

# Redes Neurais e Sistemas Fuzzy na Monitoração e Detecção de Falhas em Sensores do reator IEA-R1

**Elaine Inacio Bueno**

Instituto Federal de Educação, Ciência e Tecnologia – Campus Guarulhos  
07115-000, Guarulhos, SP  
E-mail:ebueno@cefetsp.br

**Iraci Martínez Pereira, Antonio Teixeira e Silva**

Instituto Federal de Pesquisas Energéticas e Nucleares  
05508-000, São Paulo, SP  
E-mail:martinez@ipen.br, [teixeira@ipen.br](mailto:teixeira@ipen.br)

## Resumo

Neste trabalho foi desenvolvido um sistema Neurofuzzy para Monitoração e Detecção de Falhas em sensores do reator IEA-R1. Foram utilizadas quatro variáveis do SAD (Sistema de Aquisição de dados), que é responsável pela monitoração de todas as variáveis de operação, são elas: T3 – temperatura sobre o núcleo do reator (°C), T4 – temperatura na entrada do tanque de decaimento (°C), F1M3 – vazão do primário (gpm) e N3 – potência do canal de segurança 2 (%). O sistema criado é responsável pela monitoração da variável N3, a partir dos valores fornecidos pelas variáveis de entrada (T3, T4 e F1M3). Os dados utilizados referem-se à semana de operação do reator de 12/Fev/2010, sendo que 50% dos dados foram utilizados para o treinamento do sistema e os outros 50% foram separados em um conjunto de treinamento. O sistema foi desenvolvido utilizando-se a função ANFIS (Sistema Neurofuzzy de Inferência Adaptativa) da ferramenta Fuzzy Logic na plataforma Matlab. Os resultados obtidos foram excelentes, pois o sistema de Monitoração e Detecção de Falhas desenvolvido fornece um parâmetro de medida de possibilidade de ocorrência ou não de falha, de acordo com o conjunto de regras criado com base nos dados utilizados durante o treinamento do sistema.

**Palavras-chave:** *Neurofuzzy, Monitoração, Diagnóstico de Falhas*

## 1. Introdução

Em grandes sistemas de processo, tais como usinas de potência, usinas químicas, usinas de papel ou polpa, metais e outros sistemas de manufatura, o estado de operação é monitorado por vários sensores e controlado por atuadores que utilizam as saídas desses sensores. Qualquer alteração nos valores desses sensores afetará diretamente as saídas dos controladores do sistema ou as decisões dos operadores em relação à necessária ação de controle a ser tomada.

Uma falha em um instrumento usado para fornecer um sinal de realimentação em um sistema de controle pode causar uma deterioração no desempenho do sistema. Se a falha ocorrer gradualmente e for detectada no seu estágio inicial, o instrumento falho pode ser reparado ou substituído antes que problemas mais sérios ocorram. Por outro lado, ações de controle adequadas podem ser solapadas por valores de sensores inválidos. Ambas as situações podem criar perdas econômicas e questões de segurança fazem com que seja desejável a implementação de sistemas de controle confiáveis e tolerantes a falhas.

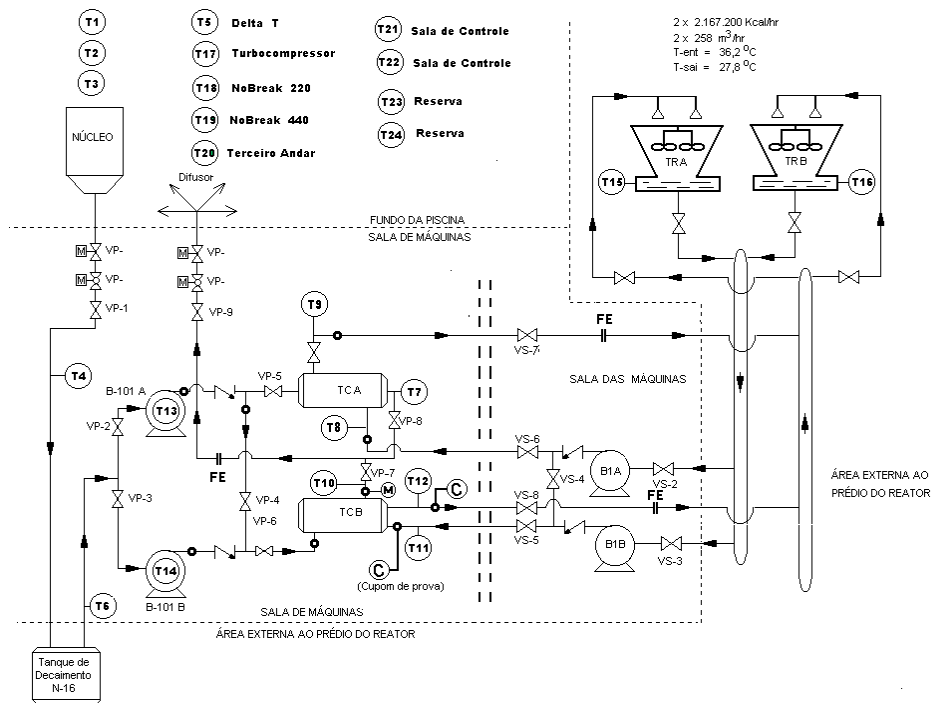
Diversos métodos e sistemas foram desenvolvidos com a finalidade de otimizar os procedimentos para controle e operação de reatores nucleares, objetivando a priorização de informações a serem disponíveis ao operador, no sentido de facilitar a identificação de falhas e ações a serem tomadas, para mitigar os efeitos das mesmas.

As técnicas de Inteligência Artificial estão sendo muito utilizadas em sistemas de Monitoração e Detecção de Falhas, destacando-se entre elas as que utilizam sistemas baseados em conhecimento como: a Lógica Nebulosa e as Redes Neurais Artificiais. Estas, em particular, têm sido exaustivamente empregadas em uma infinidade de áreas distintas [1,2,3,4,5,6,7].

O objetivo deste trabalho é o desenvolvimento de um Sistema Neurofuzzy para a Monitoração e Detecção de Falhas em sensores. Esta metodologia será aplicada ao reator de pesquisas do IPEN – IEA-R1, onde será utilizada uma base de dados contendo os valores das variáveis de processo da instrumentação, coletados e armazenados pelo SAD (Sistema de Aquisição de Dados) do reator. O SAD monitora 58 variáveis operacionais, incluindo temperatura, vazão, nível, pressão, radiação, potência nuclear e posição de barras. A função de Monitoração é independente das indicações dos painéis de Instrumentação e Controle instalados na Sala de Controle, e, portanto a instalação do Sistema de Monitoração e Detecção de Falhas não interferirá na operação do reator.

## 2. Reator de Pesquisas IEA-R1

O Reator IEA-R1 fica 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 tipo piscina, refrigerado e moderado a água leve, que utiliza berílio como refletor. Sua primeira criticalidade foi atingida em 16 de setembro de 1957, onde passou a operar a 2 MW de potência, de segunda a sexta-feira, das 8:00h às 17:00h, com uma parada a cada 15 dias, às segundas-feiras, para manutenção preventiva e corretiva. A partir de 1995, o reator teve seu regime de operação modificado para 64 horas ininterruptas visando à produção de radioisótopos e o desenvolvimento de pesquisas. A Figura 1 apresenta um diagrama esquemático do reator IEA-R1.



**Figura 1.** Diagrama esquemático do reator IEA-R1

O reator IEA-R1 é utilizado para:

- 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.

### 3. Descrição do Problema

**Sistema de Monitoração de Falhas existente:** O Sistema de Aquisição de Dados (SAD) monitora 58 variáveis operacionais, incluindo temperatura, vazão, nível, pressão, radiação, potência nuclear e de barras. O SAD permite armazenar a história temporal de todas as variáveis de processo monitoradas.

O Sistema Neurofuzzy criado irá monitorar a variável N3 (potência), a partir dos valores das variáveis T3, T4 e F1M3, descritas anteriormente.

A escolha dessa variável foi influenciada por existir uma técnica denominada *balanço térmica*, que é utilizada para a calibração dos detectores de potência do reator [8]. Esta técnica baseia-se no acréscimo de temperatura sofrido pelo fluido de refrigeração ao passar pelo núcleo do reator, sendo a potência determinada pela equação (1):

(1)

Onde:

M = vazão mássica do fluido refrigerante através do núcleo do reator (kg/s)

Cp = Calor específico do fluido refrigerante (cal/

Δt= variação da temperatura do fluido refrigerante ao passar pelo núcleo do reator (°C)

P = potência térmica do núcleo (W)

Desta forma, os valores gerados pelo sistema Neurofuzzy podem ser comparados com a resposta obtida pela técnica de balanço térmico. Porém, nesta 1ª fase do projeto não será feita esta comparação.

A Monitoração da variável N3 ocorrerá da seguinte forma: se T3 (temperatura sobre o núcleo do reator) for maior que T4 (temperatura na entrada do tanque de decaimento), teremos a presença de falha no sistema, pois de acordo com a técnica de balanço térmico, a potência é determinada pelo acréscimo de temperatura, sendo que a temperatura T4 será sempre maior que a temperatura T3.

### 4. Desenvolvimento do trabalho

No desenvolvimento do Sistema Neurofuzzy utilizou-se dados referentes à semana de operação do reator de 12/fevereiro/2010. Durante a fase de treinamento do sistema, foram usados 50% dos dados como um conjunto de treinamento e os outros 50% dos dados como um conjunto de validação. O sistema foi desenvolvido utilizando-se a função ANFIS (Sistema Neurofuzzy de Inferência Adaptativa) da ferramenta Fuzzy Logic na plataforma Matlab [9].

No treinamento do sistema foi utilizado um algoritmo híbrido: LEAST SQUARE ESTIMATION e retropropagação, visando reduzir o erro entre a saída atual e a saída desejada. Esta fase de treinamento é comparada à fase de aprendizagem de uma RNA. As funções de pertinências e o conjunto de regras foram gerados através da modelagem dos dados de entrada/saída apresentados ao sistema. Este sem dúvida é um dos principais atrativos dos sistemas Neurofuzzy, principalmente em sistemas complexos onde seria dispendioso criar regras If-Then através do manuseio de dados.

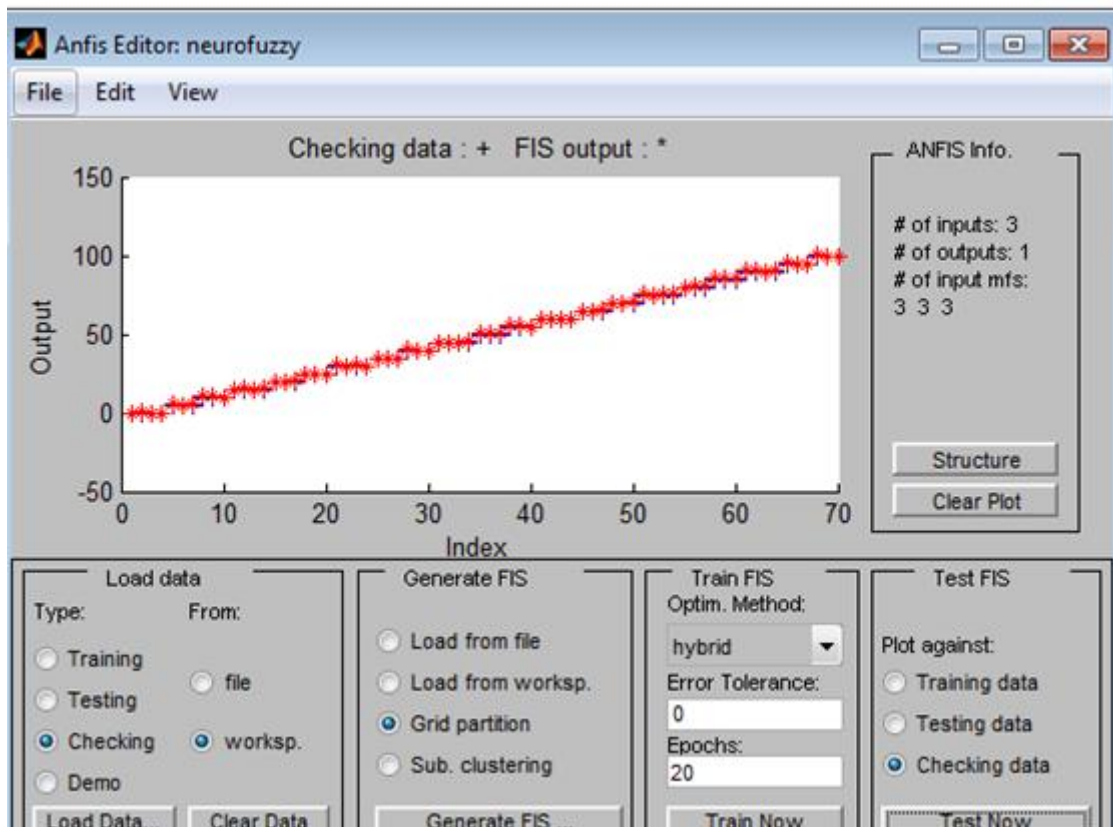
A estrutura do sistema Neurofuzzy desenvolvido baseia-se em uma topologia paramétrica (método Sugeno), onde a parte **SE** das regras (premissas) são operações lógicas e a parte **ENTÃO** (conseqüências) são funções lineares das variáveis de entrada. Esta base de regras é mais compacta que o método regular baseado em regras, pois representa um método híbrido que combina fuzzy com relações matemáticas [10].

#### 4.1 Treinamento do Sistema

Antes de iniciar o treinamento foi gerado um Sistema de Inferência Fuzzy (FIS), com suas respectivas funções de pertinência e a base de regras são atualizados após o treinamento do sistema através do algoritmo de retropropagação.

O sistema foi treinado durante 30 épocas utilizando-se valores normalizados de -1 a 1. Na fase de treinamento, o erro médio quadrático (MSE) obtido foi de 0.0483644.

Após o treinamento, o sistema foi submetido a um conjunto de dados para testar a resposta aos dados que não foram utilizados durante a fase de treinamento. O comportamento exibido pode ser observado na Figura 2. O erro para a base de dados de teste foi de 0,091657.



**Figura 2.** Teste da resposta da rede

Os parâmetros das funções de pertinências e o conjunto de regras foram ajustados após o treinamento do sistema para modelar as variações dos dados de entrada/saída apresentados durante a fase de treinamento. A estrutura do modelo gerado pode ser visto na Figura 3.

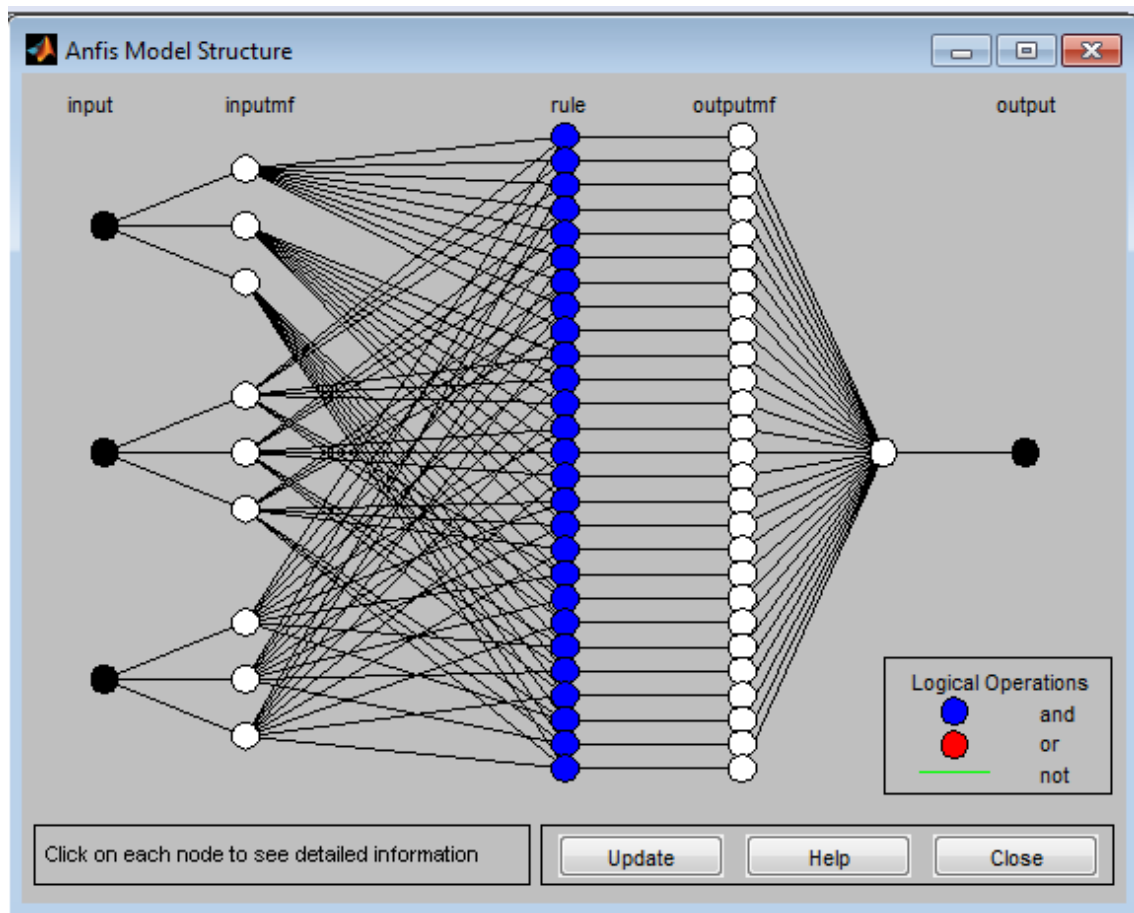


Figura 3. Estrutura do modelo

## 5. Modelagem Fuzzy do Conhecimento Especialista

Conforme exposto anteriormente, o presente trabalho consiste em monitorar e detectar Falhas nos detectores de potência do reator utilizando-se Sistemas Neurofuzzy.

As variáveis de entrada são:

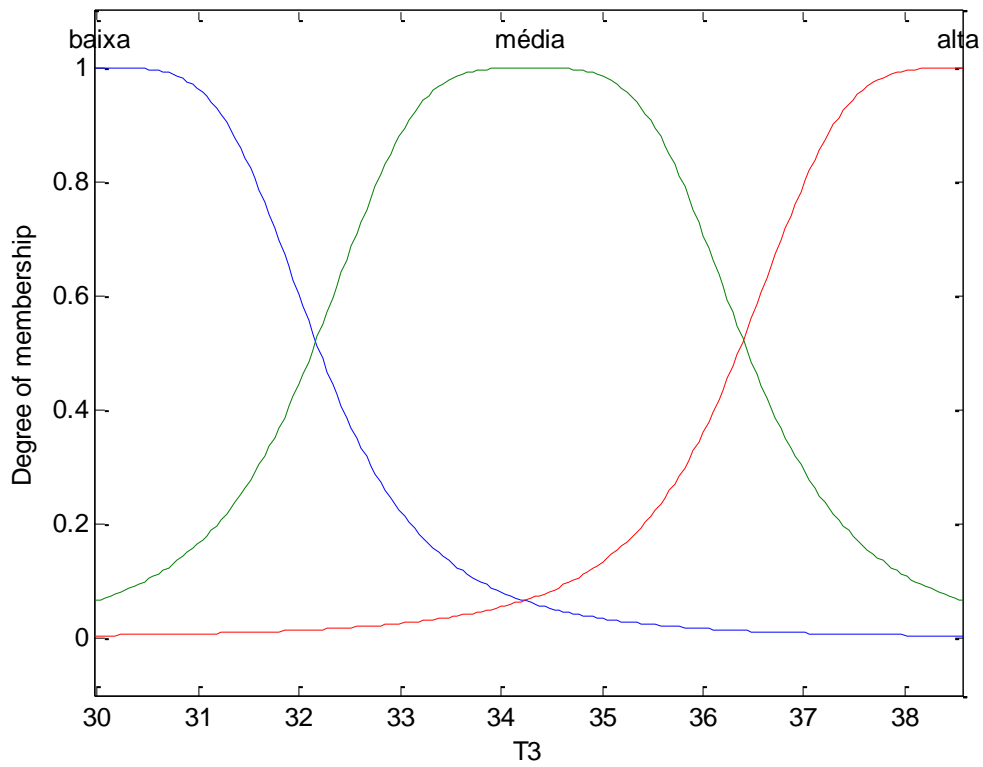
1. T3 – temperatura sobre o núcleo do reator (°C)
2. T4 – temperatura na entrada do tanque de decaimento (°C)
3. F1M3 – vazão do primário (gpm)

A variável de saída é

1. N3 – potência no canal de segurança 2 (%)


### 5.1. Modelagem das variáveis de entrada

A Figura 4 mostra a função de pertinência da variável de entrada T3. As variáveis lingüísticas que foram escolhidas como etiquetas foram: baixa, média e alta. A função *generalized Bell* foi escolhida para resolver o problema. O universo de discurso das variáveis de entrada varia de -1 a 1, sendo que o valor 1 corresponde ao valor máximo de temperatura lido do conjunto de dados de treinamento (em torno de 34°C). Está previsto em projeto que uma temperatura na faixa de 28°C a 42°C é considerada normal, porém o valor máximo obtido no conjunto de dados seria em torno de 36°C.



**Figura 4.** Variável de entrada T3

A Figura 5 mostra a função de pertinência da variável F1M3. A função utilizada foi a *generalized bell*, e o universo de discurso varia de -1 a 1.



**Figura 5.** Variável de entrada F1M3

## 5.2. Modelagem da variável de saída

A função de pertinência da variável de saída é linear, sendo obtida através da média ponderada dos pesos de defuzzificação. O número de funções de pertinência da variável de saída é igual ao número de regras gerado.

Os sinais de entrada são multiplicados e utiliza-se a operação lógica AND para alimentar os pesos sinápticos para as 27 saídas do sistema (representada por out1mf). A saída final é calculada através da média ponderada dos pesos sinápticos desse conjunto de saídas lineares, pois não é possível que as regras sejam compartilhadas, gerando-se assim para cada regra uma saída linear.

## 6. Implementação do Sistema Neurofuzzy

O Sistema Neurofuzzy descrito foi implementado utilizando a função ANFIS da ferramenta Fuzzy do Matlab. Esta ferramenta utiliza o método paramétrico Sugeno que utiliza um algoritmo híbrido composto por um método fuzzy baseado em regras e um método matemático, onde as premissas (IF) definem os trechos superpostos relacionados à transferência de entrada e saída, e os consequentes (THEN) definem aproximações lineares para estes trechos.

Neste método paramétrico, os coeficientes da equação linear são treinados por um conjunto de dados de treinamento, que é comparado à fase de aprendizagem de uma rede neural, onde são obtidos os pesos sinápticos.

As saídas das equações lineares são então defuzzificadas, onde a média ponderada dos consequentes (THEN) é avaliada pelos respectivos valores de pertinência, para determinar-se a saída.

## 7. Resultados obtidos

Foram realizadas simulações computacionais para verificar o desempenho do sistema desenvolvido. A Figura 7 mostra o resultado obtido para uma situação de falha onde T3 é maior que T4. O valor da variável de saída apresenta um valor fora do universo de discurso, indicando uma possível situação de falha no sistema.

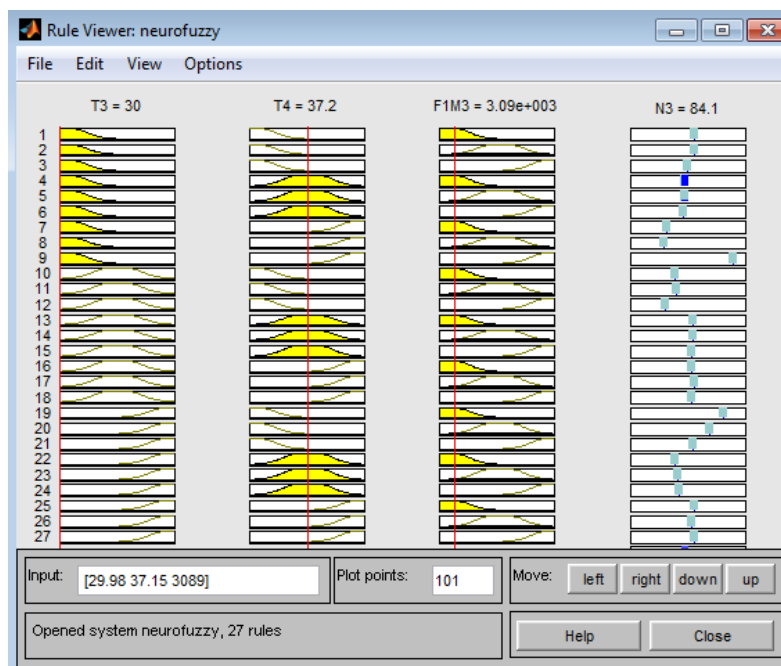


Figura 7. Simulação T3 menor que T4

## 8. Conclusão

Foi desenvolvido um Sistema Neurofuzzy para a Monitoração e Detecção de Falhas da variável N3 (potência), utilizando-se duas variáveis de temperatura (T3 e T4) e uma variável de vazão (F1M3) como entrada do sistema. Os resultados obtidos foram satisfatórios, pois o sistema consegue detectar a presença de falha (T3 maior que T4). A utilização de Sistemas Neurofuzzy é interessante, pois permite que a modelagem do sistema seja feita com base nos dados de entrada/saída apresentados ao sistema. Este é um aspecto interessante, principalmente em sistemas complexos com muitas variáveis de entrada e saída, onde o especialista teria um grau de dificuldade elevado para criar a base de regras e as funções de pertinência do sistema.

## 9. Referências Bibliográficas

- [1] Gajate A., Haber R. E., Vega P. I., and Alique J. R. A Transductive Neuro-Fuzzy Controller: Application to a Drilling Process *IEEE Transactions on Neural Networks*, v. 21, n. 7, July 2010
- [2] Serra G. and Bottura C., An IV-QR Algorithm for Neuro-Fuzzy Multivariable Online Identification. *IEEE Transactions on Fuzzy Systems*, v. 15, n. 2, April 2007
- [3] Othman M. F., Moh Shan T. and Yau, Neuro Fuzzy Classification and Detection Technique for Bioinformatics Problems, *Proceedings of the First Asia International Conference on Modelling & Simulation (AMS'07)*, Control and Instrumentation Department, Faculty of Electrical Engineering, Universiti Teknologi Malaysia, Skudai, Malaysia, 2007
- [4] Panchariya, P.C., Palit, A.K., Popovic, D., Sharma, A.L., Nonlinear System Identification using Takagi-Sugeno Type Neuro-Fuzzy Model, *SECOND IEEE INTERNATIONAL CONFERENCE ON INTELLIGENT SYSTEMS*. 2004
- [5] Chia-Feng Juang, A TSK-Type Recurrent Fuzzy Network for Dynamic Systems Processing by Neural Network and Genetic Algorithms *IEEE Transactions on Fuzzy Systems*, v. 10, n. 2, April 2002
- [6] Sadeghian, A. R., Lavers, J. D., Application of Feedforward Neuro-Fuzzy Networks for Current Prediction in Electric Arc Furnaces, Dept. of Math, Physics & Computer Science, Ryerson Polytechnic University, Toronto, Ontario, Canada 0-7695-06 19-4/00 2000 IEEE
- [7] Zhang, J. and Morris, A. J., Recurrent Neuro-Fuzzy Networks for Nonlinear Process Modeling, *IEEE Transactions on Neural Networks*, v. 10, n. 2, March 1999
- [8] Chia-Feng Juang and Chin-Teng Lin, An On-Line Self-Constructing Neural Fuzzy Inference Network and Its Applications, *IEEE Transactions on Fuzzy Systems*, v. 6, n. 1, February 1998
- [9] Nauck, D., Kruse, R., Otto-von-Guericke, A neuro-fuzzy method to learn fuzzy classification rules from data, University of Magdeburg, Faculty of Computer Science, Universitätsplatz 2, D-39106 Magdeburg, German), *Fuzzy Sets and Systems* 89 (1997) 277-288
- [10] JYH-SHING R. J., and CHUEN-TSAI SUN, Neuro-Fuzzy Modeling and Control, *Proceedings of the IEEE*, v. 83, n. 3, March 1995
- [11] Cárdenas, J. P. N. Monitoração Contínua do Balanço Térmico para determinação da potência do reator IEA-R1. XII ENFIR, 2000.
- [12] Fuzzy Logic Toolbox for use with Matlab