



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

GPL 01
14 a 17 Outubro de 2007
Rio de Janeiro - RJ

GRUPO VII

GRUPO DE ESTUDO DE PLANEJAMENTO DE SISTEMAS ELÉTRICOS - GPL

MERCADO DE ENERGIA ELÉTRICA: DESENVOLVIMENTO DE UMA FERRAMENTA COMPUTACIONAL PARA PREDIÇÃO DECENAL

**Mayse Regal Maia ^{(1) *} Kátia de Oliveira Gonçalves Veloso ⁽¹⁾ Miriam Terumi Okamoto ⁽¹⁾
Nelson F. F. Ebecken ⁽²⁾ Alexandre Gonçalves Evsukoff ⁽²⁾ Marco Aurélio Fernandes Zarur ⁽²⁾
Guilherme Saad Terra ^(2,4) Angelo Maia Cister ⁽²⁾ Fábio Teodoro de Souza ⁽²⁾
Alexandre dos Santos Rigueira ⁽³⁾ Geraldo Martins Tavares ⁽³⁾**

⁽¹⁾ **FURNAS CENTRAIS ELÉTRICAS S.A.**
⁽²⁾ **NTT, COPPE/Universidade Federal do Rio de Janeiro – UFRJ**
⁽³⁾ **UFF, Universidade Federal Fluminense**
⁽⁴⁾ **CEFET – Campos/UNED - Macaé**

RESUMO

Este trabalho apresenta os resultados de pesquisa desenvolvida por FURNAS, dentro do Programa de P&D da ANEEL, para o desenvolvimento de sistema computacional de previsão de carga de longo prazo, no horizonte de 10 anos. O sistema computacional desenvolvido para previsão decenal do mercado do setor elétrico considerou análises macroeconômicas e todo o conhecimento disponível. Devido às condições especiais da economia brasileira, foi utilizada na construção do sistema uma abordagem dinâmica e flexível. O sistema construído é baseado em conhecimento e em outras técnicas avançadas de mineração de dados. Neste sistema é possível a intervenção do especialista para modificar e atualizar, de acordo com a sua sensibilidade, dados da realidade nacional e internacional bem como a influência de variáveis ao longo do tempo, de forma a permitir um ajuste contínuo das previsões aos cenários considerados.

No presente trabalho, duas abordagens são utilizadas para fazer a previsão do consumo de energia elétrica no horizonte de 10 anos: redes neurais e regressão linear (modelo causa/efeito). As séries históricas usadas no desenvolvimento dos modelos foram: PIB, salário mínimo, preço da energia elétrica, população, número de consumidores e consumo de energia elétrica.

Os resultados dos dois modelos são coerentes entre si e com outros modelos que utilizam uma quantidade significativamente maior de dados. Durante a análise do sistema computacional desenvolvido ficou evidenciado que não existe apenas um modelo ideal, e sim diversos plausíveis, ou seja, que alguns modelos estudados são tão eficazes quanto os dois preconizados neste trabalho: Rede Neural e Causa/Efeito. Portanto, pode-se afirmar com segurança que o fator determinante para escolha do modelo passa, sobretudo, pela quantidade e qualidade das informações e recursos disponíveis.

PALAVRAS-CHAVE

Predição Decenal, Mercado, Setor Elétrico, Consumo, Cenários, Mineração de Dados, Redes Neurais

1.0 - INTRODUÇÃO

O consumo de energia elétrica, especialmente no Brasil, país que ainda possui um amplo potencial de crescimento e disseminação da utilização deste produto, tem expectativas de crescimento bastante acentuadas, no médio e longo prazo. As projeções sobre a demanda futura de energia elétrica são fundamentais para os

estudos de planejamento da expansão, que irão apontar para as necessidades de acréscimo da oferta para atender a esta demanda, bem como da expansão da transmissão que fará a integração destas novas fontes geradoras.

Para tal, as projeções são baseadas em acompanhamento e a caracterização atual do mercado consumidor de energia elétrica no país, incorporando o conhecimento aprofundado dos vários segmentos de consumo, em especial dos setores industriais, grandes consumidores de eletricidade. Face à estreita relação entre o comportamento de economia e o consumo de eletricidade, a conjuntura econômica também foi analisada visando subsidiar a construção de cenários macroeconômicos, base dos estudos prospectivos de mercado.

Ao longo da realização deste sistema computacional, buscou-se determinar o melhor modelo para determinação da predição decenal do consumo de energia elétrica no Brasil. Inúmeras técnicas foram estudadas e testadas no intuito de formalizar um modelo adequado às necessidades de FURNAS.

Nos últimos anos, diversos artigos foram publicados descrevendo sistemas para a projeção do mercado de energia elétrica [1, 2, 3, 4]. Projeções para o curto, médio e longo prazo foram realizadas utilizando-se modelos estatísticos tradicionais e técnicas especiais de "data mining" (mineração de dados) como redes neurais [5], algoritmos genéticos, modelos "neuro-fuzzy" [6], entre outros.

Em especial, os modelos neurais apresentam algumas características que os fazem atrativos para as áreas de projeção [7], tais como: (a) é um método auto-adaptado direcionado pelos próprios dados – o conhecimento é capturado pelo modelo através de exemplos, ou seja, aprendendo com a experiência; (b) depois do aprendizado, ele apresenta capacidade de generalização, (c) ele aproxima qualquer função contínua com a precisão desejada; (d) é um modelo não linear, o que o torna bem mais genérico.

Considerando a relação existente entre os diferentes dados relacionados a um fenômeno, o modelo baseado nesta técnica oferece um grande potencial de precisão na obtenção de projeções do consumo de energia. Para a predição do consumo de energia elétrica num horizonte de 10 anos foram desenvolvidos dois modelos: um baseado nas técnicas de inteligência computacional – redes neurais e algoritmos genéticos, e outro nos métodos estatísticos econométricos – causa e efeito. As séries históricas usadas no desenvolvimento dos modelos foram: PIB, salário mínimo, preço da energia elétrica, população, número de consumidores e consumo de energia elétrica.

Ficou certo que não existe apenas um modelo ideal, e sim diversos plausíveis, ou seja, que alguns modelos estudados são tão eficazes quanto os dois preconizados neste trabalho, Rede Neural e Causa/Efeito. Portanto, pode-se afirmar com segurança que o fator determinante para escolha do modelo passa pelas informações e recursos disponíveis, assim, preponderantes para a consecução do sistema.

Desde o período de racionamento, as áreas de planejamento que estudam o mercado de energia elétrica adotaram como modelos mais adequados os baseados no conhecimento de especialistas, que supostamente poderiam antecipar, ou na pior das hipóteses, levar em consideração eventos desse tipo, em detrimento daqueles que levam em consideração apenas o histórico e a evolução do consumo.

Com os modelos idealizados e já testados, buscou-se a utilização de técnicas modernas de "data mining" (mineração de dados), extraindo conhecimento não dos especialistas, mas sim das bases de dados levantadas.

A exploração desse conhecimento foi precedida do aprofundamento do estudo dos dados existentes do mercado, onde se consumiu grande parte do tempo do projeto, não só com as etapas de levantamento, mas também com as de formulação e consolidação das mesmas, através da análise do comportamento das variáveis, suas correlações e de suas curvas, também fazendo uso da mineração de dados, através de técnicas computacionais de alto desempenho.

2.0 - RESUMO DA METODOLOGIA

O desenvolvimento do trabalho foi orientado por uma metodologia bem definida, dividida em etapas. A metodologia pode ser descrita através das seguintes etapas:

1ª Etapa - Análise das metodologias existentes - Nesta etapa foi efetuado o estudo das metodologias atualmente utilizadas no setor elétrico. Foram confrontadas também outras metodologias já utilizadas em outras experiências e aplicações.

2ª Etapa - Análise da conjuntura através de estudos de cenários - A área de macroeconomia e política forneceu insumos sob a forma de análise econômica e política para tomada de decisões empresariais.

3ª Etapa - Ampla definição de variáveis - Nesta etapa foram estudadas todas as variáveis surgidas nos estudos e cenários bem como outras variáveis que podiam surgir em prospecção de longo prazo. A validação foi efetuada utilizando técnicas de mineração de dados.

4ª Etapa - Coleta e preparação dos dados - Preparar os dados, que consiste em transformar os dados brutos disponíveis em uma base de dados adequada ao processo de "data mining" - o objetivo dessa etapa foi a obtenção de uma base de dados, formada por um subconjunto dos dados disponíveis, que serviu como base para todas as atividades de modelagem, avaliação e operação do sistema. Nessa fase foram executadas atividades de armazenamento e seleção de atributos dos dados, bem como de transformação e limpeza dos dados que foram utilizados nas ferramentas de modelagem.

5ª Etapa - Análise dos dados - Nesta etapa foi efetuada a consistência e o entendimento de todos os dados adquiridos e considerados relevantes.

6ª Etapa - Análise das incertezas - Nesta etapa foi efetuado o estudo das incertezas contidas em todas as variáveis.

7ª Etapa - Projeto do sistema - Construiu-se o projeto do modelo do protótipo do sistema computacional - nessa fase, várias técnicas de modelagem foram selecionadas e aplicadas e os seus parâmetros otimizados.

8ª Etapa - Implementação do sistema - Nesta etapa o sistema foi implantado. Antes de instalá-lo foi feita uma avaliação rigorosa do mesmo e revisados todos os passos executados para sua construção, com o fim de verificar se algum dos requisitos importantes para que o protótipo atinja seus objetivos não tenha sido considerado com a profundidade suficiente.

9ª Etapa- Análise de resultados - Nessa etapa foi avaliado o protótipo do sistema. É necessário que o protótipo do sistema seja implantado e operado pelo pessoal de FURNAS, inicialmente com o apoio da equipe da pesquisa. Além disso, é necessário que os resultados sejam avaliados continuamente para que o sistema ganhe a confiança da equipe de FURNAS e seja efetivamente utilizado por ela.

3.0 - MODELOS SELECIONADOS PARA O SISTEMA

Foram desenvolvidos modelos (1) causa-efeito e (2) não-lineares (redes neurais artificiais) para a previsão do *Consumo de Energia Total*, tendo como suporte à projeção dos indicadores de entrada modelos auto-regressivos.

A definição dos sistemas utilizados foi a seguinte:

- S1 - Sul;
- S2 - Sudeste + Centro-Oeste;
- S3 - Nordeste + Maranhão;
- S4 - Norte Interligado;
- S5 - Norte Isolado.

As categorias utilizadas foram as seguintes:

- C1 -Residencial;
- C2 - Industrial;
- C3 - Comercial;
- C4 - Outras.

A previsão de mercado no horizonte 2004-2014 foi feita com base em três cenários macroeconômicos similares aos adotados, na época, pelo Comitê Técnico para Estudos de Mercado - CTEM / ELETROBRÁS e utilizadas no planejamento do setor elétrico brasileiro, cujas projeções oficiais são anualmente enviadas ao Ministério de Minas e Energia - MME:

- Cenário A – otimista;
- Cenário TRA – mais provável, realista;
- Cenário B – pessimista.

4.0 – MODELO CAUSA E EFEITO

Este modelo surgiu durante a realização das etapas relacionadas à preparação da base de dados. A busca de inconsistência na base de dados passou por diferentes estágios. O primeiro ficou concentrado única e exclusivamente nas respectivas séries, ou seja, buscava-se naquele momento encontrar valores nitidamente não justificáveis, caracterizados por descontinuidades, grandes variações absolutas e/ou relativas. O segundo estágio contemplou o estudo de séries derivadas, ou seja, foram construídos índices e analisados os respectivos comportamentos – crescimento, variações absolutas e/ou relativas.

Como a obtenção da série “Consumo de energia elétrica” para as diferentes categorias está intrinsecamente relacionada ao desempenho econômico do país, esta foi a razão para a busca de índices construídos a partir de séries que apresentam relacionamentos causa-efeito.

Esta ferramenta foi desenvolvida com o propósito de permitir que os futuros usuários do sistema consigam atualizar a base de dados de forma consistente e que ao trabalharem com a ferramenta de visualização aprimorem a percepção em relação às séries relevantes para o sistema de previsão. Com relação às séries derivadas, cabe destacar que as previsões feitas com um determinado modelo, para um determinado cenário de desenvolvimento econômico, implicam em valores futuros para os índices derivados que podem e devem ser visualizados a fim de checar a coerência das previsões.

O modelo batizado de Causa e Efeito (CE) preconiza a relação linear crescente ao longo do tempo do índice que representa o quanto é gerado em bilhões de Reais por densidade de consumo (MWh ano), ou seja:

$$I(t) = \frac{PIB(t)}{\rho_{classe}(t)} = \frac{PIB(t)}{\frac{Consumo_{classe}(t)}{NumConsumidor_{classe}(t)}} = A * t + B$$

Com as projeções do PIB, Número de Consumidores e o índice descrito acima foi possível determinar o consumo representado pela expressão:

$$Consumo_{classe}(t) = \frac{NumConsumidor_{classe}(t) \times PIB(t)}{(A * t + B)}$$

:

Os coeficientes A e B , sendo definidos a partir dos valores dos anos pós-acionamento (2002, 2003 e 2004), permitem que o índice $I(t)$ seja extrapolado e, em conjunto com a projeção do Número de Consumidores e do PIB, venha a se determinar o consumo futuro.

Na figura 1, a projeção do consumo adotada, na época, oficialmente pelo setor elétrico brasileiro (CTEM/ELETROBRÁS) no intervalo 2004-2014 para os diferentes cenários é comparada com a previsão obtida no modelo causa-efeito.

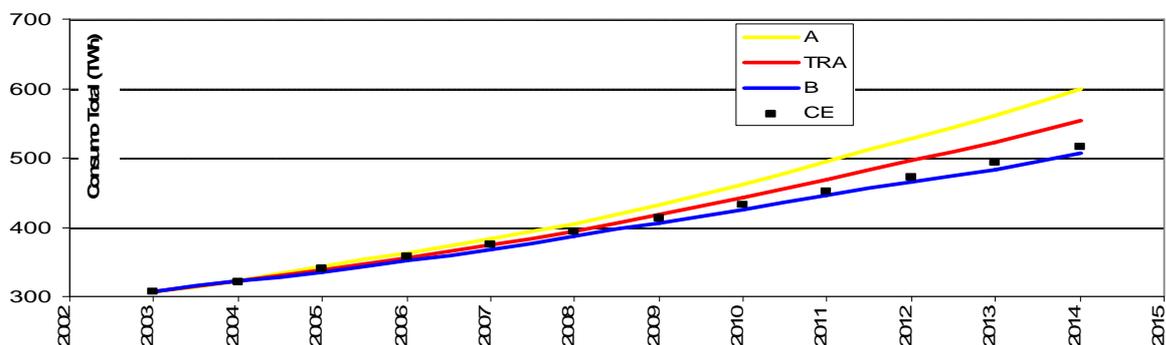


Figura 1 – CONSUMO TOTAL (TWh) – MODELO CAUSA E EFEITO

5.0 – MODELO DE REDES NEURAIAS OTIMIZADAS POR ALGORITMOS GENÉTICOS

O modelo RNA é baseado em conhecimento e técnicas avançadas de computação, tais como, redes neurais, algoritmos genéticos e reamostragem “bootstrap”. Como diferencial competitivo em relação aos demais métodos mais utilizados em projeções pode-se destacar seu caráter dinâmico, uma vez que é possível a intervenção do especialista para modificar, de acordo com a sua sensibilidade e com dados atualizados da realidade nacional e internacional, a influência de variáveis ao longo do tempo, de forma a permitir um ajuste contínuo, e adequar as previsões às novas realidades.

Portanto, à medida que os valores verdadeiros ou inferências forem sendo incluídos, o modelo permitirá a inserção dos valores ou taxas, possibilitando em tempo real a atualização dos valores da previsão de consumo, ano a ano.

Em contraponto, os modelos mais utilizados demandam recursos e logística complexa para determinação dos cenários e, passados os primeiros anos de sua implantação, necessitam de nova análise dos resultados, invariavelmente determinando a confecção de um novo estudo de cenarização.

Vale lembrar que as Redes Neurais Artificiais (RNA's) são modelos conexionistas capazes de tratar problemas complexos. As RNA's podem aprender através de exemplos; possuem tolerância a erros, pois elas são habilitadas para manusear ruídos e dados incompletos; são capazes de proceder com problemas não lineares; e, uma vez treinadas, podem realizar previsões e generalizações com alta precisão.

Uma vez determinada a previsão do consumo total de energia elétrica (consumo Brasil no horizonte decenal), a análise dos valores para os sistemas, assim como para as categorias (residencial, comercial e industrial) é feita através da decomposição percentual dos valores de contribuição de cada um per si.

6.0 – ANÁLISE DOS RESULTADOS

Durante a realização do projeto a base de dados foi consolidada a partir de fontes governamentais, na maior parte dos casos, que apresentavam para uma determinada informação, valores diferentes. Esta realidade direcionou os trabalhos para a formação de um ferramental para facilitar a execução da etapa que consome grande parte do projeto de Mineração de Dados, ou seja, preparação da base de dados (coleta, consistência, análise, transformações, etc.).

Devido às características da aplicação (quantidade de dados em questão), todas as informações e aplicativos necessários para análise foram mantidos neste ambiente. Esta decisão permitirá que os usuários do sistema continuem a manipular com facilidade a base de dados, atualizando-a e tendo ferramentas para estudar e consolidar as novas informações. O produto desenvolvido foi mantido neste ambiente com interface amigável para o usuário.

As projeções por classe e subsistema dos modelos RNA e Causa-Efeito seguiram a mesma proporção do cenário TRA (mais provável), adotado oficialmente, na época, pelo setor elétrico nacional.

Na figura 2, abaixo, são apresentadas as participações do consumo por classe e subsistema para os anos 2004 e 2014, evidenciando a ligeira modificação projetada para o período. A escolha de uma outra distribuição é livre, sendo sempre pertinente estudar a evolução dos índices utilizados.

	VALORES (TWh)				PARTICIPAÇÃO (%)			
	2004	2014			2004	2014		
		A	TRA	B		A	TRA	B
Total	321,8	599,3	553,8	507,1				
residencial	78,9	152,2	142,2	129,8	24,5	25,4	25,7	25,6
industrial	145,8	273,8	249,3	218,5	45,3	45,7	45,0	43,1
comercial	50,1	99,7	90,6	85,2	15,6	16,6	16,4	16,8
outros	47,1	73,6	71,6	73,6	14,6	12,3	12,9	14,5
N Iso	6,7	15,6	15,6	15,6	2,1	2,6	2,8	3,1
Sist Int	315,2	583,6	538,1	491,5	97,9	97,4	97,2	96,9
N Int	22,2	60,8	55,2	50,6	6,9	10,1	10,0	10,0
Nd Int	45,3	92,4	82,2	72,6	14,1	15,4	14,8	14,3
SE/CO	192,3	329,8	308,4	282,4	59,7	55,0	55,7	55,7
Sul Int	55,4	100,6	92,3	85,9	17,2	16,8	16,7	16,9

Figura 2– PROJEÇÃO POR CLASSE PARA OS TRÊS CENÁRIOS – MODELO CAUSA-EFEITO

Os valores preconizados pelo modelo causa-efeito são ligeiramente superiores ao projetado pelo cenário pessimista (B), sendo este ligeiramente superior ao projetado pelo modelo RNA. O modelo RNA fornecerá valores diferentes se um cenário diferente para as variáveis que utiliza, for escolhido. O modelo Causa-Efeito depende apenas da projeção do PIB Brasil e da projeção do número de consumidores brasileiro.

	VALORES (TWh) - MODELO CAUSA-EFEITO, RNA E CENÁRIOS A, TRA e B										
	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014
Total(A)	321,8	343,0	362,7	383,3	404,8	433,0	461,7	494,4	527,9	561,1	599,3
Total(TRA)	321,8	338,4	356,5	374,2	394,7	417,6	442,4	469,4	496,5	523,2	553,8
Total(B)	321,8	335,0	352,2	368,6	387,4	405,9	424,9	445,7	465,3	483,5	507,1
Total(CE)	320,9	340,6	357,9	375,5	393,8	412,5	431,8	451,5	472,3	493,6	515,6
Total(RNA)	320,9	328,7	342,0	358,1	376,0	394,8	414,3	434,1	455,3	476,4	497,4

Figura 3 - PROJEÇÃO PARA O CONSUMO TOTAL – MODELO CAUSA-EFEITO E RNA

Considerando os valores da figura 3 acima, cabe destacar que as projeções adotadas oficialmente pelo setor elétrico e utilizadas como balizadoras das saídas das ferramentas desenvolvidas têm em sua essência um viés de alta, respaldado pela certeza de que o desenvolvimento econômico do país depende da energia e a construção/ampliação do parque gerador demanda um longo período. É compreensível neste caso a visão sempre

otimista: o país vai crescer a altas taxas, ocorrerá a distribuição de renda aumentando o poder aquisitivo, a tarifa não subirá a taxas superiores às do crescimento da renda da população, etc.

7.0 – CONSIDERAÇÕES FINAIS E CONCLUSÕES

Os modelos RNA e causa-efeito foram desenvolvidos com base nas séries históricas das variáveis relevantes, buscando, portanto, descobrir as relações não aparentes entre as variáveis, pela aplicação das técnicas de “data mining”.

Para a construção do sistema apresentado, grande investimento foi efetivado no entendimento da modelagem matemática, seleção de conteúdo e simulação do sistema utilizando técnicas de mineração de dados.

A ferramenta foi desenvolvida em um ambiente amigável e de fácil manuseio, através de planilha Excel, cujos gráficos e diversos cenários foram implementados para auxiliar na análise e na tomada de decisão das projeções, conforme mostrada na figura 4.

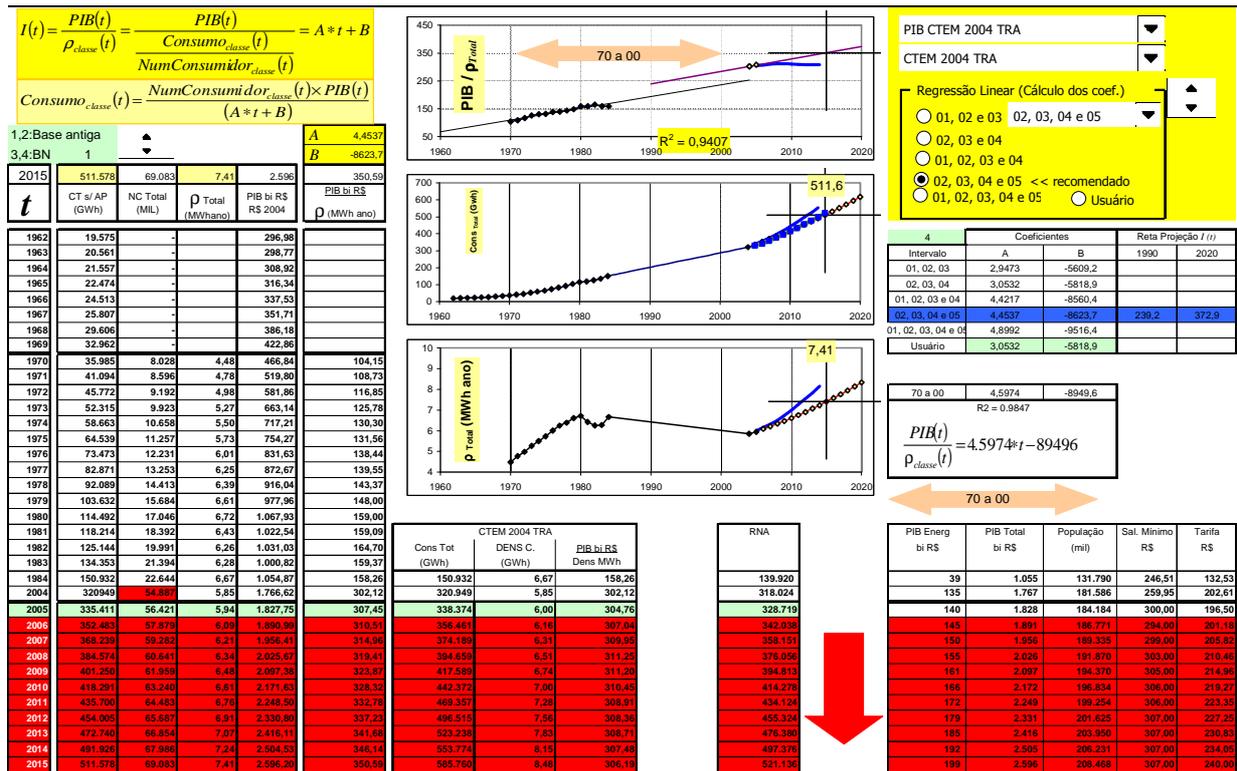


Figura 4 – FERRAMENTA DE PROJEÇÃO RNA E CAUSA-EFEITO

Constata-se, definitivamente, que o modelo Causa-Efeito e o RNA propiciam um ferramental de grande potencial para o planejamento e o apoio à tomada de decisão para o setor energético. As previsões de consumo de energia elétrica deles gerados, através dos cenários simulados, poderão efetivamente ter impacto direto sobre decisões importantes como: Programas Decenais de Expansão da Geração, Transmissão e Distribuição; Estabelecimento de programas de investimentos e de contratos para comercialização de energia; Leilões de Energia; dentre outras.

8.0 – REFERÊNCIAS

- [1] Chen, G. J., Li, K. K., Chung, T. S., Sun, H. B. & Tang, G. Q., Application of an innovative combined forecasting method in power system load forecasting, *Electric Power Systems Research*, 59; pp. 131-137, 2001.
- [2] Hippert, H. S., Pedreira, C. E. & Souza, R. C., Neural Net-works for short-term load forecasting: A Review and Evaluation, *In IEEE Transactions of Power Systems*, 16(1), pp. 44-55, 2001.
- [3] Gavrilas, M., Ciutea, I. & Tanasa, C., Medium-term load forecasting with artificial neural network models, *Proc. of the 16th International Conference and Exhibition on Electricity Distribution*, Part 1: Contributions. CIRED. (IEE Conf. Publ No. 482), 6, pp. 167–171, 2001.
- [4] Chen, G. L., Li, K. K., Chung, T. S., Sun, H. B. & Tang, G. Q., Application of an innovative combined forecasting method in power system load forecasting, *In Electric Power Systems Research*, 59, pp. 131-137, 2001.
- [5] Al-Saba, T., El-Amin, I., Artificial Neural Networks as applied to long-term demand forecasting, *In Artificial Intel-ligence in Engineering*, 13, pp. 189-197, 1999.
- [6] Padmakumari, K., Mohandas, K. P. & Thiruvengadam, S., Long Term distribution demand forecasting using neuro fuzzy computations, *In Electrical Power and Energy Systems*, 21, pp. 315-322, 1999.
- [7] Zhang, G., Patuwo, B. E. & Hu, M. Y., Forecasting with artificial neural networks: The state of the art, *International Journal of Forecasting*, 14, pp. 35–62, 1998.

9.0 – BIBLIOGRAFIA

- [1] Abreu, M. Pereira de., "Um estudo classificatório das ferramentas tecnológicas envolvidas em um processo de gestão do conhecimento". Tese de mestrado COPPE/UFRJ, março de 2002.
- [2] Arouca, Mauricio Cardoso. Gomes, Frederico Birshal M. Rosa, Luis Pinguelli. Estrutura da Demanda de Energia no Setor Residencial no Brasil. COPPE/ Universidade Federal do Rio de Janeiro; 1983.
- [3] Arouca, Mauricio Cardoso. Rosa, Luis Pinguelli. Altomonte, Hugo. Consumo Residencial de Energia e Distribuição de Renda, Universidade das Nações Unidas. 1985.
- [4] Bentley, Peter J.. *Biologia Digital: Como a Natureza Está Transformando a Tecnologia e Nossas Vidas*. Ed. Berkeley, 2002.
- [5] Bigus, Joseph P.. *Data Mining With Neural Networks, Solving Business Problems, From Application, Development to Decision Support*. McGraw Hill.
- [6] FAHEY, Liam; RANDALL, Robert M. *Learning from the future. Competitive foresight scenarios*. John Wiley & Sons, 1998.
- [7] Fayyad, Piatetsky-Shapiro, Smyth e Uthurusamy. *Advances in Knowledge Discovery and Data Mining*. AAAI / MIT press.
- [8] HAYKIN, Simon. *Redes Neurais Princípios e Práticas*. Ed. Bookman, 2001.
- [9] MILLETT, Stephen M. Los Angeles 2007: Implication of a scenario analysis for energy forecasting. *Planning Review*. 1992.
- [10] ICDM'98 - Data Mining, WITPress, Southampton UK 1998.
- [11] ICDM'00 - Data Mining, WITPress, Southampton UK 2000.
- [12] ICDM 02,03,04,05 - Data Mining, WITPress, Southampton UK 2002,2003,3004,2005.
- [13] *Sistemas Inteligentes* - Editora Manole 2002.
- [14] HARP, S. A., SAMAD, T., 1991, "Genetic Synthesis of Neural Network Architecture". In: L. Davis, editor, *Handbook of Genetic Algorithms*, International Thomson Computer Press, pp 202-221.
- [15] CUROTTO, C.L., EBECKEN, N.F.F., "Implementing Data Mining Algorithms in Microsoft SQL SERVER", WIT Press, Southampton, 2005.
- [16] Zarur, M.A.F., "Modelo para Elaboração de Cenários do Setor Energético, Utilizando Técnicas de Data Mining", Tese de Mestrado, COPPE/UFRJ, 2005.
- [17] Terra, G.S., "UMA METODOLOGIA DE MINERAÇÃO DE DADOS PARA PREVISÃO DE CARGAS", Tese de Doutorado, COPPE/UFRJ, 2003.
- [18] Roitman, V.L., "Um modelo computacional de redes para Predição do Índice de Desempenho Aberto, Tese de Doutorado, COPPE/UFRJ, 2001.
- [19] Mendonça, C.E.L.R., "Um Sistema Computacional para Otimização através de Algoritmos Genéticos e Redes Neurais", tese de Doutorado COPPE/UFRJ, 2004.
- [20] Hruschka, E.R., "Imputação Bayesiana no Contexto da Mineração de Dados", Tese de doutorado COPPE/UFRJ, 2003.
- [21] Braga, Antônio de P.; Carvalho, André P. de L. F.; Ludermit, Teresa B.; *Fundamentos de Redes Neurais Artificiais*, 11a Escola de Computação, Rio de Janeiro, julho de 1998.
- [22] Jang, J.; Sun, C.; Mizutani, E.; *Neuro Fuzzy & Soft Computing A Computational Approach to Learning & Machine Intelligence*. Prentice Hall, 1997.
- [23] McNelis, P.D., "Neural Networks in Finance : Gaining Predictive Edge in the Market", Elsevier, 2005.
- [24] Han, J., Kamber, M. "Data Mining: Concepts and Techniques", Morgan Kaufmann, 2005.

10.0 - DADOS BIOGRÁFICOS

Mayse Regal Maia

Nascida no Rio de Janeiro, RJ em 13 de janeiro de 1958

MBA (2002) em Gestão Empresarial: UCAM-RJ; Pós Graduação (1990) em Planejamento Energético: COPPE/UFRJ e Graduação (1980) em Engenharia Civil: PUC-RJ

Empresa: FURNAS Centrais Elétricas S.A., desde 1980, Gerente da Divisão de Estudos Econômicos e de Mercado

Katia de Oliveira Gonçalves Veloso

Nascida no Rio de Janeiro, RJ, em 24 de julho de 1969

Pós Graduação (1997) em Engenharia Econômica: UERJ e Graduação (1995) em Engenharia de Produção: UFRJ

Empresas: Banco Nacional S.A. (1993–1995)

Metal Data Ltda. (1996)

FURNAS Centrais Elétricas S.A., desde 2000, Engenheira da Divisão de Estudos Econômicos e de Mercado

Míriam Terumi Okamoto

Nascida no Rio de Janeiro, RJ, em 06 de agosto de 1971

Pós Graduação (1999) em Engenharia de Produção: UFF e Graduação (1995) em Engenharia de Produção Elétrica: PUC-RJ

Empresas: Membrana Digital Ltda. (1996)

Rio Ship Management (1997)

FURNAS Centrais Elétricas S.A., desde 2000, Engenheira da Divisão de Estudos de Econômicos e de Mercado

Nelson Francisco Favilla Ebecken

Nascido em Niterói, RJ, em 18 de abril de 1949

Doutorado (1977) em Engenharia Civil: COPPE/UFRJ; Mestrado (1973) em Engenharia Civil: COPPE/UFRJ e Graduação (1970) em Engenharia Civil: UFF

Instituição: COPPE/UFRJ, desde 1974, Professor Titular

Alexandre Gonçalves Evsukoff

Nascido no Rio de Janeiro, RJ, em 18 de abril de 1966

Doutorado (1998) em Automatique Productive: INPG/Grenoble - França; Mestrado (1992) em Engenharia Mecânica: COPPE/UFRJ e Graduação (1990) em Engenharia Mecânica: UFRJ

Instituição: COPPE/UFRJ, desde 2002, Professor Adjunto

Marco Aurélio Fernandes Zarur

Nascido no Rio de Janeiro, RJ, em 04 de agosto de 1963

Mestrado (2005) em Engenharia Civil: COPPE/UFRJ; Pós Graduação (1989) em Análise de Sistemas: PUC-RJ, Pós Graduação (1988) em Engenharia Econômica: UGF-RJ; Graduação (1987) em Engenharia Civil: UGF-RJ

Instituição: Companhia Brasileira de Trens Urbanos – CBTU, desde 1988, Engenheiro/Assessor

Guilherme Saad Terra

Nascido em Campos dos Goitacazes, RJ, em 22 de março de 1969

Doutorado (2003) em Engenharia Civil: COPPE/UFRJ; MBA (1999) em Finanças: IBMEC/RJ, Mestrado (1996) em Engenharia Mecânica: COPPE/UFRJ e Graduação (1992) em Engenharia Mecânica: UFRJ

Instituições: CEFET-Campos/UNED-Macaé, (1994-2006), Professor

UFF- Pólo de Rio das Ostras, desde 2006, Professor

Ângelo Maia Cister

Nascido no Rio de Janeiro, RJ, em 21 de setembro de 1963

Doutorado (2005) em Engenharia Civil: COPPE/UFRJ; Mestrado (1997) em Engenharia de Sistemas: COPPE/UFRJ e Graduação (1985) em Física: UFRJ

Instituição: UFRJ – Faculdade de Administração e Ciências Contábeis, Professor Adjunto, Coordenador do Curso de Administração

Fábio Teodoro de Souza

Nascido em Santo Antônio da Platina, PR, em 22 de janeiro de 1972

Doutorado (2004) em Engenharia Civil: COPPE/UFRJ; Mestrado (1999) em Engenharia Civil: COPPE/UFRJ e Graduação (1995) em Engenharia Civil: UEPG/RS

Instituições: COPPE/UFRJ, (1996-2005), Pesquisador

UFF-RJ, (2003-2005), Pesquisador

UNIMORE – Itália, Departamento de Economia Política, desde 2006. Pesquisador

Alexandre dos Santos Rigueira

Nascido em Niterói, RJ, em 22 de outubro de 1948

Pós Graduação (1972) em Sistemas de Potência: COPPE/UFRJ e Graduação (1970) em Engenharia Elétrica: UFRJ

Instituições: Centro de Processamento de Dados do Estado do Rio de Janeiro – CPDERJ (1969-1972)

CHESF (1972-1976)

PTEL (1976-1978)

Monasa Consultoria e Projetos (1978-1985)

MDK Engenharia de Projetos Ltda. (1985-1986)

Engevix Informática (1986-1991)

Planave (1998-1999)

A. Rigueira Consultoria Ltda., desde 1999, Sócio-Diretor

Geraldo Martins Tavares

Nascido em São Sebastião do Alto, RJ, em 10 de maio de 1947

Doutorado (1998) em Engenharia de Produção: COPPE/UFRJ; Mestrado (1975) em Engenharia Elétrica: COPPE/UFRJ e Graduação (1970) em Engenharia Elétrica: UFRJ

Empresas/Instituições: CHESF (1971-1972)

ELETROSUL (1972-1976)

MDK Engenharia de Projetos Ltda. (1976-1986)

Engevix S. A. Estudos e Projetos de Engenharia (1986-1989)

UFRJ – Departamento de Engenharia Elétrica, desde 1992, Professor Adjunto