

## SELEÇÃO DE ENTRADAS PARA REDES NEURAIS ARTIFICIAIS USANDO O ALGORITMO GMDH

**Elaine Inacio Bueno**, [ebueno@cefetsp.br](mailto:ebueno@cefetsp.br)

Instituto Federal de Educação, Ciência e Tecnologia de São Paulo – Campus Guarulhos  
Avenida Salgado Filho, 3501 – 07115-000 – Guarulhos/SP

**Iraci Martinez Pereira**, [martinez@ipen.br](mailto:martinez@ipen.br)

**Antonio Teixeira e Silva**, [teixeira@ipen.br](mailto:teixeira@ipen.br)

Instituto de Pesquisas Energéticas e Nucleares (IPEN/CNEN-SP)  
Avenida Professor Lineu Prestes, 2242 – 05508-000 – São Paulo/SP

**RESUMO.** *A utilização de Redes Neurais na Monitoração e Detecção de Falhas em centrais nucleares é interessante por permitir o estabelecimento de um modelo do processo em questão através de uma base de dados. Em uma central nuclear há centenas de variáveis de processo, assim a escolha adequada das variáveis de entrada para as Redes Neurais é extremamente importante para tornar os sistemas de Monitoração e Detecção de Falhas mais robustos. Neste trabalho, foi utilizado o algoritmo GMDH com o propósito de selecionar variáveis de entradas para as Redes Neurais, evitando assim a necessidade de utilização do conhecimento especialista, possibilitando o desenvolvimento de novos métodos de Monitoração e Detecção de Falhas em sensores. Para tal estudo, foi utilizada uma base de dados gerada por um modelo teórico do reator de pesquisas do IPEN-IEA-R1.*

**Palavras chaves:** *Monitoração, Detecção de Falhas, GMDH e Redes Neurais Artificiais*

### 1. Introdução

A Monitoração e a Detecção de Falhas em sensores requer a estimativa de algumas variáveis de interesse. Essa estimativa pode ser usada para auxiliar os operadores no controle de plantas nucleares e na detecção e no diagnóstico de sensores falhos. Muitos métodos de Inteligência Artificial vêm sendo utilizados para realizar tal tarefa (Goode, 1995) (Rovithakis et. al., 2004) (Samanta, 2004) (Puig et. al., 2007) (Raymer et. al., 2000). A utilização desses métodos é justificada por permitir a modelagem do processo sem a utilização de equações algébricas que descrevam matematicamente o fenômeno (Brosse et. al., 1999) (Kaewarsa e Attakitmongcol, 2004) (Zupan et. al., 1997), sendo necessária apenas a utilização de uma base de dados que contenha o histórico temporal de operação da instalação.

A utilização de RNA's na modelagem do processo é muito interessante, tanto pela forma como estes problemas são representados internamente pela rede, como também pelos resultados gerados. Em RNA's, o procedimento usual na solução de problemas passa inicialmente por uma fase de *aprendizagem*, onde 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.

A possibilidade de *aprender* através de exemplos e *generalizar* a informação aprendida são, sem dúvida, os principais atrativos na solução de problemas através de RNA's. A generalização, que está associada à capacidade da rede aprender através de um conjunto reduzido de exemplos, e posteriormente dar respostas coerentes para dados não conhecidos, é uma demonstração de que a capacidade das RNA's não se limita apenas em mapear relações de entrada e saída. As RNA's são capazes de extrair informações não apresentadas de forma explícita, através de exemplos.

Nas aplicações onde se utiliza RNA's existe uma grande preocupação quanto à escolha das variáveis de entrada, pois o desempenho da mesma está diretamente relacionado com a seleção adequada das variáveis de entrada para o treinamento. A utilização de variáveis de entrada irrelevantes no treinamento de uma Rede Neural pode conduzir a resultados indesejados (Verikas e Bacauskiene, 2002), além de aumentar o tempo computacional.

O objetivo deste trabalho é demonstrar a aplicação da metodologia GMDH na seleção de entradas para Redes Neurais. A metodologia desenvolvida foi implantada usando dados de um modelo teórico do reator de pesquisas do IPEN – IEA-R1. A função de Monitoração é independente das indicações dos painéis de Instrumentação e Controle instalados na Sala de Controle, e, portanto não interferirá na operação do reator.

### 2. Descrição do reator IEA-R1

O Reator IEA-R1 é um reator tipo piscina, refrigerado e moderado a água leve, que utiliza berílio como refletor. Foi projetado e construído pela “Babcok & Wilcox”, em 1956. A Figura 1 mostra um diagrama esquemático do reator IEA-R1.

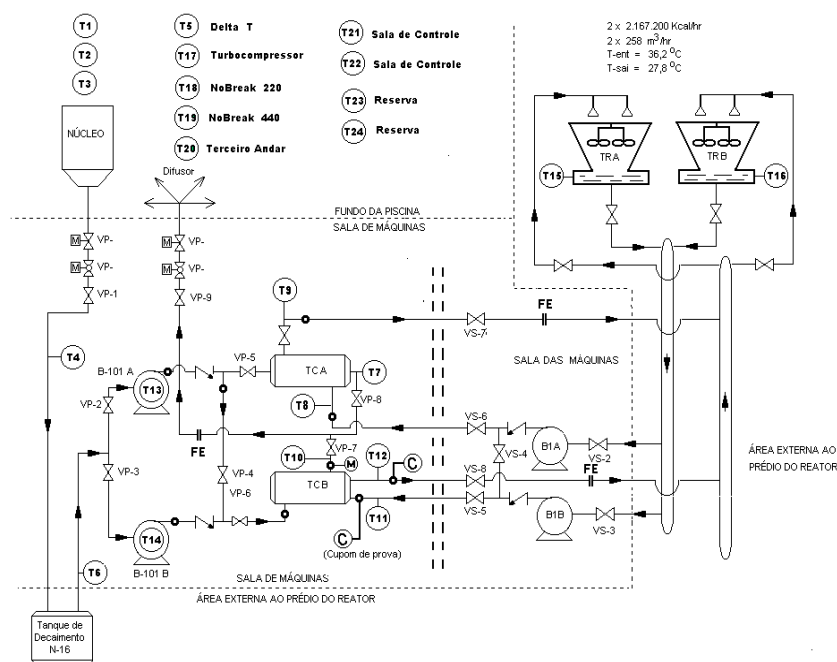


Figura 1. Diagrama esquemático do reator IEA-R1

O reator IEA-R1 é utilizado para (Instituto de Pesquisas Energéticas e Nucleares, 1999):

- ❖ Produção de radioisótopos para aplicações na medicina, indústria, agricultura e para pesquisas;
- ❖ Treinamento e formação de operadores do reator;
- ❖ Teste de materiais;
- ❖ Pesquisa em física e química nuclear;
- ❖ Realização de experimentos visando à obtenção de parâmetros nucleares

## 2.1. Modelo Teórico do reator IEA-R1

O modelo teórico do reator (Gonçalves e Ting, 2005) foi desenvolvido com o uso da ferramenta GUIDE do Matlab (Creating Graphical User Interfaces, 2008), que permite gerar dados em diversas condições de operação, permitindo trabalhar com situações que não são possíveis de se obter experimentalmente devido às restrições de operação do reator nuclear. Este modelo representa as relações básicas entre as diferentes variáveis de processo. O reator IEA-R1 possui dois circuitos de refrigeração, e neste modelo foi representado apenas um deles. 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 (Gonçalves & Ting, 2005). No modelo teórico, foram consideradas as seguintes variáveis: T1 (Temperatura na superfície da piscina), T2 (Temperatura a 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 primário) e F2M3 (Vazão do secundário).

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, sendo que a escolha das variáveis com falha é feita a partir de uma lista que contém todas as variáveis do modelo. Existe ainda a opção de gerar dados “sem falha”, ou seja, na condição normal de operação do reator. Pode-se ainda atribuir níveis de ruídos das variáveis de entrada através de uma janela, sendo o seu valor determinado em %.

Além disso, é possível determinar o número total de pontos que serão gerados para as condições estabelecidas, onde o programa calcula para um ponto, atualiza os valores necessários, e reinicia o cálculo para o próximo ponto. Para gerar uma base de dados, pode-se digitar diretamente os valores desejados nas caixas de edição da interface, e em seguida pressionar o botão *calcular*, onde será calculado o valor da potência de acordo com as equações do balanço térmico.

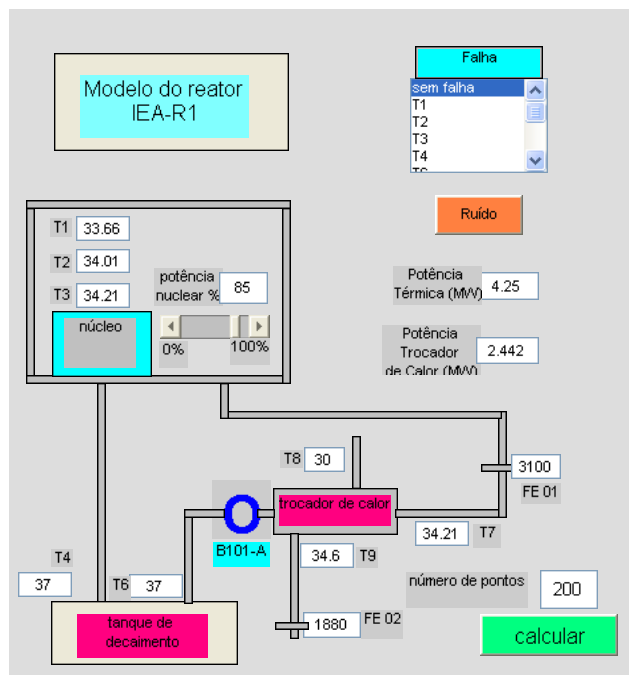


Figura 2. Interface do programa desenvolvido

### 3. Group Method of Data Handling - 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) (Ivakhnenko e Yarachkovskiy, 1981). A metodologia pode ser considerada como um algoritmo auto-organizável de propagação indutiva para a solução de problemas práticos mais 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 de modelos escolhidos a partir de um conjunto de modelos candidatos de acordo com um critério fornecido. A maioria dos algoritmos GMDH usa 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:

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

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, podem-se 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.

A teoria GMDH soluciona problemas em várias áreas dentre as quais se podem destacar (Ivakhnenko, 1969):

- ❖ estimativa de processos e eventos a curto e longo prazo;
- ❖ aproximação de processos multivariados;
- ❖ "clusterização" de amostras de dados;
- ❖ reconhecimento de padrões no caso de variáveis contínuas e discretas;
- ❖ diagnóstico através de algoritmos probabilísticos de escolha e seleção;
- ❖ suporte na decisão após um cenário de regras do tipo "se-então".

Aksenova e Yurachkovskiy (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

estatísticas, 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 simples.

### 3.1. Descrição da metodologia GMDH

Em geral, os dados disponíveis são as variáveis de entrada e de saída de um sistema, representadas pela matriz de variáveis de entrada  $X = (x_{ij})$ , e pelo vetor da variável de saída  $Y = (y_i)$ ,  $i = 1, 2, \dots, n$  e  $j = 1, 2, \dots, m$ , onde  $n$  é o número total de observações e  $m$  é o número total de variáveis.

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & \dots & x_{2m} \\ \dots & \dots & \dots & x_{ij} & \dots \\ \dots & \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & \dots & x_{nm} \end{bmatrix} \quad Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_i \\ \dots \\ y_n \end{bmatrix} \quad (2)$$

O algoritmo GMDH é executado de acordo com os seguintes passos:

1º passo. O primeiro passo consiste em construir um novo conjunto de variáveis  $Z$ . Para tanto, inicialmente deve-se dividir as observações em dois subconjuntos distintos. O primeiro subconjunto será utilizado para ajuste ( $i=1$  a  $nt$ ) e o segundo para verificação ( $i=nt+1$  até  $n$ ).

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & \dots & x_{1m} \\ x_{21} & x_{22} & \dots & \dots & x_{2m} \\ \dots & \dots & \dots & x_{ij} & \dots \\ \dots & \dots & \dots & \dots & \dots \\ x_{nt1} & x_{nt2} & \dots & x_{ntj} & \dots \\ \dots & \dots & \dots & \dots & \dots \\ x_{n1} & x_{n2} & \dots & \dots & x_{nm} \end{bmatrix} \quad Y = \begin{bmatrix} y_1 \\ y_2 \\ \dots \\ y_{nt} \\ \dots \\ y_n \end{bmatrix} \quad (3)$$

A seguir tomam-se as variáveis independentes do subconjunto de ajuste duas de cada vez para todas as combinações possíveis e calculam-se os coeficientes da seguinte regressão polinomial, onde  $p$  e  $q$  são as colunas da matriz  $X$ :

$$y = a_{pq} + b_{pq}x_p + c_{pq}x_q + d_{pq}x_p^2 + e_{pq}x_q^2 + f_{pq}x_px_q \quad \begin{cases} p = 1, 2, \dots, m, p \neq q, \\ q = 1, 2, \dots, m, q > p, \\ i = 1, 2, \dots, nt \end{cases} \quad (4)$$

Para cada combinação das variáveis independentes (colunas de  $X$ ) há um conjunto de coeficientes da regressão, resultando na matriz de coeficientes  $C$ . Como se tem  $m(m-1)/2$  diferentes combinações das variáveis de entrada, resultam  $m(m-1)/2$  linhas da matriz de coeficientes  $C$ .

$$C = (a_{pq}, b_{pq}, c_{pq}, d_{pq}, e_{pq}, f_{pq}) \quad \begin{cases} p = 1, 2, \dots, m, p \neq q, \\ q = 1, 2, \dots, m, p > q \end{cases} \quad (5)$$

Para cada conjunto de coeficientes  $C_{pq}$ , avalia-se o polinômio para todos os  $n$  pontos de dados para calcular uma nova estimativa de  $y$ , chamada  $z_{pq}$ :

$$z_{pq} = a_{pq} + b_{pq}x_p + c_{pq}x_q + d_{pq}x_p^2 + e_{pq}x_q^2 + f_{pq}x_px_q \quad (6)$$

Esses novos valores são armazenados na primeira coluna de uma matriz  $Z$ .

Repete-se esta avaliação para todos os conjuntos de coeficientes e para todos os n dados, gerando uma nova matriz Z chamada nova geração de variáveis.

$$Z = (z_{ij}) \begin{cases} i = 1, 2, \dots, n, \\ j = 1, 2, \dots, m(m-1)/2 \end{cases} \text{ onde cada } j \text{ corresponde a um par } p, q \quad (7)$$

$$Z = \begin{bmatrix} z_{11} & z_{12} & \dots & z_{1n(m-1)/2} \\ z_{21} & z_{22} & \dots & \dots \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ z_{n1} & z_{n2} & \dots & z_{nn(m-1)/2} \end{bmatrix} \quad (8)$$

Podem-se interpretar estas variáveis (matriz Z) como novas variáveis que têm melhor poder de estimativa do que aquelas da geração original (matriz X).

2º passo. O próximo passo é comparar cada coluna de Z com a variável dependente Y. Isto é, para cada coluna j de Z calcula-se o desvio médio quadrático  $r_j$  para i variando de nt+1 até n, ou seja, utilizando o subconjunto de verificação:

$$r_j^2 = \frac{\sum_{i=nt+1}^n (y_i - z_{ij})^2}{\sum_{i=nt+1}^n y_i^2} \quad j=1, 2, \dots, m(m-1)/2 \quad (9)$$

Ordena-se as colunas de Z em ordem crescente de  $r_j$  e então seleciona-se aquelas colunas de Z que satisfaçam um critério selecionado anteriormente (por exemplo  $r_j < R$ , onde R é um valor residual mínimo). Pode-se notar que o número de variáveis salvas, digamos  $m_1$ , pode ser igual, menor ou maior do que o número original m.

3º passo. Esta nova matriz Z irá substituir a matriz original X. Estas novas variáveis são combinadas exatamente como se fez anteriormente. Ou seja, calculam-se todas as equações de regressão quadráticas de y em função destas novas variáveis (duas a duas). Isso irá fornecer um novo conjunto de  $m_1(m_1-1)/2$  equações de regressão para estimar y a partir das novas variáveis. Agora são selecionadas as melhores das novas estimativas, gerando novas variáveis independentes a partir das equações selecionadas para substituir as anteriores, e combinar todos os pares destas novas variáveis.

4º passo. Do passo anterior encontra-se o menor  $r_j$  e chama-se de RMIN. Se o valor de RMIN é menor que o valor de RMIN da geração prévia, repete-se os passos 1, 2 e 3. Se o valor de RMIN é maior que o valor precedente, assume-se que a "curva RMIN" atingiu seu mínimo, o processo é interrompido e usam-se os resultados da geração anterior, como pode ser visto na Figura 3.

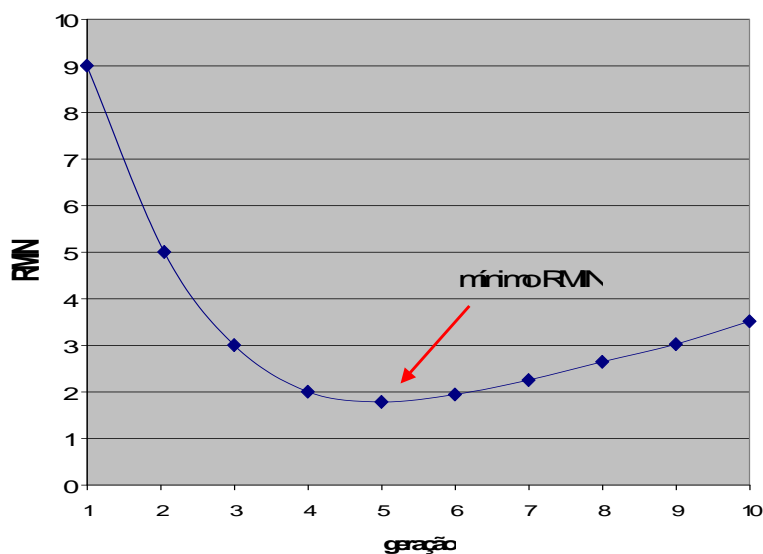


Figura 3. Curva RMIN calculado a cada geração



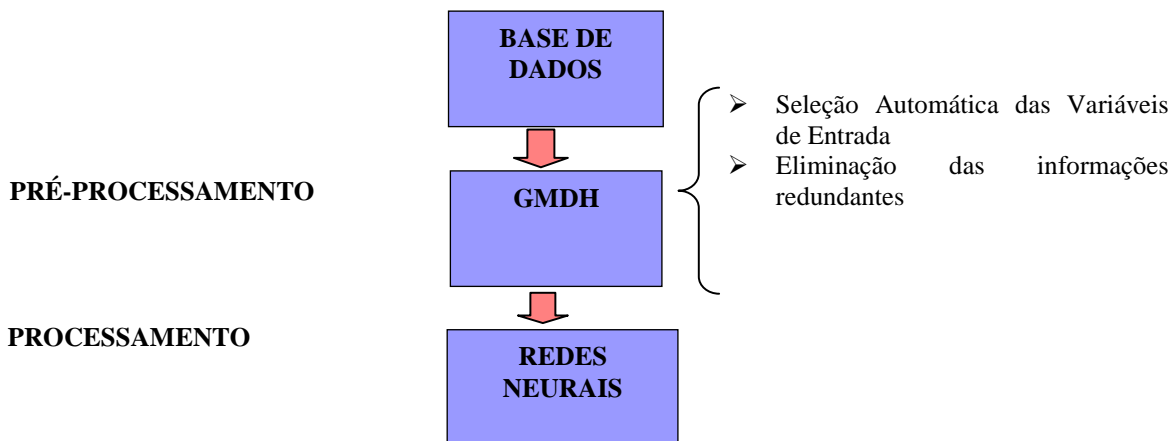


Figura 5. Fluxograma da metodologia proposta

## 5. Resultados obtidos

A metodologia GMDH foi aplicada para iniciar os estudos na área Monitoração e Detecção de Falhas em sensores através da seleção de entradas para Redes Neurais. Para tanto, utilizou-se uma base de dados gerada por um modelo teórico do reator IEA-R1. As variáveis consideradas pelo modelo teórico são: T1, T2, T3, T4, T6, T7, T8, T9, F1M3 e F2M3, descritas anteriormente.

Com base neste modelo, 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 típicas 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 (11):

$$pn = 2 \times \left( \frac{p - \min p}{\max p - \min p} \right) - 1 \quad (11)$$

Onde:

$p$ : entradas

$\min p$ : menor valor de  $p$

$\max p$ : maior valor de  $p$

$pn$ : valor normalizado das entradas de [-1,1]

Foram realizadas simulações computacionais usando esta base de dados, onde o algoritmo GMDH forneceu uma melhor estimativa das variáveis consideradas pelo modelo teórico. Essas novas estimativas foram utilizadas como entradas para as Redes Neurais, eliminando assim a necessidade de utilização do conhecimento especialista na determinação das melhores entradas para uma determinada saída.

A arquitetura de rede utilizada neste trabalho foi a MLP (Multilayer Perceptron) treinadas pelo algoritmo de retropropagação. As redes desenvolvidas são compostas por: uma camada de entrada, uma oculta e uma de saída. Na camada de entrada foi utilizada a função linear (identidade). Para a camada oculta das redes desenvolvidas, foram estudados e testados 10 casos com diferentes números de neurônios. O estudo foi iniciado com um número pequeno de neurônios na camada oculta, observando se os erros obtidos estavam dentro de um valor adequado para a aplicação. Na camada oculta foi utilizada a função tangente hiperbólica. A camada de saída das redes é composta apenas por um neurônio, que representa a variável monitorada. Na camada de saída foi utilizada a função linear, por apresentar um erro menor do que as outras funções de ativação.

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 (60%), validação (20%) e teste (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.

Foram estabelecidos dois parâmetros para interromper o treinamento das Redes Neurais. O primeiro parâmetro foi o MSE (Erro Médio Quadrático), cujo valor foi de  $10^{-5}$ ; 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.

Como parâmetro para comparação do desempenho de cada rede foi utilizado o valor do resíduo, calculado pela equação (12). A rede que apresentasse o menor resíduo seria escolhida para a aplicação.

$$resíduo = \left( \frac{|y - y_d|}{y_d} \right) \times 100 \quad (12)$$

Onde:

y: saída da rede

y<sub>d</sub>: saída desejada

### 5.1. Monitoração dos sensores de temperatura

Os resultados obtidos na monitoração dos sensores de temperatura são mostrados nas Figuras 6 e 7. Nestas Figuras são apresentados também os resultados obtidos na monitoração usando apenas a metodologia de Redes Neurais [3] para possibilitar um estudo comparativo.

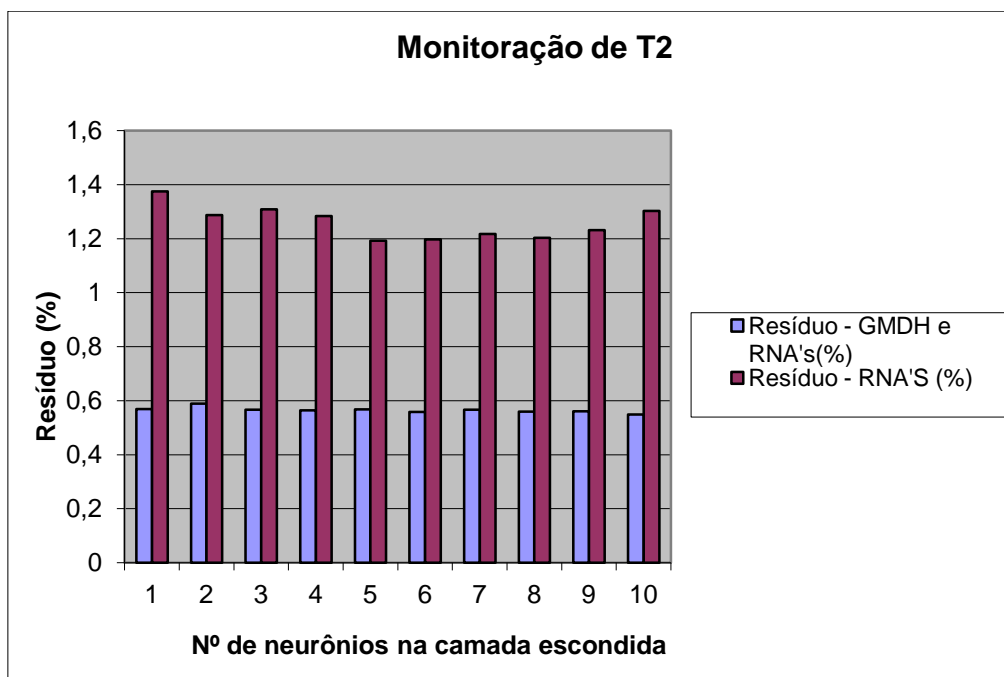


Figura 6. Monitoração de T2 – Comparação dos resultados obtidos

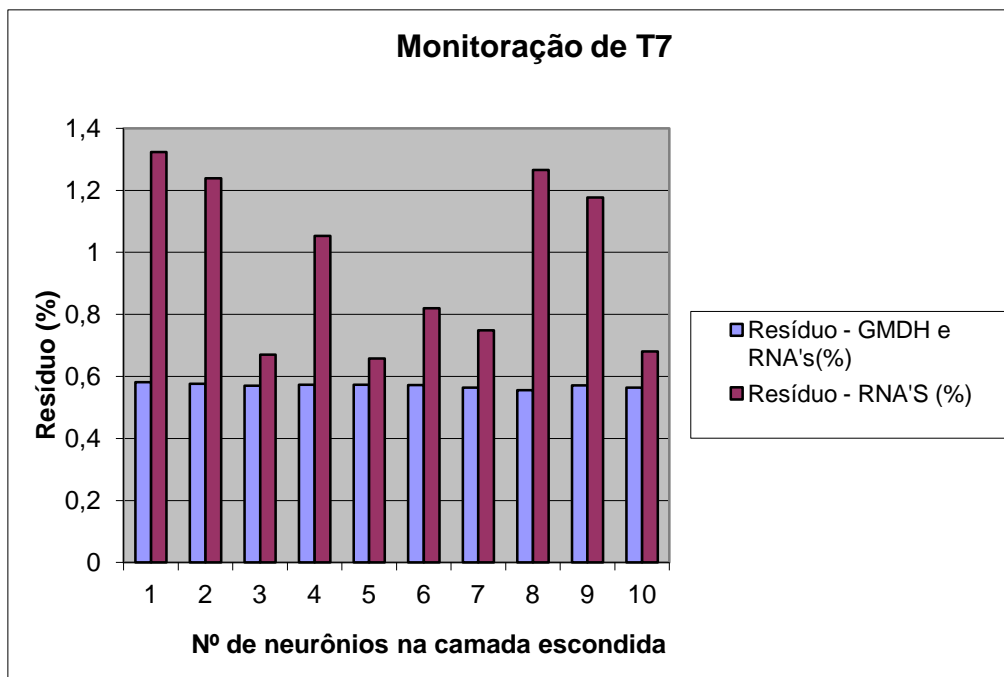


Figura 7. Monitoração de T7 – Comparação dos resultados obtidos

Através da análise das Figuras 6 e 7, verifica-se que os resíduos obtidos na monitoração dos sensores de temperatura usando GMDH e Redes Neurais são menores do que os obtidos utilizando-se apenas Redes Neurais mostrando assim a necessidade de utilização de métodos capazes de otimizar a seleção das variáveis de entrada.

## 6. Conclusões

Neste trabalho foi proposto um método de seleção de variáveis de entrada aplicado na Monitoração dos sinais de sensores, usando as metodologias GMDH e Redes Neurais. Para tanto, foi utilizada uma base de dados gerada por um modelo teórico do reator IEA-R1

O modelo teórico do reator foi desenvolvido utilizando-se a ferramenta GUIDE do Matlab. Este modelo possui uma interface que permite gerar dados de operação normal, dados com falhas e dados com diferentes níveis de ruído nas variáveis de entrada. O modelo teórico do reator possui um total de onze variáveis, porém neste trabalho foram consideradas apenas quatro variáveis de temperatura.

O GMDH foi utilizado na etapa de pré-processamento fornecendo assim, uma melhor estimativa das variáveis originais. Essas novas estimativas foram usadas no treinamento das Redes Neurais obtendo-se bons resultados, demonstrando assim a viabilidade de utilização deste método no desenvolvimento de Sistemas de Monitoração e Detecção de Falhos mais robustos, estimulando assim a continuidade nas pesquisas nesta área.

## 7. Referências Bibliográficas

AKSENOVA, T. I.; YURACHKOVSKY, Yu. P. A Characterisation at Unbiased Structure and Conditions of Their J-Optimality. *Sov. J. of Automation and Information Sciences*, 21 (4): p. 36-42, 1988.

BROSSE, S. et. al. The use of neural networks to asses fish abundance and spatial occupancy in the littoral zone of a mesotrophic lake. *Ecological Modelling*, 120 (2-3): p. 229-311, 1999.

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, 2006.

*Creating Graphical User Interfaces*. Version 7.6, the MATHWORKS Inc., USA, 2008.

FERREIRA, P. B. *Incipient Fault Detection and Isolation of Sensors and Field Devices*. Tese (Doutorado) - University of Tennessee, August 1999.

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 (Cdrom)*, 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): p. 131-138, 1995.

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. Moscou: *Tekhnika*, 392, 1969.

IVAKHNENKO, A. G.; YARACHKOVSKIY, Yu. P. Self-organization at a System of Complex Models. *Radio and Signal*. Moscou, 1981.

KAEWARSA, S.; ATTAKITMONGCOL, K. Wavelet-Based Neural Networks Approach to Power Quality Disturbance Recognition. *Proceedings of 2004 International Symposium on Intelligent Signal Processing and Communication Systems*, 2004.

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 (7): p. 886-897, 2007.

RAYMER, M. L. et. al. *Dimensionality reduction using Genetic Algorithms*. IEEE Transactions on Evolutionary Computation, 4 (2): p. 164-171, 2000.

ROVITHAKIS, G. A. et. al. 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): p. 695-703, 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.

VERIKAS, A.; BACAUSKIENE, M. Feature Selection with neural networks. *Pattern Recognition Letters*, 23 (11): p. 1323 – 1335, 2002.

ZUPAN, J. et. al. Kohonen and counterpropagation artificial neural networks in analytical chemistry. *Chemometrics and Intelligent Laboratory Systems*, 38 (1): p. 1-23, 1997.

## 8. Nota de responsabilidade

Os autores são os únicos responsáveis pelo conteúdo deste artigo.