



PREVISÃO DE EFICIÊNCIA ENERGÉTICA NA CENTRAL TERMOELÉTRICA 2 DA COMPANHIA SIDERÚRGICA NACIONAL ATRAVÉS DE REDES NEURAIS ARTIFICIAIS¹

Nelson Neves Teixeira²
José Adilson de Castro³

Resumo

Este estudo propõe um método alternativo para a previsão de eficiência energética (energia elétrica, vapor, ar soprado) para a CTE2 da CSN, através do desenvolvimento de um modelo de avaliação baseado em RNA's. A metodologia Destaca os principais fatores que devem pautar a modelagem de um sistema baseada em redes neurais artificiais, os quais são: seleção das variáveis de entrada; quantidade de variáveis; arquitetura da rede; treinamento; previsão da saída visando a aplicação para previsão da eficiência energética em centrais termoeletricas. O modelo ora apresentado foi desenvolvido a partir da arquitetura MLP (Multi Layer Perceptron) e usa um conjunto de dados de consumo de gás natural, Gases Siderúrgicos (Gás de Coqueria - GCO, Gás de Alto de Forno - GAF, e Gás Aciaria - GLD), Óleo Combustível e Alcatrão, nos anos de Jan./2008 a Mai./2011 para o treinamento. Os resultados de previsão foram comparados com os valores medidos do período em questão, bem como previsões de um modelo previamente desenvolvido baseado no método de regressão multilinear. Resultados de previsões utilizando a rede neural desenvolvida apresentaram superiores concordância com os resultados de monitoramento quando comparados com o método de regressão multilinear.

Palavras-chave: RNA; Termoelétrica; Eficiência energética.

FORECAST OF ENERGY EFFICIENCY IN THERMOELECTRIC PLANT 2 OF COMPANHIA SIDERÚRGICA NACIONAL THROUGH ARTIFICIAL NEURAL NETWORKS Abstract

This study proposes an alternative method for predicting energy efficiency (electricity, steam, air blown) for the second thermoelectric plant of Companhia Siderúrgica Nacional, by developing an evaluation model based on RNA. The methodology highlights the main factors that will govern the model a system based on artificial neural networks, which are: selection of input variables, number of variables, network architecture, training, forecasting output the application in order to predict the efficiency energy in power plants. The model presented here was developed from the architecture MLP (Multi Layer Perceptron) and uses a data set of natural gas consumption, Gas, Steel (Coke oven gas - GCO, blast furnace gas - GAF, and Gas Steelmaking - GLD), Fuel Oil and Oil Tar in the years January 2008 to May 2011 for training. The prediction results were compared with the measured values of the period in question, as well as predictions of a model previously developed method based on regression multilinear. Results of predictions using the developed neural network showed higher agreement with the results of monitoring when compared with the multilinear regression method.

Key words: RNA; Thermal; Energy efficiency.

¹ Contribuição técnica ao 33º Seminário de Balanços Energéticos Globais e Utilidades e 27º Encontro de Produtores e Consumidores de Gases Industriais, 22 a 24 de agosto de 2012, Belo Horizonte, MG.

² Eng. Metalúrgico. Mestrando em Engenharia Metalúrgica. Área de Concentração - Modelamento e Simulação de Processos e Fenômenos - EEIMVR - UFF.

³ Eng. Metalúrgico. Prof. Ph. D. da EEIMVR - UFF.



1 INTRODUÇÃO

O estudo das Redes Neurais Artificiais tem alta relevância para os pesquisadores de Inteligência Artificial, sendo objeto de crescentes pesquisas e servindo como valiosa ferramenta para diversas aplicações. Uma das principais metas do planejamento, segundo é diminuir o impacto das incertezas relacionadas ao futuro de qualquer organização. Prever o futuro passou a ser o foco da empresa moderna, através do estudo do comportamento de um conjunto de variáveis e da conseqüente ação para alcançar determinados objetivos com a máxima eficiência possível.

Os modelos baseados em ferramentas matemáticas e estatísticas ainda hoje são amplamente usados. Entretanto, devido ao acelerado avanço tecnológico observado nas duas últimas décadas, as pesquisas passaram a ser direcionadas para o uso de ferramentas mais modernas para desempenhar a tarefa de fazer previsões. Ainda que, a partir de 1987, tenham sido publicados vários artigos utilizando metodologias mais avançadas (por exemplo, algoritmos genéticos, lógica difusa e redes neurais) em modelos de previsão, tais modelos têm, em sua maioria, se concentrado na área econômica⁽¹⁾ como a previsão em bolsas de valores, em séries econômicas e na previsão de preços de petróleo.

A pesquisa de novos métodos de previsão de eficiência energética tem sido o alvo de estudos de pesquisadores e de planejadores da área de sistemas de energia, pelo acelerado crescimento da carga. Deste modo, vários pesquisadores têm mostrado uma maior inclinação por modelos mais eficientes para a análise e a previsão de demanda de energéticos.⁽¹⁾ Recentemente foi que o Brasil começou a dar seus primeiros passos em direção a modelos que utilizem tecnologia mais avançada para a previsão da demanda de energia.^(2,3) Até o presente momento, o que se vê são modelos tradicionais – baseados em séries temporais – sendo utilizados na previsão de demanda apenas de energia elétrica.^(4,5) A relação entre a carga e seus fatores exógenos tem caráter complexo e não-linear, o que torna estas previsões difíceis de serem modeladas para a energia elétrica, através de técnicas convencionais, tais como as séries temporais e a regressão linear.⁽⁶⁾ Buscar eficiência em um cenário com tantas variações é tarefa extremamente árdua, considerando-se as contingências apresentadas no Brasil, que exige grande flexibilidade de critérios de ordem econômica, financeira, empresarial, ambiental e outros, que sempre ocorrem ao longo do tempo, devido à dimensão continental. Isso implicou na necessidade de desenvolvimento no setor elétrico focando principalmente na criação de condições para a retomada dos investimentos na expansão do sistema de geração de energia, ainda mais no setor siderúrgico.

Com a implantação da nova Central Termoelétrica 2 na CSN com *start up* com gás natural a uma eficiência energética projetada de 35% (aceite de partida da planta com maior consumo de gás natural do que gases siderúrgicos) e o resultado médio obtido foi o de 32,27% (período de janeiro a novembro/2008). Com o gradual aumento no custo desse gás, houve a necessidade desenvolver um modelo para a unidade a fim de possibilitar um melhor planejamento de consumo de combustível siderúrgico contra um menor volume de gás natural. A intenção é focada na otimização da absorção de combustíveis siderúrgicos para a geração de energéticos, visando à redução no consumo de Gás Natural.

A CTE2 gera aproximadamente 60% da energia elétrica necessária para a UPV, já os outros 40% de energia é fornecida por fornecedores externos (Itasa e Igarapava). O gerenciamento de combustíveis tem um papel de extrema importância no controle e monitoração da distribuição dos combustíveis, para o máximo aproveitamento de



energia dos gases gerados internamente. O propósito deste estudo é avaliar se os modelos mais modernos são superiores, em particular aqueles baseados em redes neurais artificiais, em eficiência, aos tradicionais, que se norteiam por técnicas estatísticas, ou seja, modelos paramétricos obtidos por regressão estatística.

2 METODOLOGIA

Conforme Maçada,⁽⁷⁾ a pesquisa que utiliza os passos apresentados a seguir, salientando-se que a seqüência não é rígida, mas indica as principais etapas a serem vencidas: a) Definição do Problema; b) Construção do Modelo; c) Solução do Modelo; d) Validação do Modelo; e) Análise dos Resultados.

Para este estudo, foram seguidas as técnicas indicadas na literatura sobre redes neurais para a implementação do modelo de predição,^(8,9) sua solução e a consequente análise dos resultados.

Os principais fatores que devem pautar a modelagem de um sistema, baseado em RNA, são: a) seleção das variáveis de entrada; b) quantidade de variáveis; c) arquitetura da rede; d) treinamento; e) previsão da saída.

Alguns pesquisadores estudaram os efeitos de alguns fatores-chave para a modelagem de várias aplicações. Argumenta-se que o modelo com uma camada oculta é suficiente para funções contínuas e séries temporais.⁽¹⁰⁾ A importância das variáveis de entrada é destacada por Fish e Blodgett.⁽¹¹⁾ Já a preparação dos dados é crucial para o desempenho da rede neural. O número de entradas desempenha papel importante na precisão. Quanto mais treinada a rede, maior sua precisão.

A ferramenta utilizada no desenvolvimento das redes neurais do presente estudo, o software FORTRAN, realiza uma transformação no intervalo [-1, 1] que, é mais eficaz no trato com a função de ativação das camadas ocultas da rede.

Freqüentemente o método da minimização do erro conduz o algoritmo a convergir para mínimos locais. Deste modo, após várias seções de treinamento, ocorrem erros de treinamento – e também de predição – diferentes. Com o propósito de minimizar este problema e de tornar os resultados mais confiáveis, para cada algoritmo deste estudo, foi realizado um conjunto de sessões independentes de treinamento, tomando-se o resultado que apresente o menor erro de predição.

O modelo baseado em RNAs (Perceptron Multicamadas com Retro programação de Erro) deve ser desenvolvido com o auxílio do software baseado no algoritmo Perceptron de Múltiplas Camadas (Multi Layer Perceptron - MLP) através de linguagem FORTRAN desenvolvido no Programa de Pós graduação em Engenharia Metalúrgica da Universidade Federal Fluminense (Simulador RNA).

Os pesos sinápticos (w_{ji}) nas RNA's devem ser multiplicados pelos sinais de estímulo (x_j) e/ou sinais oriundos dos neurônios das camadas internas (y_i) seguida de combinação linear conforme a equação (1), sendo toda a informação desse neurônio repassada ao próximo através de uma função de ativação (equação 2). O neurônio j pode ser descrito matematicamente pelas equações (1, 2).

$$u_j = \sum_{i=1}^m w_{ji} (y_i \vee x_j) \quad (1)$$

$$y_j = \varphi(u_j) \quad (2)$$

As funções de ativação é o da tangente hiperbólica (3), para os neurônios de camadas ocultas e função sigmóide (4), para os neurônios da camada de entrada e saída. A cada sinal de entrada submetido à RNA é apresentada uma resposta



desejada. O sinal de erro (equação 5) é gerado após a realização dos cálculos o sinal de saída da rede for diferente da resposta desejada.

$$\varphi(u_k) = \tanh(u) \quad (3)$$

$$\varphi(u_k) = \frac{1}{1 + \exp(-au)} \quad (4)$$

$$e = d_k - \varphi_k(v_k) \quad (5)$$

A retropropagação pela RNA do sinal de erro altera os valores dos pesos sinápticos através da regra delta generalizada conforme a equação (6). A aprendizagem da RNA ocorre quando o sinal do erro médio quadrático dos neurônios de saída segundo a equação (7) e é minimizado a um valor pré-definido ou anulado.

$$\Delta w_{ji}(n) = \alpha' \cdot \Delta w_{ji}(n-1) + \eta \cdot \delta_j \cdot y_i \quad (6)$$

$$\xi = \frac{1}{2} \sum_{k=0}^m e_k^2 \quad (7)$$

Conforme exposto anteriormente, a RNA utilizou software baseado no algoritmo Perceptron de Múltiplas Camadas (*Multi Layer Perceptron - MLP*), com RNA contendo duas camadas ocultas.

Para a regressão a análise de tendências tecnológicas é baseada na hipótese que os avanços da tecnologia tendem a seguir um processo exponencial de melhoria. A técnica usa dados referentes às melhorias para estabelecer a taxa de progresso e extrapolar a taxa para projetar o nível de progresso no futuro. Os resultados obtidos por essa técnica são basicamente quantitativos. Na prática, é utilizada para projetar desenvolvimentos, proporcionando velocidade de operação, nível de desempenho, redução de custos, melhoria da qualidade e eficiência operacional. Os modelos básicos de extrapolação são aplicados normalmente para projeções de curto prazo. A regressão múltipla, como é o caso deste trabalho, é similar à regressão simples, mas usa múltiplas variáveis ao mesmo tempo. A regressão múltipla muitas vezes dá uma explicação mais adequada do comportamento passado da variável e uma base melhor para prever seus níveis futuros.

Supor a construção de um modelo estatístico para relacionar a variável de geração de energéticos (Gcal/dia) com as variáveis de contribuição energética pelos combustíveis utilizados (dam3/dia e t/dia) é razoável. Assim, definimos o modelo de regressão linear múltipla dado por

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \varepsilon \quad (8)$$

em que Y representa a variável resposta (o ganho em íons), x_1 e x_2 representam as variáveis explicativas e ε representa o erro aleatório experimental. Esse é um modelo de regressão linear múltipla com duas variáveis independentes ou explicativas (x_1 e x_2). O termo linear é usado, pois, a equação (8) é uma função linear de parâmetros desconhecidos β_0 , β_1 e β_2 denominados coeficientes da regressão.



A partir da equação que melhor representa a relação entre as variáveis, pode-se obter a concepção do modelo estatístico de regressão. A partir da conclusão da seqüência de ações em conjunto com o Plano de Vendas da produção pode-se construir o modelo empírico do simulador de previsão de geração de energéticos e eficiência energética na planta da CTE2 da CSN. O Simulador de Eficiência Energética com base no MER, hoje adotado, está na revisão 3, de Mai./2011, e contemplando faixas de Energia Elétrica Líquida compreendidas em: ≤ 3.119 MW/dia; 3.120 a 3600 MW/dia; 3.601 a 4.175 MW/dia; e ≥ 4.176 MW/dia.

Os modelos foram testados com o mesmo conjunto de dados, utilizando-se os dados para o desenvolvimento de cada modelo e para as previsões calculadas (estimadas) para cada modelo. Em outras palavras, foram utilizados os dados no período de jan./2008 a maio/2011 no conjunto de treinamento. Modelos de regressão consideram que a variável a ser prevista tem um relacionamento causa e efeito com uma ou mais variáveis independentes. Seu princípio é descobrir esta forma de relacionamento ou correlação e utilizá-la na previsão da variável dependente. Com a mesma característica de poder realizar previsões, além de outras possibilidades, as redes neurais artificiais surgem como alternativa ao procedimento estatístico, aproveitando-se de suas características próprias, como nas situações em que são exigidas inferências de relações não lineares complexas entre as variáveis de entrada e de saída de um modelo predictor.

A principal diferença entre redes neurais e as abordagens estatísticas é que as redes neurais não estabelecem hipóteses ou suposições sobre a distribuição ou propriedades dos dados, e desta forma tendem a ser mais úteis em situações práticas.⁽¹⁰⁾ As RNA's constituem também uma abordagem inerentemente não-linear, fornecendo mais precisão quando modelando dados de padrões complexos que estatísticos. As redes neurais artificiais surgem como alternativa ao procedimento estatístico.

2.2 Condições de Cálculo

O cálculo para valores de eficiência energéticos atualmente utilizados, incluindo técnicas estatísticas, é insuficiente para chegar-se a um valor correto em todos os casos.

Durante o treinamento o vetor de pesos é progressivamente ajustado, buscando diminuir a diferença entre as saídas estimadas e as desejadas (valores reais da amostra), até o nível de precisão desejado. Atingido este ponto, a rede deve ser testada, empregando-se o conjunto de dados reservado para a validação. Um dos problemas do uso de RNA é identificar o momento para encerrar o treinamento, evitando o *overtraining*, que faz com que a rede "memorize" os dados, funcionando corretamente apenas com o conjunto de treinamento.

Descrevendo o diagrama do modelo proposto, compo uma RNA *feed forward* treinada com algoritmo *back propagation*, composta por três camadas: neurônios de entrada - para seis variáveis; camadas ocultas - com duas camadas: uma com cinco neurônios, a segunda com três neurônios; e neurônio de saída - para uma variável. Suas ligações (parâmetros livres) foram ajustadas pelos reais valores de Gcal/dia e t/dia na construção e integração das funções componentes do software e dos respectivos pontos de função associados.

Uma nova etapa na elaboração de simulador através de MER para a CTE2 da CSN foi concretizada abrindo este simulador também em faixas como os apresentados anteriormente. A única diferença é que todas as linhas de amostras foram



contempladas para o estabelecimento do modelo matemático, não se limitando a tão somente as 180 linhas de amostras por faixas, ou seja todas 984 linhas de amostras foram consideradas para a elaboração do simulador. Foram consideradas as mesmas 4 linhas de amostras adotadas para validação do RNA para a MER, compondo 3,66% da amostra total. É interessante salientar que o trabalho com MER para o estabelecimento dos coeficientes de regressão PLS (*Partial Least Squares*), foi desenvolvido anteriormente pelo corpo técnico da CSN⁽¹²⁾ com ganhos tangíveis expressíveis (R\$5,727 milhões de Maio a Dezembro/09).

3 RESULTADOS E DISCUSSÃO

Este estudo foi desenvolvido com o propósito de criar um modelo para a previsão de eficiência energética na CTE2 da CSN através de RNA, que se apresente como uma alternativa às atividades de estimativas tradicionalmente usadas, trazendo vantagens em termos de versatilidade e maior precisão.

A ferramenta computacional utilizada com RNA é apontada por diversos autores, citados ao longo do trabalho, como de maior eficiência na previsão de demandas. Ao longo deste estudo, a comparação entre os modelos implementados por RNA e MER evidencia que uma das principais vantagens do uso de RNA para o modelo preditivo é a capacidade desta de trabalhar com dados que apresentem grande aleatoriedade (ruído), visto que o modelo desenvolvido por meio da técnica estatística de regressão linear multivariada é útil para ajustes de sistemas cujas respostas não contenham uma grande variedade de fatores interferentes (ruídos), sendo assim os mesmos (ruídos) foram retirados da massa de amostragem. Esta limitação reside no fato de a informação contida na matriz de variáveis independentes serem inteiramente incorporada ao modelo de regressão. Desse modo, a informação irrelevante também está presente no modelo de regressão, reduzindo sua precisão para estabelecer estimativas confiáveis.

Os resultados apresentados mostram que modelos preditivos baseados em RNA é uma alternativa viável aos métodos tradicionais, os ditos modelos paramétricos, que utilizam ferramentas estatísticas na sua determinação. Comparativamente, este estudo mostrou vantagens na utilização das RNA sobre os modelos tradicionais. Uma destas vantagens diz respeito à versatilidade da rede neural, visto que, ocorrendo variações no cenário em estudo, é suficiente que a rede seja treinada novamente para realocar seus pesos sinápticos, ao passo que outro modelo requer uma total reformulação.

Excluindo-se os projetos supracitados, foram criados outros dois conjuntos de dados: um para treinamento (180 linhas de amostras) e outro para validação (4 linhas de amostras), compondo 2,5% do total das amostras de treinamento. Foram realizadas por faixa de Energia Elétrica Líquida (MW/dia) o treinamento da rede conforme Tabela 1.

Tabela 1 – Treinamento por faixa de Energia Elétrica

	≤ 3.119 MW/dia	3.120 a 3.600 MW/dia	3.601 a 4.175 MW/dia	≥ 4.176 MW/dia
épocas de treinamento	1100	1100	1100	750
taxa de aprendizagem	0,5	0,45	0,45	0,55
constante de momento	0,8	0,8	0,8	0,76



Medidas de dispersão da RNA e MER com validação por faixas são apresentados com os resultados obtidos por erro médio percentual e por desvio padrão na Tabela 2.

Tabela 2 – Dispersão da RNA e MER com validação por faixas de Energia Elétrica

		≤ 3.119 MW/dia	3.120 a 3.600 MW/dia	3.601 a 4.175 MW/dia	≥ 4.176 MW/dia
RNA	Erro médio	- 0,21%	8,20%	- 2,522%	3,59%
	Desvio padrão	0,0000842763	0,1038232	0,038430206	0,066486652
MER	Erro médio	32,92%	17,17%	9,10%	- 0,15%
	Desvio padrão	1,51	4,48	0,43	0,38

Como se vê, os valores fornecidos pelo modelo de RNA implementado são bem próximos dos obtidos (Figura 1) pela utilização do que a do modelo de regressão estatística, mesmo sendo utilizados poucos dados no treinamento de RNA, exceto na última faixa de energia elétrica líquida (≥ 4.176 MW/dia).




Figura 1 – Estimativa Real X RNA X Método Estatístico de Regressão (Gcal/hora X amostras).

4 CENÁRIOS ANALISADOS

Os três cenários aqui apresentados são situações hipotéticas de previsões nunca praticadas na planta da CTE2, na geração de energéticos.

- 1º Cenário – Sem consumo de GLD, máximo consumo de GAF e GCO, e GN com consumo mínimo de GN. A CTE2 poderá consumir o máximo de GAF se o processo estiver normal no Alto Forno (injeção de oxigênio e finos de carvão). Caso contrário deve-se passar as caldeiras para baixa velocidade pelo Ventilador de tiragem induzida (IDFs – *Iduced Draught Fan*) e reduzir para máximo de 100 dam³/caldeira. O consumo máximo de GAF (550 dam³/h) terá por sua vez a limitação na vazão da rede de distribuição. As caldeiras apresentam 92% de eficiência cada (93 kgf/s) para a capacidade de produção de vapor.
- 2º Cenário – Sem consumo de GCO e médio consumo de GN - Mantendo a equivalência de 1 queimador de GCO para 2 queimadores de GN que corresponde a 3,5 dam³/h.



- 3º Cenário – Máximo consumo de GCO e mínimo consumo de GN - As caldeiras tem mais de 12 anos de uso, com 90% de sua capacidade dos queimadores (4 dam³/h por queimador), Cada caldeira possui 3 queimadores.

Aplicando estes cenários anteriormente citados na RNA e MER, obtivemos as previsões dos números da Tabela 3, mostrando as gerações de energéticos possíveis de serem realizadas na CTE2.

Tabela 3 – Cenários hipotéticos de geração de energéticos por RNA e MER

Cenário	Combustível de Entrada	Previsão		Faixas de Energia Elétrica Líquida (MW/dia)
		RNA (Gcal/h)	MER (Gcal/h)	
1º	GCO - 36 dam ³ /h GLD - sem consumo GAF - 550 dam ³ /h GN - 9 dam ³ /h Óleo e Alcatrão - 0 t/dia	193,49	189,40	3.601 a 4.175
2º	GCO sem consumo GLD - 47 dam ³ /h GAF - 300 dam ³ /h GN - 14 dam ³ /dia Óleo e Alcatrão - 0 t/h	113,01	124,60	≤ 3.119
3º	GCO - 33 dam ³ /h; GLD - 47 dam ³ /h; GAF - 400 dam ³ /h; GN - 9 dam ³ /h; e Óleo e Alcatrão - 0 t/dia	190,19	172,70	3.601 a 4.175

Observa-se neste resultado a mesma flexão nas curvas de geração de energéticos tanto para RNA quanto para MER, porém os cenários aplicados ficaram limitados a somente duas faixas de energia elétrica líquida. Quanto mais cheia (todos os equipamentos disponíveis em 100% de carga para geração) estiver a planta, maior será a eficiência energética. Para o caso em questão aplica-se a melhor eficiência por planta cheia, somente para o 1º cenário. Os três cenários são passíveis de serem realizados na CTE2, visto que para o 1º cenário o resultado obtido encontra-se acima da capacidade mínima de geração que é de 70 MW/dia, para uma necessidade prevista de Energia Elétrica Líquida de 85 MW/dia (71 Gcal/h de saída, Vapor de Processo de 30 Gcal/h de saída e 9,8 Gcal/h de saída). Para o 2º cenário o mesmo também é passível de ser praticado na planta. Com o balanço de carga confirmando não extrapolar a capacidade das caldeiras para o 3º cenário, que compreende a faixa de 554 a 756 Gcal, para um resultado obtido de 614 Gcal, mostra que este cenário pode ser praticado.

5 CONCLUSÕES

Seguindo-se recomendações apontadas na literatura como primordiais ao bom desempenho da rede neural, foi dada especial atenção a três aspectos da rede neural: a) seleção de variáveis adequadas aos setores de demanda estudados; b) arquitetura da rede neural; e c) treinamento da rede, através de um algoritmo adequado tanto à minimização do erro de aprendizagem, quanto com relação à garantia de boa generalização (menor erro de predição possível).

Sob estes aspectos, verificou-se que os resultados obtidos foram satisfatórios, com a confirmação da importância da única variável selecionada para este estudo: vazão dos combustíveis empregados (dam³/dia e/ou t/dia). Conforme Setyawati, Creese e Sahirman⁽¹³⁾ e Haykin,⁽¹⁴⁾ a quantidade de variáveis selecionadas exerce um papel fundamental no desempenho da rede. A RNA é mais flexível para reproduzir os



resultados por possuir mais parâmetros a serem ajustados, enquanto que o MER apresenta uma leve tendência a reproduzir os resultados conforme mostrado na Figura 21, porém não se adapta a tendência de variabilidade dos resultados comparados aos do obtidos em condição real. A RNA apresentou um erro médio de 2,27%, contra 14,81% do MER, e desvio padrão de 0,05221 contra 1,70 respectivamente. O desenvolvimento desse modelo de previsão de eficiência energética na CTE2 da CSN através de RNA, comparando-o com um modelo paramétrico tradicional que é o MER, para as variáveis de entrada adequadas à consecução do modelo de previsão de demanda foram mais apropriados que o de regressão uma vez que há uma maior tendência do método de RNA seguir a tendência da curva real de energia total de energético produzida pela planta da CTE2, mostrando-se assim que o objetivo geral foi alcançado. Consequentemente o treinamento da rede e a sua validação das topologias foram mais eficazes no método de RNA de forma comparativa ao MER, visto ter havido uma redução significativa no erro médio (predição) quanto para os desvios padrão, tomando-se como base os mesmos dados históricos escolhidos.

Para os três cenários analisados para situações hipotéticas de previsões nunca praticadas na planta da CTE2, na geração de energéticos conclui-se que todos os cenários são passíveis de serem praticados, porém para a obtenção de uma maior eficiência energética, o ideal é que a planta esteja com todos os equipamentos disponíveis em 100% de carga para geração, limitando ao a aplicação ao 1º cenário. Para adequar esta prática na planta o ideal é fixar a eficiência energética e flexionar o consumo de combustível achando o ponto ótimo para uma necessidade exigida no PVP.

A variação na topologia da rede mostrou também a sua sensibilidade no que se refere ao seu número de neurônios, podendo, inclusive, não apresentar convergência em determinados casos, o que foi constatado para o caso do último quartil de faixa de energia elétrica líquida.

Embora se tenha obtido uma redução no erro de predição, a arquitetura da rede foi mantida, o que, segundo a literatura pertinente, não é recomendado, visto que a arquitetura da rede também pode depender do tamanho da amostra. Os resultados colhidos, neste caso, poderão apontar uma tendência de que o modelo pode apresentar maior precisão quando trabalhar com amostras de maior ou menor tamanho.

REFERÊNCIAS

- 1 HOBBS, B. F.; HELMAN, U., JITPRAPAIKULSARN, S., SREENIVAS, K., MARATUKULAN, D. Artificial neural networks for short-term energy forecasting: accuracy and economic value. Amsterdam, Neurocomputing, v. 23, n. 1/3, p. 71 a 84, December 1998.
- 2 LORENTZ, E. G. Aplicação de redes neurais na previsão de demanda de energia elétrica: um estudo comparativo entre modelos. 1995. 131 f.: il. Dissertação (Mestrado) – Universidade Federal de Minas Gerais. Escola de Engenharia. Belo Horizonte, 1995.
- 3 SOTO, C. P. Redes neurais temporais para o tratamento de sistemas variantes no tempo. 1999. ix, 101 f.: il. Dissertação (Mestrado) – Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Engenharia Elétrica. Rio de Janeiro, 1999.
- 4 GONZALEZ, J. A. Modelo estocástico de produção de energia usando o método dos cumulantes considerando unidades com limitação de energia. 1991. 166 p. Dissertação (Mestrado) – Universidade Federal de Santa Catarina. Centro Tecnológico. Florianópolis, 1991.



- 5 CAIO, L. S. Análise das metodologias de previsão de mercado de energia elétrica: relações macroeconômicas e o novo perfil no ambiente pós-privatização. 1998. 227 p. Dissertação (Mestrado) – Universidade de São Paulo. Energia. Programa Interunidades de Pós-Graduação em Energia. São Paulo, 1998.
- 6 CARPINTEIRO, O. A. S.; REIS, A. J. R. A hierarchical self-organizing map model in short term load forecasting. In: CONGRESSO BRASILEIRO DE AUTOMÁTICA, 15. Gramado, 2004. Anais... Gramado: UFRGS, 2004. 1 CD-ROM, paper n. 548.
- 7 MAÇADA, A. C. G. Impacto dos investimentos em tecnologia da informação nas variáveis estratégicas e na eficiência dos bancos brasileiros. 2001. [211] p. Tese (Doutorado) – Universidade Federal do Rio Grande do Sul. Departamento de Administração de Empresas. Porto Alegre, 2001.
- 8 GUERRA, F. A.. Análise de métodos de agrupamento para o treinamento de redes neurais de base radial aplicadas à identificação de sistemas. 2006. 149 p. Dissertação (Mestrado) – Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Engenharia de Produção e Sistemas.
- 9 ROCHA, D. M.. Redes neurais para modelagem de sistemas estruturais offshore dinâmicos não-lineares com histerese. 2007. 167 p. Tese (Doutorado) – Universidade Federal do Rio de Janeiro. Programa de Pós-Graduação de Engenharia Civil.
- 10 FREIMAN, J. P.; PAMPLONA, E. O.. Redes Neurais Artificiais na Previsão do Valor de Commodity do Agronegócio. V Encuentro Internacional de Finanzas. Santiago, Chile, 19 a 21 de janeiro de 2005.
- 11 FISH, K. E; BLODGETT, J. G. A visual method for determining variable importance in an artificial neural net. London, Journal of Targeting, Measurement and Analysis for Marketing, v. 11, n. 3; p. 244-254, March 2003.
- 12 TEIXEIRA, N. N. Desenvolvimento e aplicação de simulador na CTE2 para melhoria da eficiência energética (trabalho 17166) – 31º Seminário de Balanços Energéticos Globais e Utilidades e 25º Encontro de Produtores e Consumidores de Gases Industriais, 17 a 20 de agosto de 2010, Foz do Iguaçu, PR – Brasil.
- 13 SETYAWATI, B. R.; CREESE, R. C.; SAHIRMAN, S. Neural network for cost estimation (part 2). Morgantown, AACE International Transactions , v. 14, p. 1-10, 2003.
- 14 HAYKIN, S. Redes neurais: princípios e prática. Tradução Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001. Tradução de Neural networks: a comprehensive foundation.