

Modelos de Inteligência Computacional Aplicados em um Estudo de Caso de Concessionária de Energia da Amazônia Brasileira para Previsão de Carga Elétrica

Liviane P. Rego¹, Ádamo L. de Santana¹, Guilherme Conde¹,
Carlos Renato L. Francês¹, Pedro Vitor M. Araújo¹, João Gabriel R. de O. Lima¹, Cláudio A. Rocha²,
Armando A. A. Tupiassu³, Vanja Gato³, José Marcelo A. Vale³, Pedro Pinto³

Resumo – A previsão de carga de energia elétrica comprada/vendida no mercado futuro é um dos pontos mais almejados pelas concessionárias de energia elétrica. Nesse sentido, esse artigo apresenta um estudo de previsão de carga para as empresas distribuidoras de energia elétrica, comparando a qualidade dos estimadores baseados em técnicas de *wavelets*, métodos de análise de série temporal e redes neurais, considerando previsão a longo prazo. Os resultados obtidos no modelo apresentam baixa margem de erro total de predição, adequado ao padrão de desvio aceitável pela concessionária, contribuindo assim, para a definição do consumo de energia futuro de uma dada região.

Palavras-chave – energia elétrica, previsão, redes neurais, série temporal, *wavelet*.

I. INTRODUÇÃO

A previsão de carga elétrica é uma estratégia primordial dos sistemas elétricos e é baseada nessa previsão que se planejam e operam esses sistemas de forma confiável e segura [1,2]. 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

Este trabalho foi desenvolvido no âmbito do Programa de Pesquisa e Desenvolvimento Tecnológico do Setor de Energia Elétrica regulado pela ANEEL e consta dos Anais do V Congresso de Inovação Tecnológica em Energia Elétrica (V CITENEL), realizado em Belém/PA, no período de 22 a 24 de junho de 2009.

Liviane P. Rego, Ádamo L. de Santana, Guilherme Conde e Carlos Renato L. Francês trabalham na Universidade Federal do Pará – UFPA (e-mails: liviane@ufpa.br; adamo@ufpa.br; conde@ufpa.br; rfran-ces@ufpa.br; pedrovitor.25@gmail.com; jgabriel_lima@hotmail.com).

Cláudio A. Rocha trabalha na Universidade da Amazônia – Unama (e-mail: alex@bcc.unama.br).

Armando Tupiassu, Vanja Gato, Jose Marcelo A. Vale e Pedro Pinto trabalham nas Centrais Elétricas do Para - CELPA (e-mails: armando.tupiassu@redenergia.com; vanja.gato@redenergia.com; jose.vale@redenergia.com; pedro.pinto@redenergia.com).

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.

Para realizar a previsão de carga, por razões corporativas, concessionárias de energia elétrica estão, alguma vezes, impossibilitadas de aplicar variáveis exógenas ao modelo, devido ao fato de que tais variáveis são de difícil obtenção e/ou possuem um custo alto. O uso de alguns atributos também é descartado para a análise preditiva por não permitir uma estimativa precisa e, portanto, não estarem aptos para serem utilizados nos algoritmos, principalmente quando o período de previsão aumenta.

Nós consideraremos, no estudo apresentado aqui, a alternativa para previsão de carga quando apenas os dados do próprio consumo de energia estarão disponíveis para as concessionárias.

As contribuições desse trabalho são o estudo e o aprimoramento das técnicas de predição utilizando métodos estatísticos e de inteligência computacional, especificamente regressão, redes neurais e *wavelets*, introduzindo novas variáveis e modelos a essas técnicas. Além disso, é realizada uma análise comparativa da efetividade e aplicabilidade dessas abordagens.

Em qualquer situação, a previsão de carga deve manipular dados históricos de cargas elétricas registrados em seus bancos de dados. Então, como entrada básica dos estudos tem-se os dados históricos de cargas, obtidos em intervalos de coleta convenientes. Contudo, esses dados são influenciados por muitas outras variáveis aleatórias, como temperatura, umidade, sazonalidades, como períodos de feriados.

O método de regressão aplicado incorpora não somente o conhecimento dos períodos anteriores, mas também o uso de variáveis virtuais e contenção do impacto exercido por anomalias no consumo de energia, no caso específico do Brasil, decorrentes da medida de racionamento de energia dos anos de 2001 e 2002 (o “apagão” como é comumente conhecido).

O projeto que origina este artigo denomina-se “Estratégias de Melhoria da Interpretabilidade das Inferências Bayesianas Utilizadas no Sistema Predict”, apresentado pela CELPA – Centrais Elétricas do Pará S.A. no ciclo 2005-2006,

aprovado pela ANEEL sob o código 0371-006/2006, sendo a entidade executora a UFPA – Universidade federal do Pará.

Esse artigo está organizado da seguinte forma: A seção II representa as técnicas de predição de energia propostas neste trabalho, sendo que um método de regressão de energia elétrica é o assunto de sua subseção A. Já a subseção B da seção II apresenta o modelo de redes neurais usado para definição de seus parâmetros e na subseção C é apresentado um modelo previsão utilizando *wavelets* e na seção III, as considerações finais são apresentadas.

II. MÉTODOS IMPLEMENTADOS

A. Modelo De Séries Temporais E Regressão Para A Predição De Energia

Nesta seção, é apresentado o modelo de regressão linear utilizado para análise dos dados. O modelo foi utilizado de modo a verificar a tendência dos dados, examinando o passado para inferir sobre o seu comportamento futuro, possibilitando a realização de previsões.

Os dados disponíveis para análise são referentes à energia requerida para todo o estado do Pará. Esses dados dizem respeito ao consumo total de energia no estado no decorrer de um determinado período. Para efeito de estudo de caso, foram utilizados os dados relativos à energia requerida no período de Janeiro de 1991 a Dezembro de 2006, como é apresentado no gráfico da figura 1.

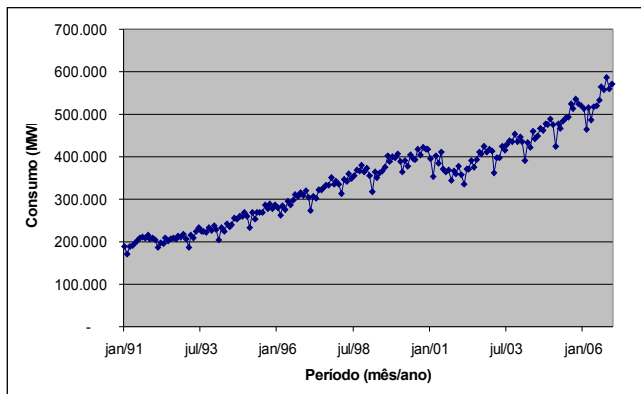


Figura 1. Histórico do consumo de energia de Jan/91 a Dez/06.

Pela observação do gráfico da figura 1, resultante do histórico dos dados fornecidos pela concessionária de energia elétrica, pode ser verificada a existência de uma tendência, caracterizando-se, como apresentado a seguir, por meio de correlogramas, como uma série não-estacionária.

Através da figura 2, pode ser constatada a não-estacionariedade da série, não só em nível, mas também que a mesma não se torna estacionária em consecutivas diferenciações (figura 3).




Figura 2. Correlograma em nível da série.

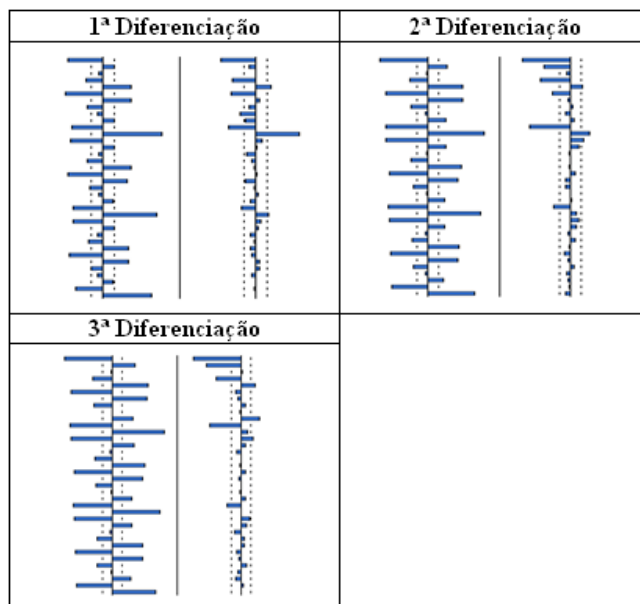


Figura 3. Autocorrelação e Correlação Parcial da 1ª, 2ª e 3ª diferenciação da série.

Uma vez verificado pelo seu comportamento que os dados tratam de uma série “explosiva”, e que a mesma não atingia uma estacionariedade, observando-a como um todo, utilizou-se uma nova abordagem. Desta feita, seccionando a série única de dados, antes mensal, em 12 séries anuais, correspondentes aos meses de janeiro a dezembro.

Partindo dessa abordagem, as séries foram então analisadas, apresentando agora, como pode ser visto pelos correlogramas da figura 4, uma estacionariedade [3].

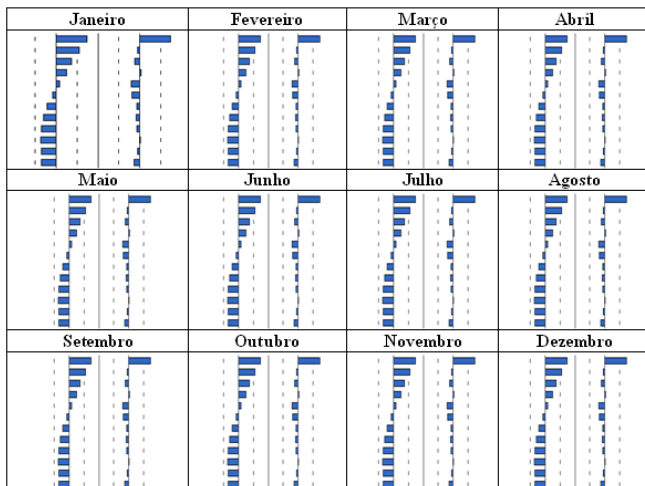


Figura 4. Autocorrelação e Correlação Parcial dos dados nos meses de Janeiro a Dezembro.

A partir da figura 5, que representa o histórico da série separado mês a mês, é possível observar um crescimento linear das séries no decorrer do tempo, com exceção do período que vai de 2001 a 2002, caracterizado pela ocorrência da medida de racionamento nacional de energia [4], que reduziu drasticamente o consumo de energia em virtude do baixo nível de água disponível nos reservatórios das usinas hidrelétricas do país. É importante salientar que, no Brasil, a energia gerada é basicamente através de usinas hidrelétricas.




Figura 5. Dados históricos de consumo dos anos de 1991 até 2006, separados mensalmente.

O estimador estabelecido para realizar a predição dos valores futuros de consumo de energia utiliza da análise de regressão múltipla (ver [4,5]), 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:

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

onde, Y é um vetor coluna, com dimensão $n \times 1$; 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 $n \times 1$ distúrbios.

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 possível a perda de conhecimentos decorrentes de eventos ou situações exógenas ao comportamento padrão do sistema que tenham ocorrido no decorrer dos onze 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 exemplos de tais eventos, podem ser citados 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 [6]), 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 da análise um único fator que melhor representa a série (em torno de 99.6%) e, conseqüentemente, o comportamento anual.

O segundo termo adicionado diz respeito à contenção do impacto exercido por anomalias existentes no histórico do consumo de energia. Aqui abordamos o período anômalo no consumo de energia (de Junho de 2001 a Fevereiro de 2002), adicionando às séries mensais uma variável artificial binária para considerar a ocorrência do apagão, indicando a presença ou ausência de um valor impactado diretamente por essa ocorrência, atribuindo valores 1 ou 0, respectivamente.

Não somente o período de vigência da medida de racionamento é tratado aqui, mas também os meses seguintes a esse período, que persistiram com uma diminuição do consumo de energia, até a série retornar a sua normalidade.

O modelo é primeiramente aplicado para testar confiabilidade do estimador, utilizando os dados existentes de Jan/1991 até Dez/2006. Após o teste o estimador foi aplicado para projetar o comportamento dos anos de 2007 e 2008.

O desempenho do modelo será avaliado através do erro médio percentual absoluto (MAPE), calculado de acordo com (2).

$$MAPE = \frac{1}{N} \sum_{i=1}^N \left(\frac{|y_i - \hat{y}_i|}{y_i} \right) \times 100\% \quad (2)$$

onde, N é o número de amostras existentes, y é o valor his-

tórico original e \hat{y} é o valor previsto.

A avaliação dos resultados obtidos com a rede neural e com o método *wavelet*, apresentados nas subseções II.B e II.C, respectivamente, também é baseada no MAPE.

Um teste inicial foi utilizando os dados referentes ao intervalo de 1991 até fim de 2004, e a estimativa dos valores de consumo é realizada para os anos de 2005 e 2006 (figura 6), que apresenta um erro de aproximadamente 1,76%, valor doravante considerado aceitável pela concessionária de energia.




Figura 6. Valores reais e estimados para o consumo de energia de Jan/05 a Dez/06.

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 7.




Figura 7. Valores estimados de consumo de energia para os anos de 2005 a 2008.

Os resultados alcançados pela implementação dos modelos com rede neural e *wavelet*, bem como a análise dos resultados obtidos por todas essas técnicas serão apresentados nas seções seguintes.

B. 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. Nesse contexto, as redes neurais artificiais (RNA) têm sido muito aceitas como técnicas adotadas em sistemas de previsão [7,8].

Para a construção do modelo de previsão com RNA é necessária a definição de três principais estágios: (a) identifica-

ção e definição da informação necessária para representar as séries e o horizonte de previsão; (b) modelagem da RNA; (c) seleção de um algoritmo para a RNA que seja capaz de aprender as características das séries e que realize a estimação satisfatoriamente.

Durante o processo de identificação e definição das variáveis de entrada para o processo de previsão, a variável consumo, que representa a energia requerida mensal, foi decomposta em 12 séries anuais; uma para cada mês do ano, como previamente descrito na seção II.A. Ao lado da variável consumo, as variáveis data e taxa de crescimento entre anos consecutivos também foram utilizados.

Partindo dos estudos realizados na seção II.A, empregouse a técnica de “janelamento” sobre a variável consumo 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 8 ilustra as entradas e saídas selecionadas para modelar as camadas de entrada e saída das RNAs projetadas neste trabalho.

Após vários experimentos com diferentes seqüências de valores, encontrou-se que a janela de tamanho igual a três apresentou os melhores resultados; isto é, a RNA foi alimentada com o valor do consumo e seus três últimos valores históricos.

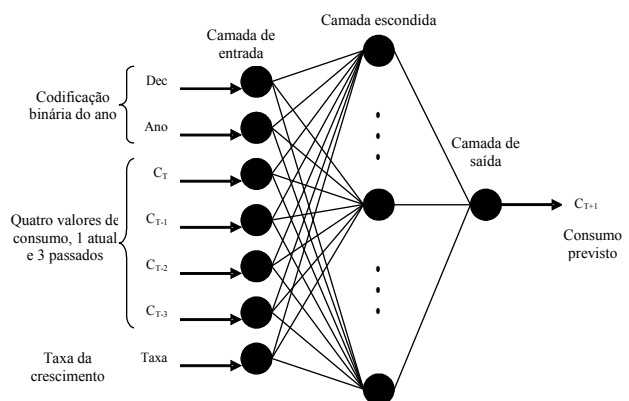


Figura 8. Arquitetura da RNA utilizada.

A seleção de uma arquitetura para RNA apropriada para o problema é o primeiro passo de um sistema de predição baseado em RNA. Aqui, a RNA escolhida foi uma a rede *perceptron* multicamada *feedforward* (MLP), com apenas uma camada escondida, devido ao seu amplo emprego nesse tipo de sistema [8, 9].

No estágio da modelagem de redes MLP, o número de neurônios nas camadas de entrada e saída foram fixadas de acordo com a seleção descrita. Contudo, o número de neurônios na camada escondida é determinado dinamicamente durante o processo de treinamento da rede, como será descrito a frente.

As séries históricas mensal foram tratadas independentemente com um sistema de predição multi-modelo [7]. Nesse tipo de modelo, a previsão de cada série mensal é feita por diferentes redes MLP. Então, no final do treinamento, doze redes MLP são geradas.

Os algoritmos de treinamento escolhido para as redes MLP foram o *backpropagation* [10] e o *Levenberg-Marquardt* [11] com algumas modificações para o ajuste dinâmico dos parâmetros de configuração.

Durante a fase de treinamento da rede MLP com o algoritmo de treinamento *backpropagation*, o número de neurônios na camada escondida, a taxa de aprendizagem das camadas escondida e de saída são alteradas repetidamente, entre um mínimo e um 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.

Após a finalização do processo de treinamento, cada série mensal possui a melhor rede MLP encontrada para realizar as previsões de consumo daquele mês.

O procedimento utilizado no treinamento da rede MLP com o algoritmo *Levenberg-Marquardt* foi o mesmo realizado com o algoritmo *backpropagation*, com exceção de que a taxa de aprendizado foi fixada em 0.02, devido esse valor ter gerado os melhores resultados após vários experimentos realizados com diversas taxas de aprendizado.

As simulações foram feitas para cada uma das doze séries, identificando e selecionando as melhores redes MLP para cada uma. Foram utilizados dois conjuntos de dados:

Primeiro, as redes MLP utilizaram como conjunto de treinamento os dados históricos de consumo de 1991 até 2004, e o conjunto de validação com os dados do ano de 2005. Após o processo de treinamento e validação, foram gerados os valores de previsão de consumo para os anos de 2005 e 2006, submetidos aos algoritmos *backpropagation* e *Levenberg-Marquardt* (figuras 9 e 10, respectivamente).




Figura 9. Valores reais e estimados de consumo de energia de Jan/2005 até Dez/2006 obtidos pela RNA com *backpropagation*.




Figura 10. Valores reais e estimados de consumo de energia de Jan/2005 até Dez/2006 obtidos pela RNA com *Levenberg-Marquardt*.

Os resultados obtidos para as previsões apresentaram erros residuais em ambos os casos, de aproximadamente $2 \times 10^{-4} \%$ com *backpropagation* e $26 \times 10^{-3} \%$ com *Levenberg-Marquardt*, para o ano de 2005. Contudo, para o ano de 2006 os erros obtidos foram de 6.06% com *backpropagation* e 3.75% com *Levenberg-Marquardt*. Os valores apontaram dessa forma uma estimacão precisa para o primeiro ano, mas que, no entanto, declinou para o segundo ano de previsão.

Os modelos de rede neural foram aplicados novamente, tendo agora como conjunto de treinamento os valores históricos dos anos de 1991 até 2005, e para o conjunto de validação os dados de 2006. Os valores de consumo foram então submetidos novamente a RNA com os algoritmos *backpropagation* e *Levenberg-Marquardt* para prever os anos 2006, 2007 e 2008 (figuras 11 e 12, respectivamente).




Figura 11. Valores de consumo estimados para os anos de 2006 até 2008 através MLP com *backpropagation*.




Figura 12. Valores de consumo estimados para os anos de 2006 até 2008 através de MLP com *Levenberg-Marquardt*.

A previsão de consumo para 2006, como mostrado nas figuras 11 e 12, também apresentaram erros residuais, de aproximadamente 1×10^{-4} % com *backpropagation* e 13×10^{-4} % com *Levenberg-Marquardt*. Isso demonstra a tendência dos resultados gerados pela rede MLP, gerando resultados bem ajustados para previsões a curto prazo, geralmente período de seis meses a um ano. Contudo, quando estudamos períodos mais longos de tempo, a confiabilidade dos valores previstos cai drasticamente, apresentando valores anômalos (figuras 9, 10, 11 e 12) de consumo a partir do primeiro ano de previsão; valores esse, que estão em desacordo com o conhecimento dos especialistas de domínio.

Os testes apresentados aqui mostraram que as redes MLP apresentam um resultado excepcional quando estudamos previsão a curto-prazo. No entanto, para previsão a longo prazo, o modelo baseado em técnicas de regressão, apresentado na subseção anterior, mostram melhores resultados, produzindo séries com um bom comportamento (figura 7); e também um bom ajuste, apesar de inferior ao obtido pela rede MLP.

C. Aplicação De Modelo Wavelets

Modelos *wavelet* são usados para análise multi-resolução, enquanto que a técnica *wavelet* permite a decomposição de um sinal original em vários componentes em múltiplas escalas.

Um dos principais aspectos de *wavelets*, que contribui para sua ampla difusão e aplicação, é o fato de que ele permite analisar um sinal tanto no domínio do tempo como no domínio da frequência, atuando como uma melhora da análise de Fourier.

Em *wavelets*, filtros passa-baixa e passa-alta são aplicados, extraindo frequências baixas (aproximações) e altas (detalhes) do sinal para o nível de decomposição escolhido, cuja soma é igual à série original; e que se torna mais suave à medida que o nível aumenta.

A transformada wavelet discreta (DWT) trabalha com sinais em tempo discreto. A função wavelet ψ é aplicada ao sinal original para realizar a decomposição e reconstrução multi-resolução *wavelet* [12]. A função *wavelet* pode ser escrita como [13,14]:

$$\psi_{j,k}(t) = 2^{-j/2} \psi(2^{-j}t - k) \quad (3)$$

onde, considerando o conjunto de números inteiros Z , $i, j, k \in Z$, j é o nível de resolução, cujo valor é inversamente proporcional a frequência e; k é o parâmetro de deslocamento, com $k = 1, 2, \dots, N/2$ e N é o número de valores de dados gravados [15].

Um dos problemas com a aplicação da DWT em análises de séries temporais é que ele se sujeita a uma falta de invariância de translação [16]. Esse problema pode, contudo, ser tratado por meio de uma transformada *wavelet* não-decimal (NWT) [17,18].

A NWT se baseia no o fato de que uma base da transformação redundante baseada em uma série temporal com n entradas tem n escalas de resolução para cada nível de resolução de interesse. Dessa forma, a informação em cada escala de resolução é diretamente relacionada em cada tempo [19].

A idéia de aplicar *wavelets* em séries temporais e previsão é decompor a série temporal original em componentes suavizados e então aplicá-los aos métodos de predição mais apropriados para cada componente individualmente. Nesse contexto, os componentes em alta frequência são melhores para explicar tendências de curto prazo, enquanto que os componentes em baixa frequência contem, em geral, as tendências das séries a longo prazo [20].

No modelo estudado aqui, foi aplicado uma NWT usando função *Daubechies* [21] de ordem cinco – tal configuração, a partir de análises empíricas, apontou ser a mais adequada para o problema aqui estudado. A série original foi inicialmente decomposta dentro de conjuntos de aproximação e detalhes; posteriormente, nos testes realizados, foi verificado que o nível dois de decomposição foi o melhor para o problema estudado (figura 13).




Figura 13. Série original (topo) e os componentes *wavelet* no nível dois de decomposição.

Os componentes foram então estudados como séries temporais individuais. Dado que o método de séries temporais de regressão múltipla obteve, de maneira geral, os melhores resultados (considerando a aplicação conjunta de ambas as previsões, a curto e longo prazos), quando comparados ao modelo de redes neurais, ele foi escolhido para ser aplicado

na análise de séries temporais *wavelets*, ao invés de se utilizar um modelo de rede de *wavelet* [22] para o mesmo.

Uma análise de regressão múltipla similar à apresentada na subseção II.A foi então aplicada pra cada uma das séries de dados (aproximação e detalhes) separadamente. Os resultados da predição obtidos para cada componente foram então adicionados para construir os resultados finais do modelo. Um resumo do sistema de previsão é apresentado na figura 14, onde A_2 representa a aproximação no nível 2 e D_1 e D_2 representam os detalhes nos níveis 1 e 2, respectivamente.

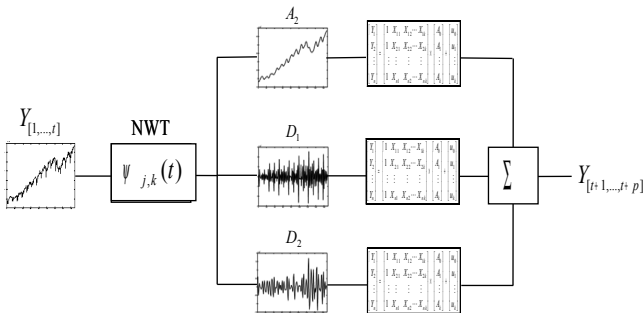


Fig. 14. Sistema de previsão regressão múltipla/*wavelet*.

O modelo obteve um erro total de predição de 0.72%, melhorando os resultados obtidos pelo método de regressão múltipla, ao manter um bom comportamento que a técnica prevê para previsão a longo prazo. Os valores obtidos (real e estimado) são mostrados na figura 15.




Figura 15. Valores reais e estimados de consumo de Jan/2005 a Dez/2006 obtidos pelo modelo de *wavelet*.

III. CONSIDERAÇÕES FINAIS

O objetivo desse trabalho é estudar modelos de previsão para consumo de energia. Nesse artigo, três técnicas para previsão foram aplicadas: série temporal, rede neural e modelos *wavelets*.

Nos testes, foram observados para todos os estimadores estudados, uma boa capacidade de ajuste e predição, apresentando erros abaixo daqueles encontrados atualmente através dos métodos tradicionais utilizados pelas concessionárias de energia elétrica; com a aplicação do modelo *wavelet* houve uma melhora do método de regressão múltipla, superando seus resultados. Essa melhora na redução do erro representa, evidentemente, uma economia considerável para a

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 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 *wavelet* com regressão uma melhor alternativa.

Diante desse panorama, a principal contribuição deste trabalho foi prover modelos de previsão, aplicando o processo de extração de padrões de consumo de energia, para dar suporte à decisão no estabelecimento de contratos mais vantajosos de compra de energia no mercado futuro para as concessionárias de energia elétrica; especialmente dado que a expansão do fornecimento de energia na região amazônica é um fator predominante para o desenvolvimento social.

IV. AGRADECIMENTOS

Os autores gostariam de agradecer a CELPA pelo apoio financeiro que propiciaram o desenvolvimento deste trabalho.

V. REFERÊNCIAS BIBLIOGRÁFICAS

- [1] A. P. Douglas, A. M. Breipohl, F.N. Lee and R. Adapa, "The impacts of temperature forecast uncertainty on Bayesian load forecasting," *IEEE Transactions on Power Systems*, pp. 1507-1513, 1998.
- [2] T. Senjyu, H. Takara, K. Uezato and T. Funabashi, "One-hour-ahead Load Forecasting Using Neural Network," *IEEE Transactions on Power Systems*, pp. 113-118, 2002.
- [3] R. S. Pindyck and D. L. Rubinfeld, *Econometric Models and Economic Forecasts*. Irwin/McGraw-Hill, 1998.
- [4] ANEEL, *Atlas de energia elétrica do Brasil*. 1ª ed. Agência Nacional de Energia Elétrica, Brasília – DF, 2003.
- [5] J. A. Rice, *Mathematical Statistics and Data Analysis*. Duxbury Press, 1995.
- [6] W. R. Dillon and M. Goldstein, *Multivariate Analysis - Methods and Applications*, John Wiley and Sons, 1984.
- [7] H. Hippert, C. Pedreira and R. Souza, "Neural Networks for Short-Term Load Forecasting: A Review and Evaluation," *IEEE Transactions on Power Systems*, vol. 16, pp. 44-55, 2001.
- [8] M. Adya and F. Collopy, "How Effective are Neural Networks at Forecasting and Prediction? A Review and Evaluation," *Journal of Forecasting*, pp. 481-495, 1998.
- [9] E. Doveh, P. Feigin, D. Greig and L. Hyams, "Experience with FNN models for medium term power demand predictions," *IEEE Transactions on Power Systems*, pp. 538-546, 1999.
- [10] S. Haykin, "Neural Networks: a comprehensive Foundation," Prentice Hall, 1998.
- [11] J. J. Moré, "The levenberg-marquardt algorithm: Implementation and theory," *Proceedings of Springer-Verlagin Numerical Analysis*, Lecture Notes in Mathematics, pp. 105-116, 1977.
- [12] S. Chen, W. Wang and G. Qu, "Combining wavelet transform and Markov model to forecast traffic volume," in *Proc. 2004 Machine Learning and Cybernetics Conf.*, pp. 2815-2818.
- [13] S. Soltani, "On the use of the wavelet decomposition for time series prediction," *Neurocomputing*, vol. 48, pp. 267-277, 2002.
- [14] Y. Dai, "The time-frequency analysis approach of electric noise based on the wavelet transform," *Solid-state Electronics*, pp. 2147-2153, 2000.

- [15] S. Chen, W. Wang and G. Ren, "A hybrid approach of traffic volume forecasting based on wavelet transform, neural network and Markov model," in *Proc. 2005 IEEE International Conference on Man and Cybernetics Systems*, pp. 393-398.
- [16] B. Zhang, R. Coggins, M. A. Jabri, D. Dersch and B. Flower, "Multiresolution forecasting for futures trading using wavelet decompositions," *IEEE Transactions on Neural Networks*, vol. 12, 765-775, 2001.
- [17] R. R. Coifman and d. L. Donoho, "Translation-invariant denoising, Wavelets and Statistics," Springer Lecture Notes, Springer-Verlag, pp. 125-150, 1995.
- [18] N. Saito and G. Beylkin, "Multiresolution representations using the auto-correlation functions of compactly supported wavelets," *IEEE Transactions on Signal Processing*, vol. 41, pp. 3584-3590, 1993.
- [19] B. L. Zhang and Z. Y. Dong, "An Adaptive Neural-Wavelet Model for Short Term Load Forecasting," *Electric Power Systems Research*, vol. 59, pp. 121-129, 2001.
- [20] P. Yu, A. Goldenberg and Z. BI, "Time Series Forecasting using Wavelets with Predictor-Corrector Boundary Treatment. In: Proceedings of the Temporal Data Mining Workshop," in *Proc. 2001 Seventh ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*.
- [21] I. Daubechies, "Ten Lecture on Wavelets," in *Proc. 1992 Regional Conference Series in Applied Mathematics*.
- [22] Q. Zhang and A. Benveniste, "Wavelet network," *IEEE Transactions on Neural Networks*, pp. 889-898, 1992.