

Identificação da Informação Relevante para a Detecção Neural de Falhas em Varetas de Combustível em Reatores Nucleares

C.R.R. Dornellas^{1,2}, J.M. Seixas¹, W. Soares-Filho^{1,3}

¹COPPE/EE/UFRJ - Universidade Federal do Rio de Janeiro

²DUKE-GP

³IPqM - Instituto de Pesquisas da Marinha - Rio de Janeiro

E-mails: cdornellas@duke-energy.com, seixas@lps.ufrj.br, william@lps.ufrj.br

Abstract

The detection of failed fuel rods in a nuclear plant with a pressurized-water reactor (PWR) is important for the safe operation of the reactor. Here, ultrasonic pulses are used for automatic detection of failed nuclear fuel rods. The detection is based on processing the received echoes of the emitted ultrasonic pulses by means of a neural network. In order to investigate whether a significant reduction on the dimensionality of the original input data space can be achieved, the relevance of each data sample is evaluated. Using four peaks resulting from the reverberation in the inner wall of the rods, 93% of failed rods are correctly identified, for a false alarm probability of ~4%. When using only the third and fourth peaks, the input dimension is reduced from 135 to only 71 data samples and an efficiency of ~93% in the detection of failed rods is obtained, for a false alarm probability of ~7%.

1. Introdução

Em usinas nucleares com reatores com água pressurizada (PWR = *pressurized-water reactor*), o combustível usado é formado por pilhas de pastilhas de urânio, inseridas em varetas de *zircaloy*. A Figura 1 mostra um corte transversal de uma vareta de combustível. O espaço existente entre o combustível e a parede interna do tubo é preenchida com gás hélio. Estas varetas são agrupadas em montagens típicas de 16x16 varetas, que operam mergulhadas em uma piscina de água. Caso ocorra alguma fissura em uma das varetas, a água irá penetrar em seu interior e exporá o combustível ao meio ambiente. A identificação correta destas falhas nas varetas é importante para a segurança e eficiência na operação da usina.

Diversos métodos são usados para a identificação de montagens que contenham uma vareta com fissuras, indo desde uma inspeção visual até operações que tentam detectar a presença do gás hélio ou de radiação na água. O desenvolvimento de métodos automáticos para a detecção da falha, com a utilização de pulsos ultra-sônicos, tem sido largamente usado [1].

Neste trabalho, empregou-se um método ultra-sônico não destrutivo para a inspeção das varetas do protótipo de uma montagem, usando-se uma rede neural para identi-

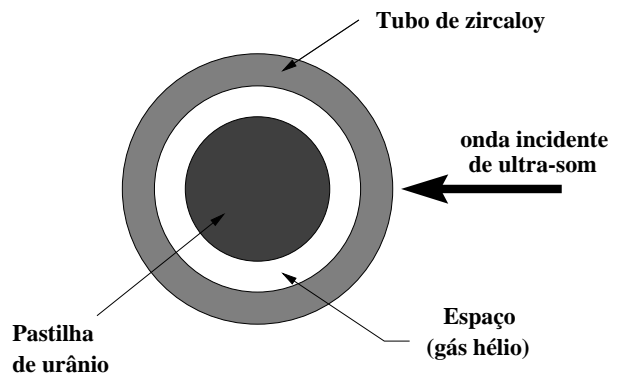


Figura 1: Diagrama esquemático de uma vareta de combustível (Dimensões fora de escala).

ficar as varetas com falhas, a partir do sinal de eco recebido. Procurou-se, então, identificar, no sinal analisado, as informações relevantes para a detecção das falhas, de modo que fosse possível reduzir o conjunto de amostras do padrão de entrada a um conjunto mínimo, que ainda assim mantivesse uma boa eficiência de classificação. Com isto, um classificador neural mais compacto pode ser projetado.

A Seção 2 descreve o experimento realizado, utilizando o ultra-som. Na Seção 3, é mostrado o processamento neural utilizado para a detecção de falhas na vareta. Na Seção 4, são mostrados os critérios para identificação da informação relevante no sinal de entrada do classificador neural. Na Seção 5, são apresentados os resultados encontrados. A Seção 6 encerra o trabalho com algumas conclusões sobre os resultados obtidos.

2 Descrição do Experimento

Para os testes experimentais, construiu-se um protótipo de uma montagem de varetas, usando varetas genuínas, sem combustível nuclear, preenchidas com ar [2]. As varetas foram posicionadas para formar uma montagem de 16x16 varetas, que foi mergulhada em um tanque com água. Algumas varetas foram parcialmente preenchidas com água para simular varetas com fissuras. A Figura 2 mostra, esquematicamente, a disposição das varetas na montagem experimental. Nesta figura, as células marcadas com o símbolo GT representam tubos guias e a célula marcada com IT representa um tu-

3 Processamento Neural

O classificador utilizado para a detecção de falhas nas varetas de combustível foi uma rede neural de três camadas, completamente conectadas e sem realimentação, cujos nós de entrada foram alimentados com 135 amostras do sinal alinhado, correspondendo aos quatro pulsos associados às reflexões na parede interna das varetas [2]. Estes pulsos carregam consigo a informação física da presença ou não de água no interior da vareta. A camada escondida da rede neural foi construída com 10 neurônios e na camada de saída, um único neurônio foi usado para indicar se o sinal é proveniente ou não de uma vareta com falha. Todos os neurônios utilizaram a função de ativação tangente hiperbólica. O algoritmo *backpropagation* foi utilizado como método de treinamento [3]. Para tal, o conjunto de sinais de eco foi particionado em dois: um conjunto de treino, utilizado na etapa de treinamento, e um conjunto de teste, utilizado apenas na avaliação da capacidade de generalização da rede. A saída desejada para cada padrão de entrada, durante o treinamento, foi ajustada em 1 para sinais de eco obtidos de varetas com falhas e em -1 para as demais varetas.

A classificação de um sinal foi feita utilizando-se o valor zero como limiar para a saída da rede. Se a saída for maior que zero, o sinal é declarado como pertencendo a uma vareta com falha. Se for menor que zero, o sinal é dito ser procedente de uma vareta sem falhas.

4 Mapeamento da Informação Relevante

O mapeamento da informação relevante existente nos padrões de entrada de um classificador tem por objetivo a identificação das amostras dos padrões que sejam importantes para a decisão final do classificador [4, 5]. Pode-se, assim, reduzir a entrada do classificador ao conjunto mínimo de amostras que ainda consigam manter uma boa eficiência de classificação. A relevância de uma determinada amostra dos padrões de entrada do classificador pode ser medida verificando-se a variação do valor da saída do classificador quando aquela amostra do padrão de entrada é fixada no seu valor médio dentro do conjunto de treinamento. A medida desta diferença pode ser feita calculando-se o erro médio quadrático da saída do classificador, antes e depois da substituição da amostra pelo seu valor médio, considerando-se ambos os padrões de classificação. Desta forma, a relevância R_i da i -ésima amostra do padrão de entrada é definida como [4]

$$R_i = \frac{1}{N} \sum_{j=1}^N (y(\mathbf{x}_j) - y(\mathbf{x}_j|_{x_{j,i}=\bar{x}_i}))^2 \quad (1)$$

onde \mathbf{x}_j é o j -ésimo padrão de entrada, \bar{x}_i é o valor médio da i -ésima amostra para todos os padrões do conjunto de treino, e N é o número de padrões no conjunto de treino.

Um baixo valor de R_i significa que o fato de se usar, para a amostra i , o valor médio (\bar{x}_i) ou os valores originais para cada sinal ($x_{j,i}$) não provoca uma variação

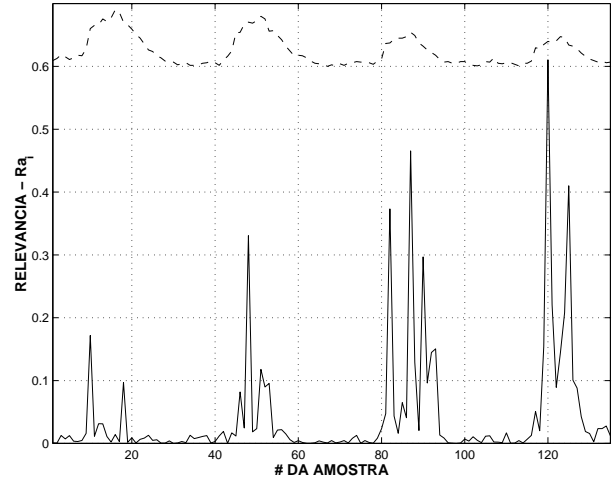


Figura 5: Relevância de cada amostra da entrada do classificador usando-se o erro médio quadrático como figura de mérito (R_i).

significativa na saída do classificador. Esta amostra, portanto, tem pouco poder de discriminação. Já um alto valor de R_i indica que a saída do classificador se altera, sensivelmente, quando se usa o valor médio \bar{x}_i no lugar dos valores originais $x_{j,i}$. Isto significa que os valores originais têm algum poder de separação entre as classes e que este poder é significativamente atenuado, ao ser feita a substituição destes pela média de todos os padrões.

Uma forma alternativa de se avaliar a relevância de uma dada amostra consiste em se verificar como a própria eficiência de classificação se altera, quando esta amostra é substituída pelo seu valor médio, considerando-se todos os eventos do conjunto de treino. Se a dada amostra não for significativa para a classificação, pouca alteração se dará na eficiência de classificação, enquanto que se a amostra for importante, espera-se que a sua substituição pela média faça a eficiência diminuir. Sendo $efic(\mathbf{x})$ a eficiência do classificador para os sinais \mathbf{x} , calculada como sendo a média entre as eficiências de classificação para os sinais das varetas com falhas e sem falhas, a relevância Ra_i é computada como sendo a variação da eficiência de classificação, que ocorre quando se usa o valor médio \bar{x}_i no lugar dos valores originais $x_{j,i}$

$$Ra_i = efic(\mathbf{x}) - efic(\mathbf{x}|_{x_{j,i}=\bar{x}_i}), j = 1, \dots, N \quad (2)$$

onde N é o número de padrões do conjunto de treino. Um aumento em Ra_i para uma dada amostra indica que esta amostra é relevante para a classificação.

5 Resultados

O mapeamento da relevância de cada amostra do sinal foi feita partindo-se de uma rede neural treinada utilizando-se em sua entrada as 135 amostras de cada sinal. A relevância R_i foi computada, de acordo com a Equação 1, substituindo-se cada amostra pelo seu valor médio no conjunto de treino, e calculando-se o erro

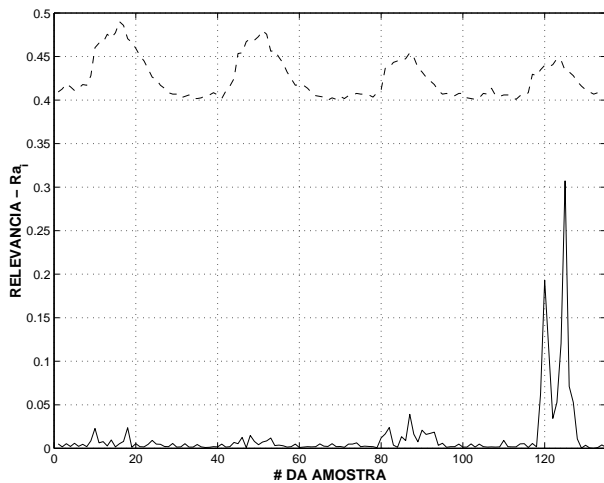


Figura 6: Relevância de cada amostra da entrada do classificador, usando-se a eficiência de classificação para o cálculo da figura de mérito (Ra_i).

médio quadrático em relação à saída inicial. A Figura 5 mostra a relevância R_i obtida. Na figura, quanto maior o erro, mais relevante é a dada amostra para a classificação do sinal. No alto do gráfico é apresentado um sinal típico (alinhado) de entrada, de forma que se possa fazer uma correlação com os valores de R_i . Observa-se que os maiores valores da relevância R_i são obtidos nas posições correspondentes aos quatro picos do sinal de entrada. O quarto pico apresenta maiores R_i , seguidos pelos terceiro, segundo e primeiro picos. Esta importância do quarto pico se encontra de acordo com os resultados de trabalhos anteriores [6]

A relevância das amostras foi computada, também, verificando-se a alteração da eficiência de classificação dos ecos de ultra-som, quando cada amostra é substituída pelo seu valor médio no conjunto de treino. A Figura 6 apresenta a relevância Ra_i , computada de acordo com a Equação 2. Desta forma, quanto menor a nova eficiência de classificação, maior será a relevância da amostra. No alto do gráfico é novamente apresentado um sinal típico de entrada, para que se possa correlacionar os valores da relevância com o sinal. Aqui, também, a relevância Ra_i é máxima na posição correspondente ao quarto pico.

O uso da medida de relevância Ra_i , calculada usando-se a eficiência de classificação, apresenta informações similares às produzidas pela medida de relevância calculada usando-se o erro médio quadrático, R_i . A curva para R_i apresenta uma relevância significativa para os três primeiros picos, o que não foi confirmado pelo mapeamento de Ra_i . O uso de Ra_i , no entanto, tem a vantagem de permitir uma interpretação um pouco mais simples da relevância, uma vez que seu cálculo é baseado na eficiência de classificação dos sinais. Pode-se observar, por exemplo, que a substituição de algumas amostras do quarto pico por seus valores médios provocou uma redução de cerca de 30% na eficiência de classificação da rede neural.

Amostras usadas (N. de amostras)	Eficiência Conj. Teste	
	Água	Ar
Todas (135)	85,9%	88,7%
$R_i > 0,01$ (67)	83,1%	87,8%
$Ra_i > 0,018$ (66)	84,5%	87,7%
4º pico (36)	78,2%	84,3%
3º e 4º picos (71)	87,3%	86,3%

Tabela 1: Eficiência na classificação de sinais de varetas com água e com ar em seu interior.

A seguir, retreinou-se a rede neural utilizando-se apenas as entradas mais relevantes dos sinais. Foram, assim, estabelecidos limiares nas curvas de relevância, de forma que apenas amostras que apresentassem relevância acima destes limiares (amostras mais relevantes) fossem usadas neste novo treinamento da rede neural. Os limiares foram estabelecidos em 0,01 para R_i e em 0,018 para Ra_i . Estes valores foram escolhidos de forma a se conseguir uma redução do espaço de entrada do classificador em torno de 50%. Além disto, treinou-se uma rede utilizando-se apenas as amostras correspondentes ao quarto pico e outra rede utilizando-se as amostras correspondentes aos terceiro e quarto picos.

A Tabela 1 apresenta a eficiência de classificação, para os sinais do conjunto de teste, para uma rede treinada utilizando-se todas as 135 amostras dos sinais (classificador original), e as eficiências de classificação resultantes do treinamento de redes neurais com número reduzido de amostras dos sinais, identificadas como relevantes, de acordo com os critérios descritos. A eficiência de classificação da rede que utilizou todas as amostras ficou em 85,9% para os sinais de água e em 88,7% para os sinais de ar. Ao se utilizar o limiar de 0,01 para R_i , o número de amostras na entrada da rede reduziu-se para 67 amostras, e a eficiência de classificação dos sinais ficou em 83,1% para a classificação dos sinais de água e em 87,8% para os sinais de ar. Já com o limiar de 0,018 para Ra_i , o número de amostras na entrada da rede reduziu-se para 66 amostras e a eficiência de classificação ficou em 84,5% para os sinais de água e em 87,7% para os sinais de ar. Para a rede treinada com o quarto pico, apenas 36 amostras foram utilizadas (amostras #100 a #135) e a eficiência obtida foi de 78,2% para os sinais de água e de 84,3% para os sinais de ar. No caso da rede treinada com os terceiro e quarto picos, foram usadas 71 amostras (amostras de #65 a #135) obtendo-se uma eficiência de classificação de 87,3% para os sinais de água e de 86,3% para os sinais de ar.

A utilização de R_i e de Ra_i , para a identificação de informação relevante para a detecção de falhas em varetas de combustível em reatores nucleares, mostrou que as amostras correspondentes aos quatro picos são importantes para a classificação dos sinais. Entre os picos, o quarto pico é o que apresenta maior relevância, seguido pelo terceiro pico. O uso desta informação de relevância das amostras permitiu a construção de uma rede neural com um número reduzido de entradas sem, no entanto,

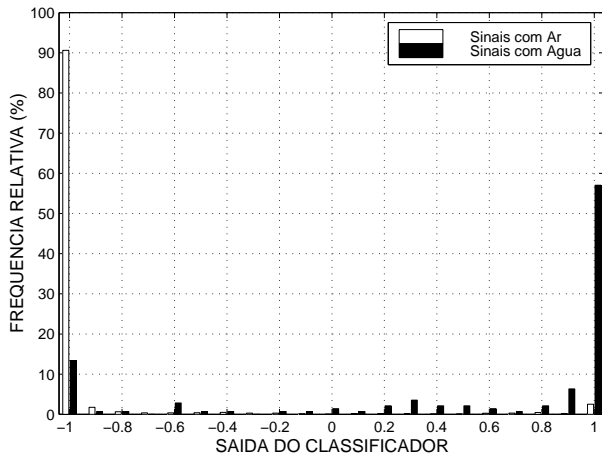


Figura 7: Histogramas da saída da rede para cada uma das classes de sinal.

diminuir sensivelmente a eficiência de classificação dos sinais do conjunto de teste. A utilização apenas do quarto pico provocou uma redução na classificação dos sinais de água, que foi praticamente recuperada ao se incluir o terceiro pico.

A identificação de uma dada vareta com falha foi realizada analisando-se a resposta da rede neural para todos os sinais adquiridos para aquela vareta. Para tal identificação, a rede neural precisa classificar a maioria dos sinais da vareta em questão, como sendo pertencentes à classe de sinais de água. A Figura 7 mostra os histogramas normalizados da saída da rede, após a fase de treinamento, para os sinais de cada classe. A rede usada foi treinada com as 135 amostras do sinal e mostra uma boa identificação dos sinais.

A Tabela 2 mostra as eficiências das diversas redes testadas na identificação de falhas (presença de água ou de ar) nas varetas de combustível. A rede que utiliza todas as 135 amostras dos sinais acertou 93% das varetas com água e 96,3% das varetas com ar. O uso do limiar de 0,01 para R_i manteve o acerto para as varetas com água mas reduziu ligeiramente, para 94,8%, o acerto das varetas com ar. O limiar de 0,018 para Ra_i piorou o acerto das varetas com água, que passou para 86%, além de ter reduzido, também, o acerto das varetas com ar, com 93,9%. O uso apenas do quarto pico dos sinais de entrada obteve os piores resultados dos testes, com 79% de acerto para varetas com água e 91,6% para varetas com ar. A inclusão do terceiro pico dos sinais, junto ao quarto pico, na entrada da rede, fez a eficiência subir novamente, com 93% para as varetas com água e 93,2% para varetas com ar. Estes números apenas reforçam as conclusões obtidas para a identificação dos sinais, em que é possível se reduzir a dimensão dos sinais de entrada das redes, baseado nas informações de relevância, sem uma perda considerável na eficiência de identificação das varetas com falhas. Observe na Tabela 2 que o número de varetas com água é pequeno, de forma que a perda de eficiência ao se errar na classificação de apenas uma vareta

Amostras usadas (N. de amostras)	Eficiência Conj. Teste	
	Água	Ar
Todas (135)	93% (13/14)	96,3% (184/191)
$R_i > 0,01$ (67)	93% (13/14)	94,8% (181/191)
$Ra_i > 0,018$ (66)	86% (12/14)	93,7% (179/191)
4 ^o pico (36)	79% (11/14)	91,6% (175/191)
3 ^o e 4 ^o picos (71)	93% (13/14)	93,2% (178/191)

Tabela 2: Eficiência na identificação de falhas nas varetas de combustível. Os números em parênteses correspondem ao número de varetas com identificação correta e o número total de varetas testadas.




Figura 8: Mapa de eficiência na detecção de falhas em varetas de combustível, usando-se uma rede neural treinada com as 135 amostras dos sinais de entrada. Veja texto.

é de quase sete pontos percentuais. Um estudo de um número maior de varetas simulando falhas é necessário para se definir, com uma maior precisão, o desempenho destas redes usando, na entrada, um conjunto reduzido de amostras.

As Figuras 8 e 9 apresentam mapas da eficiência na detecção de varetas com falhas, para a rede treinada usando todas as 135 amostras dos sinais de entrada e para a rede usando amostras dos sinais de entrada com relevância, R_i , acima do limiar de 0,01. Nestes mapas, as células representam a posição original das varetas, no protótipo da montagem de 16x16 varetas, e a eficiência de detecção é codificada em uma escala de tons de cinza, para a qual tons mais claros correspondem a uma maior eficiência. Desta forma, um mapa mais claro pode ser associado, qualitativamente, a uma melhor performance na detecção. No mapa, eficiências abaixo de 50% correspondem a erros na detecção de falha ou ausência de falha na vareta. Conforme mencionado, as células marcadas com letras e símbolos não foram usadas nos testes e correspondem a varetas sem sinais adquiridos (XX e ponto de interrogação - ?), a tubos guias (GT) e a um tubo de instrumentação (IT). As células são identificadas pelas letras e números marcados nos eixos horizontal e vertical, respectivamente. Assim, a célula K8 corresponde ao tubo




Figura 9: Mapa de eficiência na detecção de falhas em varetas de combustível, usando-se uma rede neural treinada com amostras cujo valor de relevância R_i estavam acima do limiar de 0,01. Veja texto.

de instrumentação, marcado com as letras *IT*. As varetas com água estão posicionadas nas colunas P, nas linhas de 10 a 12 e de 14 a 16, e na coluna T, nas linhas de 9 a 16.

É possível, com estes mapas, localizar as varetas corretamente identificadas e comparar, qualitativamente, o desempenho das redes. O mapa da Figura 9 é ligeiramente mais escuro do que o mapa da Figura 8, indicando um pior desempenho para a rede, alimentada com as amostras com relevância R_i acima de 0,01.

6 Conclusões

Neste trabalho, estudou-se a identificação de falhas em varetas de combustível de reatores com água pressurizada de usinas nucleares, utilizando-se o eco de sinais de ultra-som emitidos em cada uma das varetas. Uma rede neural multicamadas e completamente conectada, treinada com o algoritmo *backpropagation*, foi usada para classificar os ecos, de acordo com a presença, no interior da vareta, de água (vareta com falha) ou de ar (vareta normal). Procurou-se, então, identificar as amostras dos sinais de entrada da rede que possuísem informações relevantes para a classificação dos sinais e, conseqüentemente, para a detecção de falhas nas varetas.

Foram apresentados dois métodos para o cálculo da relevância de cada amostra. Em ambos os casos, a amostra é substituída pelo seu valor médio, considerando-se os sinais que compõem o conjunto de treino. O primeiro método utiliza o erro médio quadrático da saída da rede, antes e depois da substituição da amostra. O segundo método utiliza uma nova abordagem, onde a eficiência de classificação dos sinais é utilizada para a estimativa da relevância. O segundo método tem, como vantagem, uma facilidade maior para interpretação e quantificação dos resultados, uma vez que usa diretamente a eficiência de classificação para estimar a relevância das amostras.

O estudo da relevância mostrou que os picos do si-

nal de entrada contém informações importantes para a classificação, com os terceiro e quarto picos aparecendo como mais relevantes. A redução do número de amostras nos sinais de entrada da rede de acordo com a informação de relevância, reduziu apenas ligeiramente a eficiência na classificação dos sinais de cada vareta.

Agradecimentos

Este trabalho foi parcialmente apoiado pela Eletrobrás Termonuclear S.A., FUJB, CNPq e FAPERJ, Brasil. Agradecemos à equipe que participou deste projeto, e em especial aos Professores Zieli Thomé e Wagner Coelho de Albuquerque Pereira, pela troca de idéias que ajudaram na confecção deste artigo.

Referências

- [1] M. Attar. State-of-the-art ultrasonic detection of failed fuel. *Transactions of the American Nuclear Society*, 61:47–48, 1990.
- [2] J. Seixas, W. Soares-Filho, M. Bossan, Z. Thomé, and W.C.A.Pereira. Neural identification of failed fuel rods in nuclear reactors. In *IEEE Int. Symp. on Circuits and Systems*, volume I, páginas 160–163, Genebra, Suíça, Maio 28-31 2000. IEEE CAS.
- [3] S. Haykin. *Neural networks: A comprehensive foundation, second edition*. Prentice Hall, 1999.
- [4] A. Gruber, J. Möck, J. Fent, W. Fröchtenicht, D. Goldner, C. Kiesling, T. Kobler, H. Kolanoski, T. Krämerkämper, and P. Ribarics. Performance of backpropagation networks in the second-level trigger of the h1-experiment. In K. Becks and D. Perret-Gallix, editors, *New Computing Techniques in Physics Research III*, páginas 429–434. World Scientific Co. Pte. Ltd., 1994.
- [5] J. Seixas, L. Calôba, and I. Delpino. Relevance criteria for variable selection in classifier designs. In *International Conference on Engineering Applications of Neural Networks*, páginas 451–454, Londres, Inglaterra, 1996.
- [6] W. C. de Albuquerque Pereira. Projeto de inspeção de varetas de combustível por ultra-som, do reator de angra i. Technical report, COPPE-UFRJ, 1998.