



**SNPTEE  
SEMINÁRIO NACIONAL  
DE PRODUÇÃO E  
TRANSMISSÃO DE  
ENERGIA ELÉTRICA**

GPL 02  
14 a 17 Outubro de 2007  
Rio de Janeiro - RJ

## **GRUPO VII**

### **GRUPO DE ESTUDO DE PLANEJAMENTO DE SISTEMAS ELÉTRICOS - GPL**

#### **PREVISÃO INTELIGENTE DE MERCADOS DE ENERGIA: MAIS QUE REPETIR O PASSADO, ANTECIPAR O FUTURO**

**Jacques Szczupak, Leontina Pinto, Luiz H. Macêdo**

**ENGENHO PESQUISA, DESENVOLVIMENTO E CONSULTORIA LTDA**

**José Roberto Pascon(\*), Robinson Semolini, Marcia Inoue,**

**Carlos Almeida, Fernão R. Almeida**

**ELEKTRO SERVIÇOS DE ELETRICIDADE S.A.**

**CONSULTORES INDEPENDENTES**

## **RESUMO**

Muitos mercados de energia têm experimentado variações extremas na dinâmica de sua carga devido, por exemplo, à falta de energia ou mesmo às mudanças de regras do mercado. Nesta circunstância a nova história está limitada a apenas alguns anos, deixando um volume insuficiente de dados a ser explorado por modelos clássicos, de estatísticos a redes neurais. Este trabalho se dirige a este tipo de problema – modelagem com limitação no volume de dados – e propõe um novo método baseado em Análise Funcional, aplicado como um procedimento iterativo seqüencial. A ferramenta computacional desenvolvida é capaz de realizar, interativa e amigavelmente, a previsão de carga e mercado detalhados por classe ou mesmo postos tarifários. Um caso ilustrativo ressalta as vantagens apresentadas pelo método.

## **PALAVRAS-CHAVE**

Previsão de Mercado, Projeção de Cenários, Análise Vetorial, Projeção de Mercado

### **1.0 - INTRODUÇÃO**

A modelagem e previsão da carga/mercado é um ponto chave para toda a empresa; impacta do planejamento e operação à comercialização e aos resultados da empresa. No entanto, apesar de sua reconhecida importância, a projeção de mercado é ainda um desafio em aberto; a área continua carente de ferramentas especificamente desenhadas, capazes de oferecer um auxílio real ao agente.

Os estudos de mercado têm sido desenvolvidos tradicionalmente a partir de análises com base estatística, empregando grandes bancos de dados das empresas concessionárias. Naturalmente, a dinâmica de consumo é suposta estável dentro do período de coleta destes dados – em outras palavras, os processos associados aos dados seriam estacionários. Esta situação foi recentemente interrompida no Brasil pelo recente racionamento. Sabe-se que o mercado foi duramente atingido, e que a dinâmica de consumo sofreu profundas modificações. Em muitas empresas, toda a informação anterior aos anos de 2002 ou 2003 converteu-se em um histórico passado, incapaz de refletir o comportamento presente. Mais ainda, espera-se que a rápida transformação tecnológica (eficientização, entrada de novas fontes, etc.) produza mudanças constantes (e provavelmente irreversíveis) no consumo, exigindo uma adaptação eficiente.

A Figura 1 mostra a curva de carga da Elektro, normalizada para melhor visualização. A dinâmica da carga muda dramaticamente depois da queda de 2001 e o novo padrão de consumo parece diverso do antigo. O mercado de energia procura-se adaptar durante 2002 e só após 2003 aparenta quase estabilizar – ainda é cedo para comparar os padrões pré e pós restrição ao consumo.

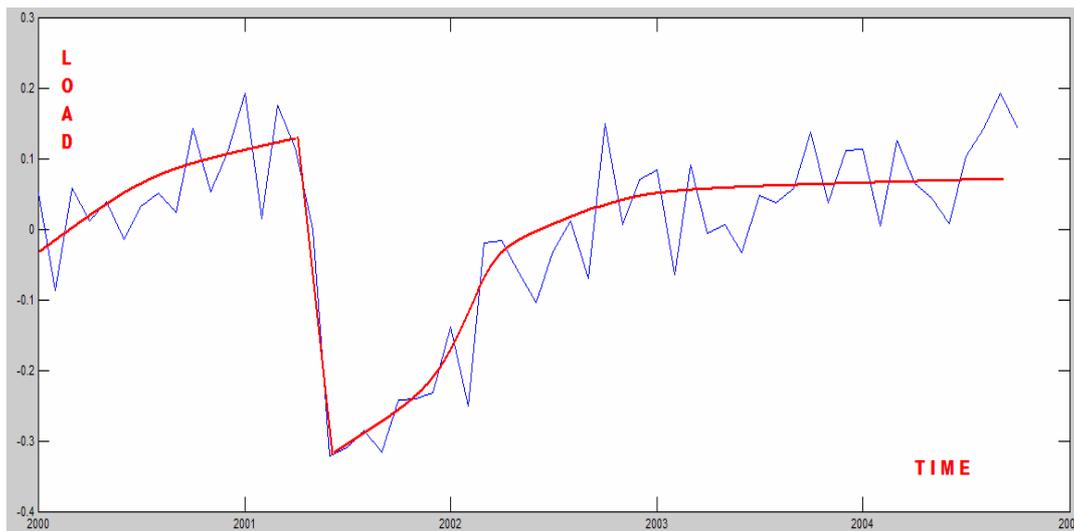


FIGURA 1 – Carga Total da Elektro

Esta situação leva à insuficiência de dados para emprego estatístico. Métodos convencionais (principalmente baseados em estatística, redes neurais, conjuntos “fuzzy”, busca de dados ou combinações destas técnicas [1-12]) requerem grandes volumes de dados que demorarão a estar disponíveis (talvez nunca estejam, se considerarmos a constante mutação de nosso mercado em evolução). Tentativas de utilizar dados estatísticos pré-2002 (e mesmo pré-2003) para aplicação ao mercado atual seriam baseadas em um passado obsoleto, possivelmente levando a resultados pouco confiáveis.

Finalmente, sabe-se que, apesar de todas estas dificuldades, as novas regras de mercado trouxeram um novo desafio: erros, mesmo que pequenos, na previsão de carga podem levar a sub- ou sobre-contratações (severamente penalizadas). A solução do problema de Previsão de Mercado a curto, médio e longo prazos nunca foi tão difícil, crítica e importante.

Este trabalho apresenta um método baseado em Análise Funcional, originalmente aplicado à teoria de sinais, preparado para a análise e previsão do mercado. Este é decomposto por diferentes variáveis explicativas, capazes de, adequadamente, descrever o comportamento e a dinâmica da carga.

## 2.0 - ESPAÇOS DE HILBERT E O TEOREMA DA PROJEÇÃO

### 2.1 Espaço de Hilbert

A Análise Funcional tem sido extensivamente empregada [14-16] como base a diversos processos de otimização. Ela pode ser aplicada com base estatística, como em muitos problemas de comunicação, ou determinística associada a Espaços de Hilbert específicos com dimensão finita.

É usual referir-se aos membros do Espaço de Hilbert a ser estudado como vetores, independente do fato de que são, neste caso, seqüências de dados, como cargas, temperaturas, índices econômicos, etc.

Idealmente o Espaço de Hilbert considerado:

- é um espaço métrico completo [14-16], composto por vetores - seqüências de dados - razoavelmente suaves, representadas em negrito como é o caso de  $\mathbf{v}$ ,
- usa a distância  $d[\mathbf{v}_1, \mathbf{v}_2] = \|\mathbf{v}_1 - \mathbf{v}_2\|$ , um número real não negativo, onde  $\|\cdot\|$  representa a norma do vetor,
- o produto interno  $(\mathbf{v}_1, \mathbf{v}_2) = \mathbf{v}_1^t \mathbf{v}_2$  induz a norma do vetor,  $\sqrt{(\mathbf{v}_1^t \mathbf{v}_2)}$ , a norma euclidiana [14-16].

Claramente a norma do vetor é uma medida (funcional) do tamanho do vetor, enquanto que a distância entre vetores é o tamanho de sua diferença.

É importante observar que este idealizado “Espaço de Hilbert de Carga” não existe para nós. Entretanto a carga verdadeira está próxima desta situação idealizada e um critério de engenharia, “suficientemente próximo”, evitará o requisito de o espaço ser completo.

A desigualdade de Schwartz [14-16],  $|(v_1, v_2)| \leq \|v_1\| \cdot \|v_2\|$  pode ser utilizada no nosso caso, espaço vetorial real, através de

$$\cos \theta = \frac{(v_1, v_2)}{\|v_1\| \cdot \|v_2\|} \quad (1)$$

onde  $\theta$  é o ângulo entre os vetores  $v_1$  e  $v_2$ .

A solução ótima do Espaço de Hilbert satisfaz o Teorema da Projeção, ou equivalentemente, o Princípio da Ortogonalidade - uma interpretação geométrica para a condição de otimalidade.

## 2.2 Teorema da Projeção

Caso o interesse seja a aproximação ótima de um vetor desejado,  $V_d$ , por um conjunto de vetores formando uma base, o Teorema da Projeção estabelece que o vetor erro é ortogonal ao espaço determinado por estes vetores básicos. Isto é indicado na Fig.2, onde  $V_d$  é otimamente aproximado por  $V_o$ , um vetor pertencente ao Espaço Vetorial. O vetor erro,  $E$ , é ortogonal ao espaço.

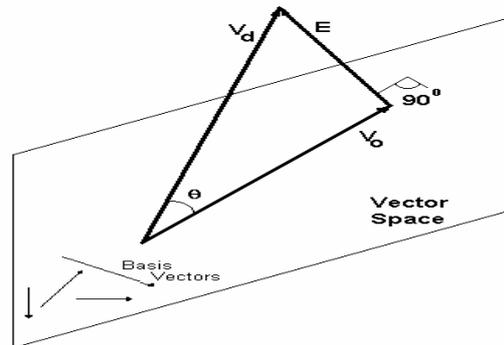


FIGURA 2 – Representação do Teorema da Projeção

Neste caso o vetor desejado inicial é constituído pela seqüência de cargas, enquanto os vetores base serão originados da economia, climatologia, séries demográficas, etc.

## 3.0 - DECOMPOSIÇÃO SEQUENCIAL DA CARGA

O Teorema da Projeção poderia ser seguido, exatamente como apresentado, para alcançar a decomposição ótima. Esta é a maneira geral pela qual é utilizado, quando os vetores base são conhecidos a priori, como nas comunicações clássicas com senóides ou nas técnicas modernas de "spread spectrum" como em sistemas CDMA [17, 18]. Entretanto este não é o nosso caso; os vetores da base, ou séries explicativas, ainda devem ser encontrados e elas podem variar de empresa a empresa, de região a região.

Devido a esta situação, ao invés de determinar o espaço pelos vetores da base, ainda desconhecidos, seguiremos um procedimento alternativo equivalente: remover sequencialmente o componente devido a cada vetor básico. O método é equivalente ao original, mas permite estimar visualmente a evolução do processo de decomposição e, principalmente, ajuda a encontrar as seqüências explicativas, vetores da base.

O Algoritmo Seqüencial pode ser descrito como:

1. Iteração  $i = 1$
2. Escolha o vetor desejado,  $V_{di}$ .
3. Escolha o vetor da base,  $V_{bi}$ .
4. Determine a projeção ótima,  $V_{oi}$ .
5. Determine o vetor erro,  $E_i$ .
6. Se  $\|E_i\|$  não é suficientemente pequeno;  $V_{di+1} = E_i$ ;  $i=i+1$ ; volte a 3. Caso contrário pare.

É interessante notar que o critério de parada baseia-se no critério de engenharia, "suficientemente próximo", previamente mencionado. Esta característica é consistente com o alvo do algoritmo: servir como ferramenta que se some à experiência do usuário, refletindo e se adaptando aos seus desejos, objetivos e expectativas.

É importante observar que, a cada iteração, só o vetor erro é ortogonal aos correspondentes vetores da base, não requerendo a ortogonalidade dos vetores base como ocorreria pela aplicação de Gram-Schmit aos vetores explicativos. Isto facilita escolher variáveis explicativas sem a preocupação quanto a problemas de co-integração.

A decomposição é alcançada após algumas iterações e própria seleção dos vetores da base. A seqüência deste trabalho mostra um procedimento detalhado para cada passo do Algoritmo Seqüencial.

#### 4.0 - CASO ESTUDO: ELEKTRO

O método proposto será ilustrado através de um caso realístico usando a carga total da Elektro – *para preservar a confidencialidade das informações da empresa, os dados foram modificados, sem comprometer a análise dos resultados*. Deve-se, entretanto, observar que o processo é totalmente geral e sua aplicação a dados de outra empresa seria imediata, o que inclui diferentes classes, clientes, grupamentos ou mesmo regiões.

##### 4.1 Carga Efetiva ao invés de Carga Mensal

Curvas de cargas mensais podem induzir a falsas conclusões. Por exemplo, a carga de fevereiro é usualmente menor não devido a um menor consumo, mas ao número reduzido de dias no mês. Além disto, nem todos os dias são semelhantes: feriados, domingos e sábados normalmente apresentam consumo diferenciado dos demais; a distribuição dos dias no mês pode então ter papel importante sobre o consumo de carga – O carnaval com seus três dias de feriado tem tremendo impacto sobre o consumo do mês correspondente.

Estas características foram modeladas transformando a carga mensal em uma carga efetiva, onde cada dia é pesado de acordo com sua contribuição ao consumo total, de acordo com uma típica curva de carga semanal. A Figura 3 apresenta ambas as séries, normalizadas para uma melhor comparação: os vales de fevereiro, por exemplo, aparecem corrigidos.

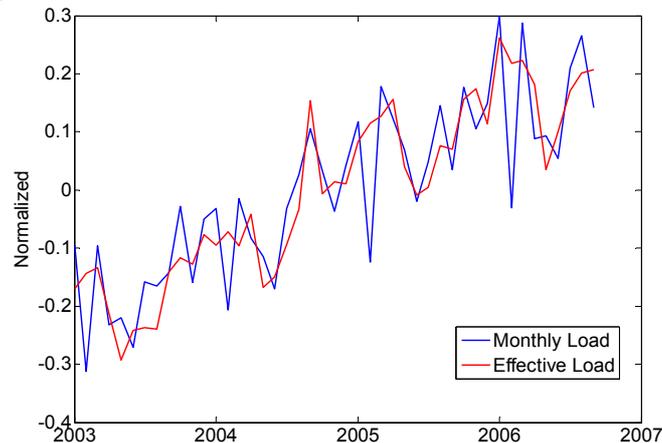


FIGURA 3 – Carga Normalizada, Mensal e Efetiva

A Figura 4 ilustra a conveniência da transformação com uma simples comparação entre a média das temperaturas regionais, a carga efetiva e a carga mensal de junho/05 a julho/06. A forma da série de temperaturas é muito mais aderente à carga efetiva que à mensal, especialmente no verão (a estação de maior carga).

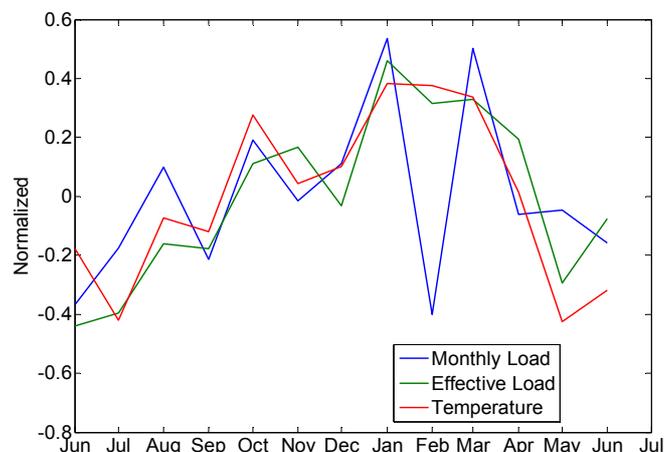


FIGURA 4 – Temperaturas Médias e Cargas Mensal e Efetiva – Normalizadas

Estes resultados conduzem a uma conclusão intuitiva, apesar de nem sempre vislumbrada: índices médios, como o são a maior parte dos climáticos, só podem ser comparados com variáveis também médias (ou, para o nosso caso, média com pesos), como a carga efetiva. Índices não médios, como a maior parte das variáveis econômicas, podem necessitar ajustes para se enquadrar nesta comparação.

A carga efetiva apresentou consistentemente, de acordo com nossa experiência, um desempenho superior em relação à mensal. Será, portanto o ponto de partida para o nosso estudo.

#### 4.2 Explicando a Dinâmica da Rede

Nosso estudo inicia pelo período do pós-acionamento – de janeiro 2003 a janeiro 2006 (apesar do término do racionamento em 2002, o transitório está presente até 2003) – limitando o volume de dados a não mais que 36 meses, insuficientes para a maior parte dos métodos estatísticos e para os baseados em modelos neurais.

O algoritmo começa pela carga total efetiva da Elektro, o vetor  $\mathbf{V}_d$ . Seguindo o Algoritmo Seqüencial;  $i=1$ ,  $\mathbf{V}_{d1} \leftarrow$  Effective Load. O passo seguinte é selecionar o primeiro vetor base, que neste caso foi a influência econômica traduzida pela tendência do PIB brasileiro. Mostra-se [13] que, apesar da alta elasticidade da carga com respeito a preços ou renda esta tendência afeta significativamente a carga. Este primeiro vetor da base é  $\mathbf{V}_{b1}$ .

O próximo passo do algoritmo é aplicar o Teorema da Projeção, determinando o  $\cos \theta$  entre  $\mathbf{V}_{d1}$  e  $\mathbf{V}_{b1}$ , o que segue diretamente da Eq.(1). Na seqüência determina-se o vetor ótimo

$$\mathbf{V}_{oi} = \underbrace{\|\mathbf{V}_{di}\| \cos \theta_i}_{\text{tamanho e sentido}} \underbrace{\frac{\mathbf{V}_{bi}}{\|\mathbf{V}_{bi}\|}}_{\text{vetor unitário}} \quad (2)$$

que é removido de  $\mathbf{V}_{di}$ , resultando no primeiro vetor erro  $\mathbf{E}_i$

$$\mathbf{E}_i = \mathbf{V}_{di} - \underbrace{\|\mathbf{V}_{di}\| \cos \theta_i \frac{\mathbf{V}_{bi}}{\|\mathbf{V}_{bi}\|}}_{\mathbf{V}_{oi}} \quad (3)$$

A Figura 5 apresenta as curvas normalizadas da Carga Efetiva, Tendência do PIB e Vetor Erro. Apesar das aparentes desigualdades (devido à normalização) o PIB responde por 87% da carga efetiva.

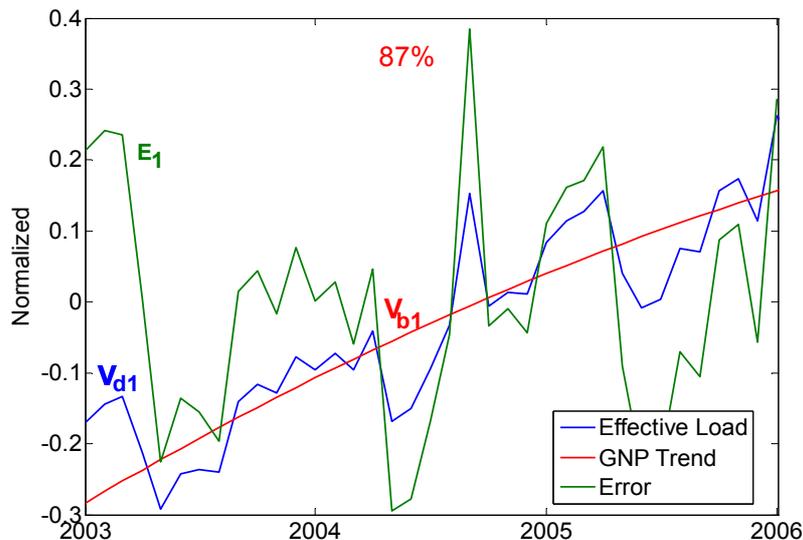


FIGURA 5 – Carga Efetiva, Tendência do PIB e Erro, Normalizados

Em outras palavras, o vetor erro para  $i=1$  responde por 13% da primeira Carga Efetiva e não é, portanto, desprezível.

O Algoritmo Seqüencial prossegue com  $i=2$ . O vetor erro anterior é o novo vetor desejado;  $\mathbf{V}_{d2} = \mathbf{E}_1$ . Um novo, segundo, vetor base deve ser selecionado – tomamos neste caso uma variável climatológica: a temperatura. Como a Elektro tem atuação sobre uma grande área geográfica, escolhemos para este exemplo a média espacial das temperaturas médias ao longo de sua área de atuação. Estudos adicionais certamente levariam possivelmente a resultados ainda mais precisos.

A Figura 6 apresenta, normalizados, o vetor desejado superposto à temperatura. Uma simples inspeção visual indica alto grau de similaridade entre as curvas, resultando em, novamente, 87% de energia no vetor ótimo projetado, como se percebe na Figura 7.

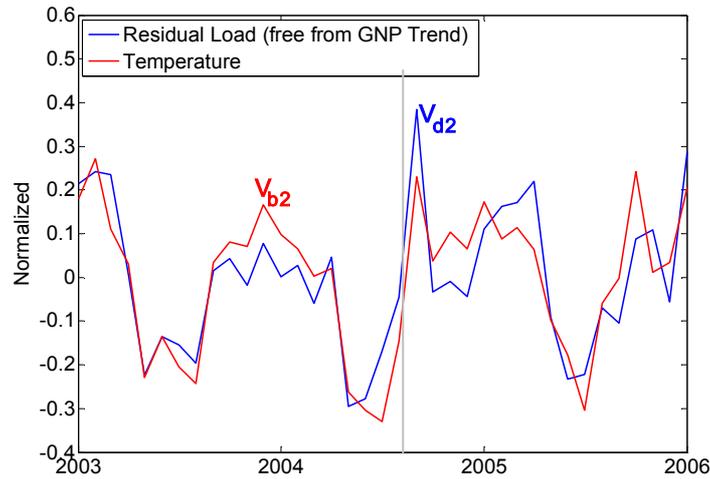


FIGURA 6 – Carga Residual e Temperatura, Normalizadas

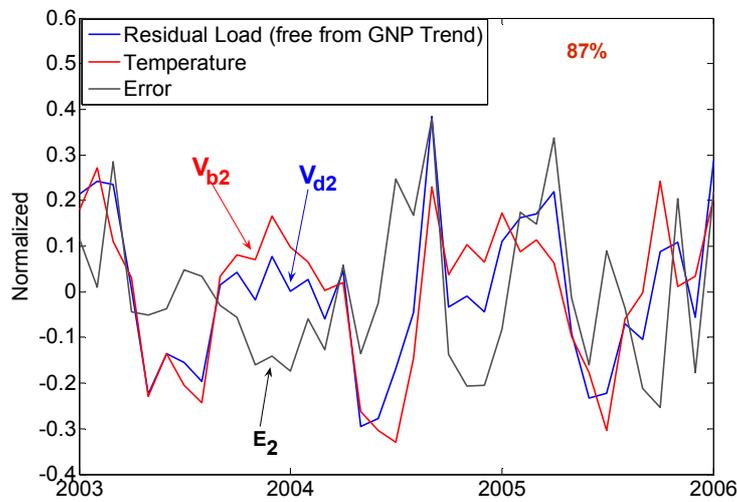


FIGURA 7 –  $V_{d2}$ ,  $V_{b2}$ , e  $E_2$ , Curvas Normalizadas

Finalmente deve-se notar que a dinâmica da carga está associada a uma sazonalidade característica – no caso da Elektro, por exemplo, há alta de consumo durante abril-maio e setembro-novembro, como resultado de atividades industriais específicas. Isto é considerado por uma terceira variável explicativa; a sazonalidade do resíduo.

A Figura 8 apresenta os resultados desta Terceira iteração, com a sazonalidade respondendo por 63% do resíduo.

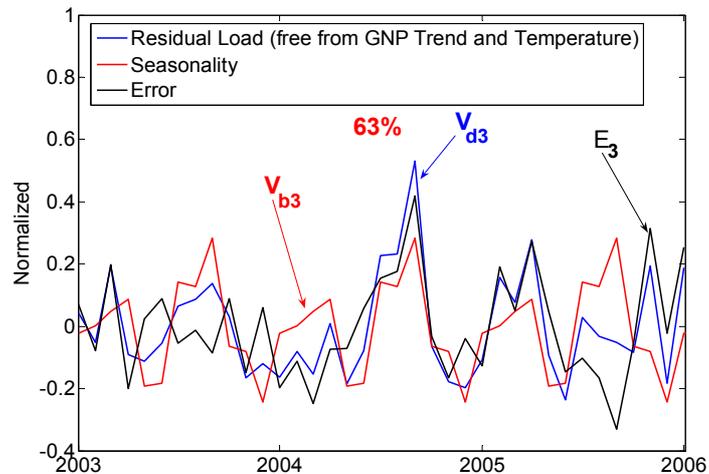


FIGURA 8 – Carga Residual, Sazonalidade e Erro, Normalizados

A Figura 9 ilustra a explicação da decomposição; apenas 0,7% da carga total ficaram sem explicação. A Figura 10 ilustra esta comparação entre carga total e residual. O nível do resíduo final é baixo o suficiente para terminar o Algoritmo Sequencial.

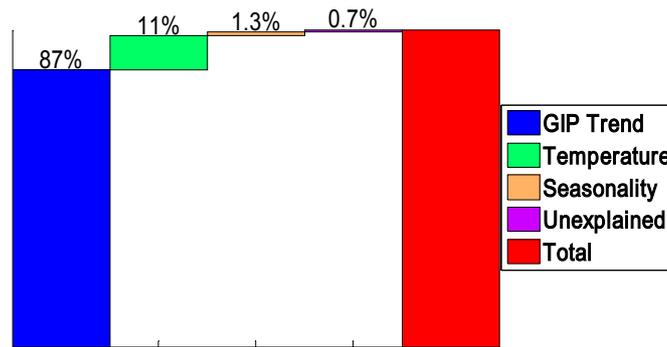


FIGURA 9 – Explicação da Decomposição

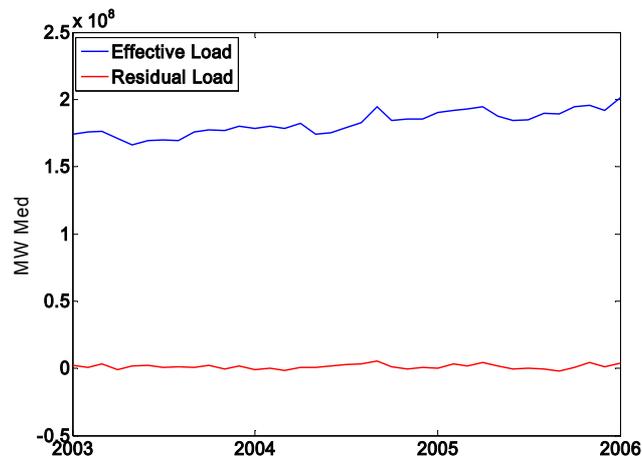


FIGURA 10 – Cargas Efetiva e Residual

É interessante observar que não apenas o nível do resíduo final é importante. Um resíduo constante, mesmo que um pouco alto pode ser um bom resultado, na medida em que limite o grau de incerteza. No nosso caso tanto o nível final do resíduo quanto a incerteza associada são pequenos. Isto nos leva ao próximo passo; previsão.

#### 4.3 Predição da Carga

A predição da carga necessita da predição das variáveis de entrada – no nosso caso Tendência do PIB, Temperatura Média e Sazonalidade. Este trabalho testará o método tomando um conjunto real destas variáveis. Usaremos a base empregada na explicação para gerar a predição de carga pelo período fevereiro a setembro de 2006 (imediatamente após o período de explicação), comparando-a com a verdadeira.

A Figura 11 mostra os resultados do teste. Pode-se observar que cargas preditas e reais são significativamente semelhantes – a maior parte dos erros fica perto dos 0,5%, sendo o erro máximo ainda inferior a 1% ao final do período. Deve-se observar que em casos reais a previsão das variáveis econômicas e climáticas levaria a maior indeterminação e conseqüentemente a erros de predição maiores.

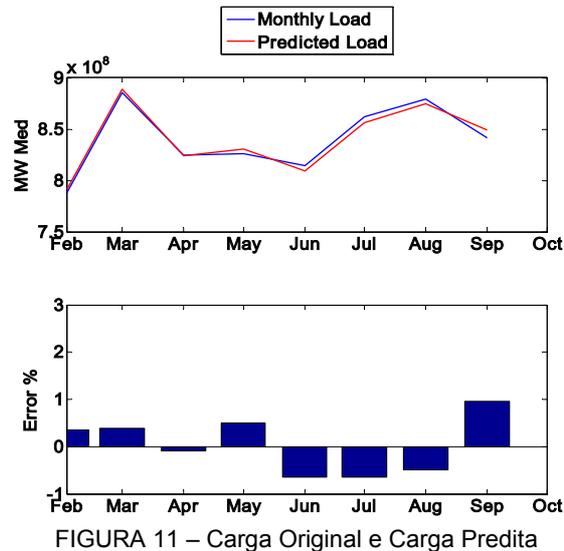


FIGURA 11 – Carga Original e Carga Predita

## 5.0 - CONCLUSÕES

Foi apresentado um novo método para a decomposição e predição da carga elétrica, capaz de modelar a carga mesmo com pouco volume de dados, o que impede a utilização de metodologia clássica, como estatística e neural. Um caso exemplo real suporta a teoria, indicando excelentes resultados tanto na decomposição da carga, quanto na sua predição. Se bem que não incluído no texto por limitação de espaço, a predição proposta foi comparada a outra gerada por método estatístico, utilizando os mesmos dados, indicando ser mais robusta, bastante mais precisa e, portanto, confiável. Deve-se ainda ressaltar que se o volume de dados se tornar substancial, o método proposto pode coincidir com as técnicas estatísticas. Na realidade, uma das vantagens deste trabalho é que o método se adapta ao volume e à dinâmica dos dados o que é de utilidade quando há variações acentuadas, como por causas tecnológicas, migração de clientes, variabilidade de preços, troca de regras, etc.

Esperamos assim ter oferecido uma contribuição à área de Previsão de Mercado – que certamente necessitará de ferramentas precisas e eficientes para fazer face a um dos maiores desafios do setor.

## 6.0 - REFERÊNCIAS BIBLIOGRÁFICAS

- (1) Song, K-B, Ha, S-K, Park, J-W, Kweon, D-J, Kim, K-H., "Hybrid load forecasting method with analysis of temperature sensitivities", IEEE Transactions on Power Systems, Vol. 21, Issue: 2 May 2006, Page(s): 869- 876
- (2) Li, R., Li, J.H., Li, H.M., "The short-term electric load forecasting grid model based on MDRBR algorithm", Power Engineering Society General Meeting, June 2006
- (3) Fan, S.; Chen, L., "Short-term load forecasting based on an adaptive hybrid method", IEEE Transactions on Power Systems, Vol. 21, Issue 1, Feb. 2006, pp.392- 401
- (4) Liao, G-C, "An evolutionary fuzzy neural network approach for short-term electric power load forecasting", IEEE Power Engineering Society General Meeting, June 2006
- (5) Song, K-B., Baek, Y-S., Hong, D.H., Jang, G., "Short-term load forecasting for the holidays using fuzzy linear regression method", IEEE Transactions on Power Systems, Vol. 20, Issue 1, Feb. 2005, pp.96- 101
- (6) Mori, H.; Ohmi, M, "Probabilistic short-term load forecasting with Gaussian processes", Intelligent Systems Application to Power Systems, 2005. Proceedings of the 13th International Conference on Intelligent Systems Application to Power Systems, 2005.
- (7) Reis, A.J.R., da Silva, A.P.A., "Feature extraction via multiresolution analysis for short-term load forecasting", IEEE Transactions on Power Systems, Vol. 20, Issue 1., Feb. 2005, pp. 189- 198
- (8) Chen, B-J., Chang, M-W., Lin, C-J., "Load forecasting using support vector Machines: a study on EUNITE competition", IEEE Transactions on Power Systems, Vol. 19, Issue 4, Nov. 2004, pp. 1821- 1830
- (9) Huang, S-J., Shih, K.R., "Short-term load forecasting via ARMA model identification including non-Gaussian process considerations", IEEE Transactions on Power Systems, Vol. 18, Issue 2, May 2003, pp. 673- 679
- (10) Nagasaka, K. Al Mamun, M., " Long-term peak demand prediction of 9 Japanese power utilities using radial basis function networks", Power Engineering Society General Meeting, 2004, pages 315 - 322 Vol.1
- (11) Khoa, T.Q.D. Phuong, L.M. Binh, P.T.T. Lien, N.T.H., "Application of wavelet and neural network to long-term load forecasting", PwerCon, vol. 2004, Volume: 1, pages: 840 - 844 Vol.1
- (12) Mori, H.; Kosemura, N.; Kondo, T.; Numa, K, ".Data mining for short-term load forecasting", IEEE Power Engineering Society Winter Meeting, 2002, Vol.1, pp. 623- 624
- (13) Pinto, L., Szczupak, J., Macedo, L, Szczerbacki, C., Pascon, J, Almeida, C, Semolini, R., "A New Approach to Load Forecast: Incorporating Climate, Economic and Social Behavior Predictions", IEEE Powertech, St. Petersburg, 2005
- (14) L.E.Franks, Signal Theory, Prentice Hall,1969.
- (15) Lokenath Debnath and Piotr Mikusinski, Introduction to Hilbert Spaces with Application, 1999, Academic Press.
- (16) N.I.Akhiezer, I.M.Glazman, Theory of Linear Operators in Hilbert Space,1988, Dover
- (17) Simon Haykin, Adaptive Filter Theory (4th Edition), Prentice Hall, 2001
- (18) S. K. Mitra, Digital Signal Processing – A Computer-Based Approach, McGraw-Hill, 1998