
ESTUDO COMPARATIVO ENTRE GMDH E REDES NEURAIS APLICADOS NA MONITORAÇÃO DE SENSORES

Elaine Inácio Bueno

Mestre em Tecnologia Nuclear pela USP
Professora do Instituto Federal de Educação, Ciência e Tecnologia – Campus Bragança Paulista

Iraci Martinez Pereira Gonçalves

Doutora em Tecnologia Nuclear pela USP
Pesquisadora do Instituto de Pesquisas Energéticas Nucleares (IPEN-CNEN)

Antonio Teixeira e Silva

Doutor em Engenharia Nuclear – Rheinisch – Westfälischen Technischen Hochschule /Aachen
Pesquisador e Professor Titular do Instituto de Pesquisas Energéticas Nucleares (IPEN-CNEN)

Este trabalho tem como objetivo apresentar um estudo comparativo entre as metodologias GMDH (Group Method of Data Handling) e Redes Neurais Artificiais (RNAs) aplicados na Monitoração de sensores de um reator experimental. Para tanto, foram desenvolvidos dois modelos de monitoração: um utilizando Redes Neurais e o outro o algoritmo GMDH. Os dois modelos de monitoração utilizaram uma base de dados gerada por um modelo teórico do reator que permite gerar situações que não são possíveis de se obter experimentalmente. Os resultados obtidos mostram que a monitoração usando GMDH apresentou resultados melhores do que os obtidos usando apenas RNAs.

Palavras-chave: Redes neurais artificiais. GMDH. Monitoração. Detecção de falhas.

This paper aims at presenting a comparative study between the methodologies Group Method of Data Handling (GMDH) and Artificial Neural Networks (ANNs) applied to the Sensor Monitoring of an experimental reactor. For this, two monitoring models were developed: one using ANNs and another using GMDH algorithm. Both Monitoring Models used a database generated by a theoretical model of reactor which creates situations which are not possible to obtain experimentally. The results obtained by GMDH monitoring model showed better results than those obtained using only ANNs.

Keywords: Artificial Neural Networks. Group Method of Data Handling. Monitoring and Fault Detection.

1 INTRODUÇÃO

A área de Monitoração e Diagnóstico de falhas em sensores tem estimulado estudos crescentes em razão da necessidade de se ter qualidade, confiabilidade e segurança nos processos de produção. Nos processos industriais, a interrupção da produção por alguma anomalia pode colocar em risco a

segurança do operador e provocar perdas econômicas, aumentando assim os custos com a reparação de algum equipamento danificado. Esses dois fatores estimulam o desenvolvimento de sistemas de controle confiáveis e tolerantes a falhas (ECHENDU & ZHU, 1993; PUIG et. al., 2007).

Nas centrais nucleares existe um grande número de variáveis a serem

observadas continuamente. Durante uma falha, os operadores recebem um grande volume de informações provenientes dos instrumentos de medição, indicando um padrão típico da mesma. Devido à grande quantidade de informação em um período de tempo muito pequeno, os operadores são obrigados a tomar algumas decisões em condições estressantes, dificultando em alguns casos a identificação da falha. Com o propósito de auxiliar os operadores das centrais nucleares, têm-se utilizado muitas técnicas de Inteligência Artificial na Monitoração e no Diagnóstico de Falhas, incluindo Lógica Nebulosa (GOODE, 1995), Redes Neurais Artificiais – RNAs (ROVITHAKIS, MANIADAKIS & ZERVAKIS, 2004; SAMANTA, 2004; KALOGIROU, 2000), GMDH (Group Method of Data Handling) (PUIG et. al., 2007) e Algoritmos Genéticos (AGs) (ROVITHAKIS, MANIADAKIS & ZERVAKIS, 2004).

O uso de RNAs na Monitoração de sensores é muito interessante, tanto pela forma como estes problemas são representados internamente pela rede, como também pelos resultados gerados. Em RNAs, o procedimento usual na solução de problemas passa inicialmente por uma fase de *aprendizagem*, em que um conjunto de exemplos é apresentado para a rede, que extrai automaticamente dos mesmos as características necessárias para representar a informação fornecida. Essas características são utilizadas posteriormente para gerar respostas a problemas com características similares às dos exemplos.

O uso do GMDH na Monitoração de sensores está associado ao fato de ele ser um algoritmo auto-organizável de propagação indutiva que permite a obtenção de um modelo matemático do sistema a partir de observações de amostras de dados (FERREIRA, 1999; IVAKHNENKO, 1969). Além disso, o GMDH apresenta algumas vantagens, tais como: possui uma arquitetura que evolui durante o processo de modelagem;

uma auto-organização indutiva, ou seja, o número de camadas e nós é estimado pelo mínimo de um critério externo (escolha objetiva); a convergência é obtida através de um modelo de grande complexidade; otimizada simultaneamente a estrutura e dependências no modelo, não sendo uma técnica consumidora de tempo; e as variáveis de entrada não apropriadas para o modelo são excluídas automaticamente (GONÇALVES, 2006).

O presente trabalho tem como objetivo apresentar um estudo comparativo entre as metodologias GMDH e Redes Neurais na Monitoração de sensores. As duas técnicas supracitadas já foram utilizadas no desenvolvimento de sistemas de Monitoração e Diagnóstico de Falhas em sensores (BUENO, 2006; GONÇALVES, 2006), em que os resultados obtidos demonstraram a viabilidade de aplicação desses métodos para tal tarefa. Este trabalho possibilitará identificar qual o melhor método para esta aplicação, além de estimular o desenvolvimento de trabalhos futuros, usando as duas técnicas de forma combinada.

2 DESCRIÇÃO DO REATOR IEA-R1

O Reator IEA-R1 está situado no IPEN (Instituto de Pesquisas Energéticas e Nucleares) localizado na Cidade Universitária em São Paulo. Foi projetado e construído pela “Babcock & Wilcox”, em 1956. É um reator de pesquisa do tipo piscina, refrigerado e moderado à água leve, que utiliza berílio como refletor. A Figura 1 mostra um diagrama esquemático do reator IEA-R1 (INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES, 1999).

3 MODELO TEÓRICO DO REATOR IEA-R1

O modelo teórico do reator (GONÇALVES & TING, 2005) foi desenvolvido com o uso da ferramenta

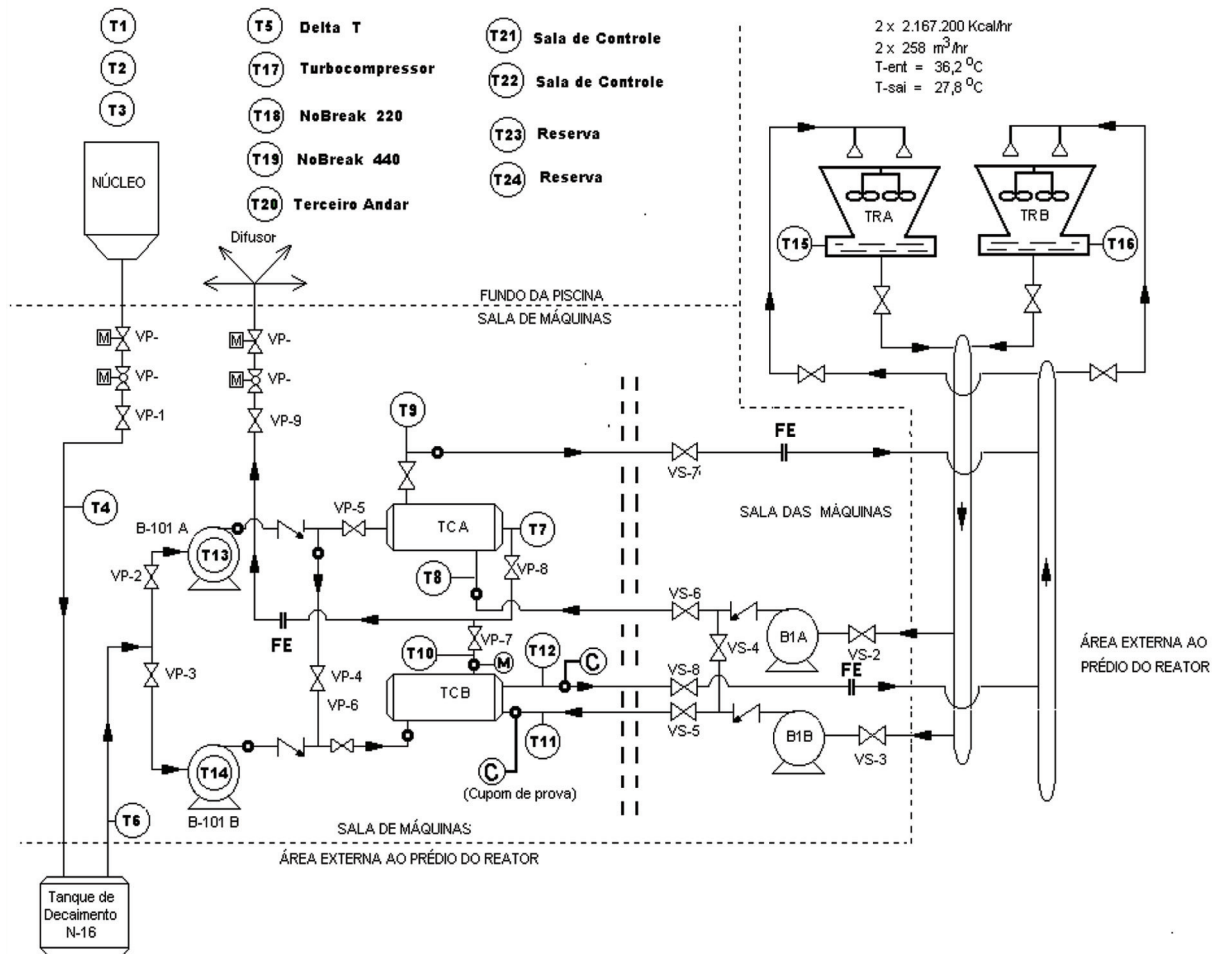


Figura 1: Diagrama esquemático do reator IEA-R1.

GUIDE do Matlab (CREATING GRAPHICAL USER INTERFACES, 2008), que permite gerar dados em diversas condições de operação, possibilitando simular situações que não são possíveis de se obter experimentalmente devido às restrições de operação do reator nuclear. As equações que regem o comportamento das variáveis de processo foram baseadas no balanço de massa e energia do reator IEA-R1, levando-se em consideração todos os aspectos físicos e operacionais, tais como comprimento e diâmetro das tubulações, relações entre os valores de vazão, temperaturas e perda de carga. No modelo teórico, foram consideradas as seguintes variáveis: T1 (Temperatura na superfície da piscina), T2 (Temperatura à meia altura da piscina), T3 (Temperatura sobre o núcleo do reator), T4 (Temperatura na entrada do tanque de decaimento),

T6 (Temperatura na saída do tanque de decaimento), T7 (Temperatura na saída do primário), T8 (Temperatura na entrada do secundário), T9 (Temperatura na saída do secundário), F1M3 (Vazão do circuito primário), F2M3 (Vazão do circuito secundário) e Pot (Potência). A interface do programa foi criada de forma a lembrar o fluxograma de processo do reator IEA-R1, como pode ser visto na Figura 2. Nessa interface é possível visualizar os valores da potência térmica (em MW), calculados no núcleo e no lado primário do trocador de calor. Neste modelo é possível: adicionar falhas às variáveis; gerar dados na condição normal de operação do reator; atribuir níveis de ruídos nas variáveis de entrada através de uma janela, sendo o seu valor determinado em %; e determinar o número total de pontos que serão gerados para as condições estabelecidas.

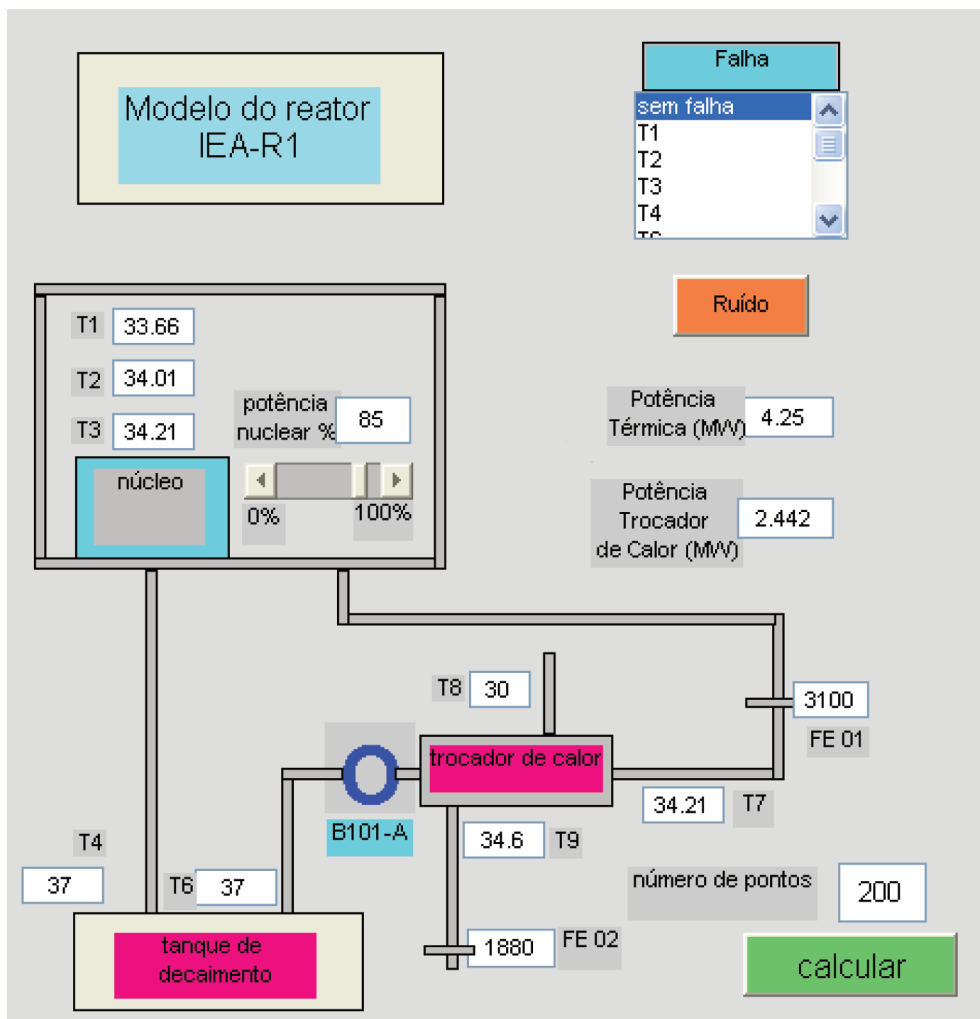


Figura 2: Interface do programa desenvolvido.

4 REDES NEURAIS ARTIFICIAIS

As Redes Neurais Artificiais podem ser definidas como sistemas paralelos compostos por unidades de processamento simples, dispostas em camadas e altamente interligadas, inspiradas no cérebro humano (HAYKIN, 1999).

O aprendizado de uma RNA é realizado a partir de um algoritmo, conhecido como algoritmo de aprendizagem, em que os pesos sinápticos são atualizados com o propósito de alcançar o objetivo desejado. As formas como os neurônios das RNAs são organizados estão intimamente associadas ao algoritmo de aprendizado utilizado no treinamento das redes. Geralmente, podemos identificar três tipos de arquiteturas de RNAs (HAYKIN, 1999):

- Redes com propagação para frente de uma camada: compostas por uma camada de entrada e outra de saída;
- Redes com propagação para frente de múltiplas camadas: compostas por uma camada de entrada, camadas ocultas e uma camada de saída;
- Redes recorrentes: contêm realimentação das saídas para as entradas.

O principal objetivo do treinamento de uma RNA é fazer com que a aplicação de um conjunto de entradas produza um conjunto de saídas desejadas ou no mínimo um conjunto de saídas consistentes. Cada conjunto de entrada ou saída é denominado *vetor*. O treinamento é realizado pela aplicação sequencial dos vetores de entrada (e em alguns casos também os de saída), enquanto os pesos da rede são

ajustados de acordo com um procedimento de treinamento pré-determinado. Durante o treinamento, os pesos da rede gradualmente convergem para determinados valores, de tal maneira que a aplicação dos vetores de entrada produza as saídas necessárias. Os procedimentos de treinamento das RNAs podem ser classificados em duas classes: supervisionado e não supervisionado.

O treinamento *supervisionado* necessita de um vetor de entrada e um vetor de saída, conhecido como vetor alvo. Esses dois vetores são então utilizados para o treinamento da RNA. O procedimento de treinamento funciona da seguinte maneira: o vetor de entrada é aplicado, a saída da rede é calculada e comparada com o correspondente vetor alvo. O erro encontrado é então realimentado através da rede e os pesos são atualizados de acordo com um algoritmo com o propósito de minimizar este erro. Este processo de treinamento é repetido até que o erro para os vetores de treinamento alcance valores pré-determinados. O treinamento *não supervisionado*, por sua vez, não requer vetor alvo para as saídas. O conjunto de treinamento modifica os pesos da rede, de forma a produzir saídas que sejam consistentes. O processo de treinamento extrai as propriedades estatísticas do conjunto de treinamento e agrupa os vetores similares em classes, em que a aplicação de um vetor de uma determinada classe à entrada da rede produzirá um vetor de saída específico.

5 GMDH

O método GMDH (Group Method of Data Handling) é composto por um algoritmo proposto por Ivakhnenko. Consiste em um método algébrico para estimar estados de um sistema, saídas de controladores e funções de atuadores (IVAKHNENKO, 1969). A metodologia pode ser considerada como um algoritmo auto-organizável de propagação indutiva para a solução de problemas práticos complexos. Além disso, é possível obter um modelo matemático do processo a partir de observações de amostras de dados, que será

utilizado na identificação e no reconhecimento de padrões, ou até mesmo para descrever o próprio processo. Este método soluciona o problema multidimensional de otimização do modelo, pelo procedimento de escolha e seleção, a partir de um conjunto de modelos candidatos de acordo com um critério fornecido. A maioria dos algoritmos GMDH utiliza funções de referência polinomiais. Uma conexão genérica entre variáveis de entrada e de saída pode ser expressa pela série funcional de Volterra, discreta análoga do polinômio de Kolmogorov-Gabor:

$$y = a + \sum_{i=1}^m b_i x_i + \sum_{i=1}^m \sum_{j=1}^m c_{ij} x_i x_j + \sum_{i=1}^m \sum_{j=1}^m \sum_{k=1}^m d_{ijk} x_i x_j x_k + \Lambda \quad (1)$$

Onde:

$\{x_1, x_2, x_3, \dots\}$: variáveis de entrada

$\{a, b, c, \dots\}$: coeficientes do polinômio.

As componentes da matriz de entrada podem ser variáveis independentes, formas funcionais ou termos de diferenças finitas, além disso se podem utilizar outras funções de referência não lineares. O método permite, ainda, encontrar simultaneamente a estrutura do modelo e a dependência da saída do sistema modelado em função dos valores de entrada mais significativos do sistema.

Aksenova & Yurachkovsky (1988) obtiveram as bases teóricas da efetividade do GMDH como método adequado e robusto de construção de modelos para estimativa. A modelagem auto-organizável é baseada em redes de aprendizado estatístico, que capturam relações complexas não lineares em uma forma de execução rápida e compacta. Essas redes subdividem o problema em partes menores de fácil manuseio e aplicam técnicas de regressão avançadas para resolver cada um desses problemas.

6 RESULTADOS OBTIDOS

6.1 Monitoração usando RNAs

Para estabelecer o modelo de monitoração usando Redes Neurais

Artificiais, foram utilizadas todas as variáveis do modelo teórico: T1, T2, T3, T4, T6, T7, T8, T9, F1M3, F2M3 e Pot; porém serão apresentados apenas os resultados obtidos na monitoração dos sensores de temperatura (T3 e T9). Todas as simulações computacionais foram realizadas utilizando a ferramenta de Redes Neurais do Matlab, versão R2008a.

Através deste modelo, as redes foram treinadas com valores pré-selecionados, gerados pelo modelo teórico do reator. Assim, foram gerados dados variando-se a Potência (N2) de 0 a 100%, no intervalo de 5 em 5%, sendo que, para cada condição de potência gerada, foram criados 20 exemplos, totalizando 420 exemplos. Foram adicionados ruídos de 0,4% na variável T3 e 1% na variável F1M3, por serem flutuações observadas durante a operação do reator IEA-R1. Esta base de dados foi normalizada no intervalo de -1 a 1, de acordo com a equação (8):

$$y = \frac{(y_{\max} - y_{\min}) * (x - x_{\min})}{(x_{\max} - x_{\min})} + y_{\min} \quad (2)$$

Onde:

x : entrada da rede

y : valor normalizado das entradas da rede de [-1,1]

Foram estabelecidos dois parâmetros para interromper o treinamento das Redes Neurais. O primeiro parâmetro foi o MSE (Erro Médio Quadrático), cujo valor foi de 10^{-4} ; e o segundo parâmetro foi o número máximo de épocas, cujo valor foi 1000. Inicialmente, o MSE era de 0,01, porém todas as redes atendiam a este critério e, no intuito de reduzir ainda mais o valor do MSE, decidiu-se adotar o valor citado acima.

No treinamento das redes, foi utilizado o método de “Parada Antecipada” (Early Stopping). Este método sugere uma divisão da base de dados em três

subconjuntos: treinamento, validação e teste, cuja proporção de divisão adotada foi respectivamente: 60%, 20% e 20%. O conjunto de treinamento é usado para calcular o gradiente e atualizar os pesos e bias da rede; o de validação é usado para monitorar o erro durante o processo de treinamento; e o de teste é usado para comparar diferentes modelos.

Como parâmetro para comparação do desempenho de cada rede foi utilizado o resíduo, descrito pela equação (9). A rede que apresentar o menor resíduo será escolhida para a aplicação.

$$\text{res} = \left(\frac{y - y_d}{y_d} \right) \times 100 \quad (3)$$

Onde:

y = saída atual

y_d = saída desejada

Através deste estudo foi possível determinar a arquitetura (MLP – Redes de Camadas Múltiplas) e o algoritmo de treinamento (Retropropagação).

As redes foram desenvolvidas com a seguinte arquitetura: uma camada de entrada, uma camada oculta e uma camada de saída. Na camada de entrada, o número de neurônios corresponde a todas as variáveis compreendidas pelo modelo teórico, com exceção da variável monitorada, e sua função de ativação é do tipo linear. Na camada oculta, a função de ativação é do tipo tangente hiperbólica e o número de neurônios foi variado de 1 a 10 para a escolha do melhor modelo. Na camada de saída, a função de ativação é do tipo linear e o número de neurônios corresponde à variável monitorada.

A Figura 3 mostra o resultado da monitoração de T3 (variável de saída), em que as variáveis de entrada foram: T1, T2, T4, T6, T7, T8, T9, F1M3 e F2M3. Para as demais variáveis de temperatura o procedimento foi semelhante.




Figura 3: Monitoração de T3 usando Redes Neurais.

6.2 Monitoração usando GMDH

O GMDH foi usado para encontrar o melhor modelo de monitoração para os sensores de temperatura. Por ser um algoritmo auto-organizável, a saída do sistema é encontrada em função das entradas mais significativas para o mesmo, não havendo necessidade de utilização do conhecimento especialista para realizar esta tarefa. Na Figura 4 são apresentados os resultados obtidos na monitoração de cada um dos termopares. A escolha do melhor modelo é feita através da equação (3).




Figura 4: Monitoração de termopares usando GMDH.

6.3 Análise dos resultados obtidos

Através da análise das Figuras 3 e 4, verifica-se que os resíduos obtidos na monitoração de termopares usando a metodologia GMDH foram menores (da ordem de 10^{-3}) do que os obtidos usando RNAs (da ordem de 10^{-1}).

7 CONCLUSÕES

Neste trabalho foi apresentado um estudo comparativo entre os métodos GMDH e Redes Neurais, aplicados na monitoração de sensores de um reator experimental. Para realizar tal estudo, utilizou-se uma base de dados gerada por um modelo teórico do reator de pesquisas IEA-R1.

Na monitoração usando RNAs, as redes foram treinadas com o propósito de estabelecer o melhor modelo para a monitoração de uma determinada variável. Pela arquitetura de rede e algoritmo de treinamento usado neste trabalho, é necessário conhecer as variáveis de maior relevância para a monitoração de um determinado sensor.

Já na monitoração usando GMDH, determinando-se a variável de saída, o modelo é obtido através da eliminação das variáveis de entrada irrelevantes.

Para a escolha do melhor modelo foram calculados os resíduos obtidos na monitoração usando cada uma das metodologias supracitadas.

Os resultados obtidos neste trabalho demonstram que os modelos desenvolvidos através do algoritmo GMDH apresentaram resíduos menores do que os obtidos usando RNAs. Esses resultados estimulam a continuidade nos estudos nesta área, principalmente no que se refere à combinação dos dois métodos aplicados na Monitoração e no Diagnóstico de Falhas em sensores.

REFERÊNCIAS

- AKSENOVA, T. I.; YURACHKOVSKY, Y. P. A Characterisation at unbiased structure and conditions of their J-Optimality. *Soviet Journal of Automation and Information Sciences*, 21 (4): p. 36-42, 1988.
- BUENO, E. I. *Utilização de redes neurais artificiais na monitoração e detecção de falhas em sensores do reator IEA-R1*. Dissertação (Mestrado). Universidade de São Paulo – IPEN, São Paulo, 2006.

CREATING GRAPHICAL USER INTERFACES, Version 7.6. MATHWORKS, USA, 2008.

ECHENDU, J. E. A., ZHU, H. Detecting changes in the condition of process instruments. In *Instrumentation and Measurements Technology Conference Rec. of IMCT*, p. 515-518, Irvine CA, USA, 1993.

FERREIRA, P. B. *Incipient fault detection and isolation of sensors and field devices*. Tese (Doutorado). University of Tennessee, Aug. 1999.

GONÇALVES, I. M. P. *Monitoração e diagnóstico para detecção de falhas de sensores utilizando a metodologia GMDH*. Tese (Doutorado). IPEN, São Paulo, 2006.

GONÇALVES, I. M. P., TING, D. K. S. A theoretical model for the IPEN research reactor IEA-R1. *INAC 2005 – International Nuclear Atlantic Conference Proceedings (Cdroom)*, Aug. 2005.

GOODE, P. V. Using a Neural/Fuzzy System to extract heuristic knowledge of incipient faults in induction motors: Part I – Methodology. *IEEE Transactions on Industrial Electronics*, 42(2), 1995.

HAYKIN, S. *Neural Networks: a comprehensive foundation*. Prentice Hall, 1999.

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES (IPEN). *Relatório de Análise de Segurança do reator de pesquisas do IPEN IEA-R1 (RAS)*, 1999.

IVAKHNENKO, A. G. *Self-teaching systems of recognition and automatic control*. Moscow: *Tekhnika*, 392, 1969.

KALOGIROU, S. A. Application of artificial neural networks for energy systems. *Applied Energy*, 67 (1): p. 17-35, Set., 2000.

PATTON, R. J.; CHEN, J.; NIELSEN, S. B. Model-based methods for fault diagnosis:

some guidelines. *IEEE Transactions of the Institute of Measurement and Control*, 17(2), 1995.

PUIG, V., et. al. A GMDH neural network-based approach to passive robust fault detection using a constraint satisfaction backward test. *Engineering Applications of Artificial Intelligence*, 20, p. 886-897, 2007.

ROVITHAKIS, G. A.; MANIADAKIS, M.; ZERVAKIS, M. A hybrid neural network/genetic algorithm approach to optimizing feature extraction for signal validation. *IEEE Transactions on Systems, Man And Cybernetics – Part B: Cybernetics*, 34 (1), 2004.

SAMANTA, B. Gear fault detection using artificial neural networks and support vector machines with genetic algorithms. *Mechanical Systems and Signal Processing*, 18 (3): p. 625-644, 2004.

SYDENHAM, P. H., THORN, R. Strategies for sensor performance assessment. In *Instrumentation and Measurements Technology Conference. Rec. of IMCT*, p. 353 – 358, Irvine CA, USA, 1993.

Para contato com os autores:

Elaine Inácio Bueno
ebueno@cefetsp.br

Iraci Martinez Pereira Gonçalves
martinez@ipen.br

Antonio Teixeira e Silva
teixeira@ipen.br