximadamente  $137 \times 10^{-3} \%$ , para o ano de 2005, apresentando também com isso, resultados bem superiores aos obtidos nos estudos previamente realizados [Rocha et al 2006], que denotaram erros em torno de 4,1%. No entanto, gerou um erro de 2,61% para o ano de 2006. Os valores apontaram dessa forma uma estimação precisa para o primeiro ano, mas que, no entanto, declinou para o segundo ano de previsão.

Ato contínuo, o modelo de rede neural foi novamente aplicado, agora tendo como conjuntos de treino os valores dos dados históricos referentes ao intervalo de 1991 até 2005 e para os conjuntos de teste os dados referentes a 2006. A estimação dos valores de consumo foi então realizada para os anos de 2006, 2007 e 2008 (Figura 7).

A estimação dos valores de consumo para 2006, como pode ser visto na Figura 7, também apresentou um erro residual, de aproximadamente  $142 \times 10^{-3} \%$ . Isso demonstrou uma tendência nos resultados gerados pela rede MLP, apresentando resultados bem ajustados para previsões em curto prazo, em períodos normalmente de seis meses a um ano. No entanto, ao estudar-se a previsão para períodos mais longos de tempo, os valores resultantes do modelo de estimação decaíram drasticamente, apresentando consigo valores anômalos (como pode ser verificado nas Figuras 6 e 7) de consumo após o primeiro ano de previsão; valores estes que contrariam o conhecimento dos especialistas no domínio, uma vez que a tendência na utilização de energia é aumentar de um ano para o outro, em estados que são considerados como “em expansão” (caso do estado do Pará).

Dessa forma, os resultados deste trabalho apontaram que as redes MLP utilizadas apresentam resultados excepcionais ao estudar-se um curto espaço de previsão (até um ano). Entretanto para as previsões com um intervalo maior, estipula-se como melhor solução o modelo de previsão baseado nas técnicas de regressão apresentados na seção 2, produzindo séries “bem comportadas” (Figura 5) mesmo ao inferir longos intervalos de tempo, apresentando também um bom ajustamento que, embora inferior ao obtido pelo modelo MLP, apresenta-se ainda bem abaixo do admissível pelas concessionárias.

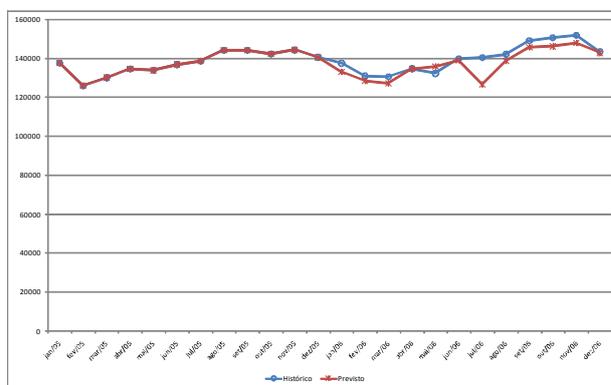


Figura 6. Valores reais e estimados de Jan/05 a Dez/06 do consumo residencial.

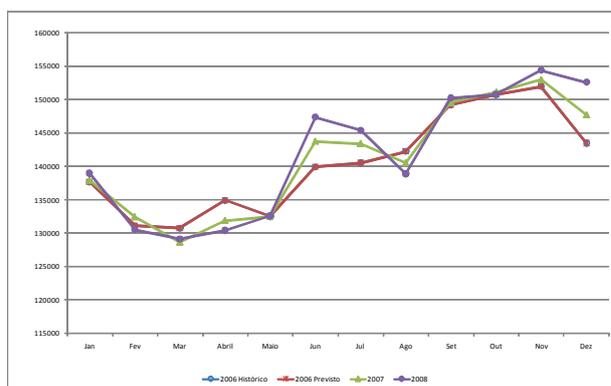


Figura 7. Valores previstos de consumo residencial para os anos de 2005 a 2008.

## 5 Considerações Finais

Neste trabalho foram aplicadas duas técnicas para a predição de carga em sistemas elétricos: através de métodos de regressão e por modelos de redes neurais. Nos testes realizados foi observada, para ambos estimadores, uma boa capacidade de ajustamento e predição, apresentando erros percentuais bem abaixo dos que são atualmente obtidos pelos métodos tradicionais empregados pelas concessionárias de energia elétrica, erro esse, cuja diminuição nas predições representa, evidentemente, uma considerável economia na compra de energia no mercado futuro.

Como aspecto diferencial, destaca-se também que, como pôde ser observado pelos resultados obtidos, o estimador baseado nos modelos neurais apresentou um desempenho excepcional para as previsões realizadas para um período de curto prazo (até um ano), obtendo um valor baixo de erro residual; mas que, no entanto, ao considerar-se a predição para períodos mais longos, produzem valores anômalos ao que se veicula o crescimento do consumo de energia elétrica e, com isso, erros gradativamente maiores; sendo neste caso o modelo de regressão uma melhor alternativa.

Com os modelos aqui apresentados, é possível disponibilizar um sistema de suporte à decisão para os gestores, tanto da concessionária de energia, que podem estabelecer contratos mais vantajosos de energia no mercado, quanto para os usuários de nível decisório dos órgãos de governo, em razão de poderem estabelecer políticas e investimentos para o desenvolvimento de determinada região do estado.

Diante desse panorama, a principal contribuição deste trabalho foi aplicar o processo de extração de padrões, com o objetivo de prever o consumo de energia residencial e, conseqüentemente, estabelecer contratos mais vantajosos de compra de energia no mercado futuro para as concessionárias de energia elétrica, bem como prover aos gestores de governo, em parceria com essas concessionárias, subsídios para a formulação de programas governamentais de inclusão social de acordo com as condições sócio-econômicas de determinada região, haja vista que a expansão do fornecimento de energia, principalmente em se tratando da região amazônica, que possui ainda muitas áreas sem energia firme, é fator preponderante de desenvolvimento.

Vale ressaltar que os modelos apresentados neste artigo são parte integrante do sistema de suporte à decisão denominado Predict [Rocha et al 2006], que está em produção nas Centrais Elétricas do Pará e que atualmente se encontra em fase de implantação nas demais concessionárias do Grupo Rede (Companhia de Energia Elétrica do Estado do Tocantins - CELTINS, Centrais Elétricas Matogrossenses S. A. - CEMAT, e Companhia Força e Luz do Oeste - CFLO - de Guarapuava, no Paraná).

## Agradecimentos

Os autores gostariam de agradecer aos financiadores do projeto que fundamenta este artigo: CAPES, CNPq, ANEEL e CELPA.

## Referências Bibliográficas

- Adya, M. e Collopy, F. (1998). "How Effective are Neural Networks at Forecasting and Prediction? A Review and Evaluation", In: *Journal of Forecasting*, vol. 17, pp. 481-495.
- ANEEL. (2003). "Atlas de energia elétrica do Brasil", Agência Nacional de Energia Elétrica, Brasília, DF.
- Dillon, W. R. e Goldstein, M. (1984). "Multivariate Analysis - Methods and Applications", John Wiley & Sons.
- Douglas, A.P., Breipohl, A.M., Lee, F.N. e Adapa, R. (1998). "The impacts of temperature forecast uncertainty on Bayesian loadforecasting". *IEEE Transactions on Power Systems*, vol. 13.
- Hair, J. F. JR., Anderson, R. E., Tatham, R. L. e Black, W. C. (1998). "Multivariate data analysis". Prentice-Hall.
- Hippert, H., Pedreira, C. e Souza, R. (2001). "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation", In: *IEEE Transactions on Power Systems*, vol. 16, no. 1, pp. 44-55.
- Pindyck, R. S. e Rubinfeld, D. L. (1998). "Econometric Models and Economic Forecasts". Irwin/McGraw-Hill.
- Rice, J. A. (1995). "Mathematical Statistics and Data Analysis". 2nd Edition, Duxbury Press.
- Rocha, C., Santana, Á. L., Francês, C. R., Rego, L., Costa, J., Gato, V. e Tupiassu, A. (2006). "Decision Support in Power Systems Based on Load Forecasting Models and Influence Analysis of Climatic and Socio-Economic Factors". *SPIE*, v. 6383.
- Russel, S. e Norvig, P. (2003). "Artificial Intelligence - A Modern Approach". Prentice Hall.
- Senjyu, T., Takara, H., Uezato, K. e Funabashi, T. (2002). "One-hour-ahead Load Forecasting Using Neural Network". *IEEE Transactions on Power Systems*, vol. 17, no. 1.