

INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES
Autarquia associada à Universidade de São Paulo

**DETERMINAÇÃO DO FATOR DE PICO DE POTÊNCIA
UTILIZANDO BARRAS DE CONTROLE, DETECTORES
EX-CORE E REDES NEURAIS**

ROSE MARY GOMES DO PRADO SOUZA

**Tese apresentada como parte dos
requisitos para obtenção do Grau
de Doutor em Ciências na Área de
Tecnologia Nuclear – Reatores.**

**Orientador:
Prof. Dr. João Manoel Losada Moreira**

**São Paulo
24 de agosto de 2005**

*À minha querida e saudosa mãe,
Lourdes da Silva Gomes*

*Ao meu pai,
Pedro Gomes do Prado*

*Ao meu marido,
Pedro Ivo Ferreira de Souza*

*Aos meus filhos,
Pedro Ivo Junior, Anne Rose e Rafael*

AGRADECIMENTOS

Ao Prof. Dr. João Manoel Losada Moreira pela orientação eficaz e apoio na execução deste trabalho, o meu muito obrigada.

Aos Professores Dr. Aquilino Senra Martinez, Dr. Benedito Baptista Dias Filho, Dr. Daniel Kao Sun Ting e Dr. Roberto Schirru por terem aceitado o convite para composição da banca examinadora.

Ao Alfredo Y. Abe, Elcio Angioletto e Rogério Jerez pela colaboração no trabalho experimental.

Ao Prof. Dr. Antônio P. Braga e ao Daniel Henrique Dominguete Carvalho pelas úteis discussões e sugestões.

Ao Hugo de Moura Dalle pela colaboração técnica.

Ao Hertz Pasqualetto e Rinaldo Fuga pela operação do reator IPEN/MB-01.

Ao Hermelindo P. Manoel e Leonam dos Santos Guimarães pela colaboração administrativa.

Aos servidores da Unidade de Informação e Biblioteca do CDTN.

Ao Centro Tecnológico da Marinha em São Paulo, CTMSP, por financiar este trabalho de pesquisa.

À Comissão Nacional de Energia Nuclear e ao Centro de Desenvolvimento da Tecnologia Nuclear pelo apoio ao desenvolvimento deste trabalho.

Ao Instituto de Pesquisas Energéticas e Nucleares, IPEN.

A todos os que contribuíram para a realização deste trabalho.

**DETERMINAÇÃO DO FATOR DE PICO DE POTÊNCIA
UTILIZANDO BARRAS DE CONTROLE, DETECTORES *EX-CORE*
E REDES NEURAIS**

Rose Mary Gomes do Prado Souza

RESUMO

Este trabalho apresenta uma metodologia baseada na técnica de redes neurais artificiais para estimar em tempo real o fator de pico de potência, de forma que possa ser implementado nos sistemas de proteção de reatores. Os dados de entrada da rede neural foram aqueles disponíveis nos sistemas de proteção, a saber, as diferenças de potência axial e por quadrante obtidas de medidas de sinais de detectores *ex-core* e as posições das barras de controle. Os sinais dos detectores *ex-core* foram medidos em experimentos, especialmente planejados, realizados no reator de potência zero IPEN/MB-01. Vários estados do reator, com diferentes distribuições da densidade de potência, foram obtidos pelo posicionamento das barras de controle em diferentes configurações. As distribuições das densidades de potência e seu fator de pico foram calculados, usando o código CITATION. Os resultados mostraram que o fator de pico de potência se correlaciona bem com a posição da barra de controle e com a diferença de potência por quadrante e, em menor grau, com a diferença de potência axial. Os dados apresentaram uma organização inerente e puderam ser classificados em diferentes classes de comportamento do fator de pico de potência como uma função das posições das barras de controle, das diferenças de potência axial e por quadrante. As rede neurais RBF foram capazes de identificar as classes e interpolar os valores dos fatores de pico de potência. O erro relativo obtido na estimativa do fator de pico de potência variou entre 0,19 % e 0,67 %, um erro menor do que o obtido em medidas detalhadas de mapeamentos da distribuição da densidade de potência com detectores *in-core*. Foi observado que as posições das barras de controle produzem informações detalhada e localizada da distribuição de densidade de potência e que as diferenças de potência axial e por quadrante descrevem a sua variação global na direção axial e radial. Os resultados mostraram que as redes RBF e MLP produziram resultados similares e que a técnica pode ser implementada em sistemas de proteção de reatores de potência.

DETERMINATION OF POWER PEAK FACTOR USING CONTROL RODS, EX-CORE DETECTORS AND NEURAL NETWORKS

Rose Mary Gomes do Prado Souza

ABSTRACT

This work presents a methodology based on the artificial neural network technique to predict in real time the power peak factor in a form that can be implemented in reactor protection systems. The neural network inputs were those available in the reactor protection systems, namely, the axial and quadrant power differences obtained from measured *ex-core* detector signals, and the position of control rods. The response of *ex-core* detector signals was measured in experiments especially performed in the IPEN/MB-01 zero-power reactor. Several reactor states with different power density distribution were obtained by positioning the control rods in different configurations. The power distribution and its peak factor were calculated for each of these reactor states using the CITATION code. The obtained results show that the power peak factor correlates well with the control rod position and the quadrant power difference, and with a lesser degree with the axial power differences. The data presented an inherent organisation and could be classified into different classes of power peak factor behaviour as a function of position of control rods, axial power difference and quadrant power difference. The RBF networks were able to identify classes and interpolate the power peak factor values. The relative error for the power peak factor estimation ranged from 0.19 % to 0.67 %, less than the one that was obtained performing a power density distribution map with in-core detectors. It was observed that the positions of control rods bear the detailed and localised information about the power density distribution, and that the axial and the quadrant power difference describe its global variations in the axial and radial directions. The results showed that the RBF and MLP networks produced similar results, and that a neural network correlation can be implemented in power reactor protection systems.

SUMÁRIO

	Página
1 INTRODUÇÃO	11
1.1 Objetivos.....	15
1.2 Justificativa, Relevância e Originalidade da Pesquisa	16
2 METODOLOGIA PARA OBTER O FATOR DE PICO UTILIZANDO REDES NEURAIS	18
2.1 Determinação da Distribuição de Potência a Partir de Sinais de Detectores <i>Ex-core</i> 18	
2.2 Correlação do Fator de Pico de Potência com Variáveis do Sistema de Proteção ...	21
2.3 Redes Neurais	23
2.3.1 Perceptron de Múltiplas Camadas - MLP	24
2.3.2 Função de Base Radial - RBF.....	26
2.4 Determinação do Fator de Pico de Potência Utilizando Redes Neurais	28
3 EXPERIMENTOS E DADOS OBTIDOS	30
3.1 Reator IPEN/MB-01.....	31
3.2 Intercalibração dos Detectores <i>Ex-core</i>	34
3.3 Medidas das Contagens dos Detectores <i>Ex-core</i> e das Posições das Barras de Controle	35
3.4 Dados de Diferenças de Potência Axial e por Quadrante.....	41
3.5 Dados do Fator de Pico de Potência.....	42
4 CORRELAÇÕES PARA O FATOR DE PICO	48
4.1 Correlação entre FP e as Posições das Barras de Controle.....	48
4.2 Correlação entre FP e as DPAs e DPQs	54
5 ESTIMATIVA DO FATOR DE PICO UTILIZANDO REDES NEURAIS	62
5.1 Geração dos Dados para Treinamento das Redes Neurais	62
5.2 Treinamento das Redes Neurais.....	64
5.2.1 Treinamento da Rede MLP	65

5.2.2	Treinamento da Rede RBF	66
5.3	Estimativa dos Fatores de Pico de Potência	67
5.3.1	Estimativa do FP a partir dos Sinais das Posições das Barras de Controle.....	68
5.3.2	Estimativa do FP a partir das Diferenças de Potência Axial e por Quadrante	75
5.3.3	Estimativa do FP a partir das Posições das Barras de Controle e das Diferenças de Potência Axial e por Quadrante.....	81
5.4	Discussão dos Resultados das Estimativas do FP.....	84
5.5	Robustez das Redes Neurais RBF e MLP	86
5.6	Discussão sobre Possível Aplicação em Reator de Potência.....	88
5.6.1	Vantagens e Dificuldades na Aplicação em Reatores de Potência.....	90
6	CONCLUSÕES	93
	APÊNDICE A - Rotina Experimental	97
	APÊNDICE B - Avaliação das Incertezas pela Fórmula de Propagação de Erros...	110
	APÊNDICE C - Programas para Treinamento das Redes Neurais	112
	APÊNDICE D - Aplicação do Método da Parada Antecipada no Treinamento de RN	125
	APÊNDICE E – Teste de Robustez das Redes RBF e MLP	129
	APÊNDICE F – Implementação em Sistema de Proteção de Reatores de Potência.	139
	REFERÊNCIAS BIBLIOGRÁFICAS	141

LISTA DE TABELAS

	Página
TABELA 3.1 - Dados gerais do reator de potência zero IPEN/MB-01 (IPEN, 1988)	32
TABELA 3.2 - Dados técnicos dos detectores de nêutrons de ^{10}B utilizados para simular os detectores <i>ex-core</i> e fatores de intercalibração	35
TABELA 3.3 - Classes de movimentação das barras de controle na construção dos estados experimentais com diferentes distribuições de densidade de potência	38
TABELA 3.4 - Posições das barras de controle e contagens normalizadas dos detectores <i>ex-core</i>	39
TABELA 3.5 - Posições das barras de controle, diferenças de potência axiais, diferenças de potência por quadrante e fatores de pico para os 56 estados críticos	43
TABELA 5.1 - Estados pertencentes aos subconjuntos de treinamento e de validação	63
TABELA 5.2 - Arquitetura e a raiz quadrada do erro médio quadrático obtido no treinamento com as redes RBF e MLP, tendo as posições das 4 barras de controle como entrada (Eq. 5.4).....	69
TABELA 5.3 - Estatística da estimativa do FP pelas redes RBF e MLP, tendo as posições das 4 barras de controle como entrada (Eq. 5.4)	72
TABELA 5.4 - Erros de treinamento e de validação das redes RBF, tendo as posições de três barras de controle como entrada (Eq. 5.5).....	75
TABELA 5.5 - Arquitetura e a raiz quadrada do erro médio quadrático obtido no treinamento com as redes RBF e MLP, tendo as DPAs e DPQs como entrada (Eq. 5.6)	76
TABELA 5.6 - Estatística da estimativa do FP pelas redes RBF e MLP, tendo as DPAs e DPQs como entrada (Eq. 5.6)	78
TABELA 5.7 - Erros de treinamento e de validação das redes RBF, tendo as posições das 4 barras de controle, DPAs e DPQs, normalizadas, como entrada (Eq. 5.7).....	82
TABELA 5.8 - Erros de treinamento e de validação das redes RBF, tendo as posições das 4 barras de controle e DPAs, sem normalizar, como entrada (Eq. 5.8).....	82
TABELA 5.9 - Erros de treinamento e de validação das redes RBF, tendo as posições das 3 barras de controle, DPAs e DPQs, normalizadas, como entrada (Eq. 5.9).....	83
TABELA 5.10 - Erros na estimativa do FP pelas redes neurais RBF, tendo as posições das barras de controle, DPAs e DPQs como entrada (Eq. 5.7, 5.8 e 5.9).....	83
TABELA 5.11 - Performance de todas as redes neurais na estimativa do fator de pico	86
TABELA 5.12 - Avaliação dos erros na estimativa do FP em caso de falha, dando sinal nulo, em cada uma das variáveis do vetor de entrada do subconjunto 7	88

LISTA DE FIGURAS

	Página
FIGURA 2.1 - Arquitetura típica de uma rede neural com uma camada oculta.....	28
FIGURA 3.1 - Vista do reator de potência zero IPEN/MB-01.....	33
FIGURA 3.2 - Vista do reator de potência zero IPEN/MB-01 representando o núcleo, o tanque moderador, a instrumentação do reator e os detectores <i>ex-core</i>	33
FIGURA 3.3 - Vista lateral do reator IPEN/MB-01, tanque e detectores.	36
FIGURA 3.4 - Distribuição radial da densidade potência normalizada - estado 1.....	45
FIGURA 3.5 - Distribuição axial da densidade potência normalizada - estado 1.	45
FIGURA 3.6 - Distribuição radial da densidade potência normalizada - estado 40.	46
FIGURA 3.7 - Distribuição axial da densidade potência normalizada - estado 40.	46
FIGURA 3.8 - Distribuição radial da densidade potência normalizada - estado 43.	47
FIGURA 3.9 - Distribuição axial da densidade potência normalizada - estado 43.	47
FIGURA 4.1 - Fator de pico em função da posição da barra de controle BS1.....	50
FIGURA 4.2 - Fator de pico em função da posição da barra de controle BS2.....	50
FIGURA 4.3 - Fator de pico em função da posição da barra de controle BC1.	51
FIGURA 4.4 - Fator de pico em função da posição da barra de controle BC2.	51
FIGURA 4.5 - Fator de pico em função da posição da barra de controle BS1, identificando as 9 diferentes classes do conjunto de dados.	52
FIGURA 4.6 - Fator de pico em função da posição da barra de controle BS2, identificando as 9 diferentes classes do conjunto de dados.	52
FIGURA 4.7 - Fator de pico em função da posição da barra de controle BC1, identificando as 9 diferentes classes do conjunto de dados.	53
FIGURA 4.8 - Fator de pico em função da posição da barra de controle BC2, identificando as 9 diferentes classes do conjunto de dados.	53
FIGURA 4.9 - Fator de pico em função da diferença de potência axial do lado norte.	55
FIGURA 4.10 - Fator de pico em função da diferença de potência axial do lado oeste.	56
FIGURA 4.11 - Fator de pico em função da diferença de potência por quadrante para a parte inferior do núcleo.	56
FIGURA 4.12 - Fator de pico em função da diferença de potência por quadrante para a parte superior do núcleo.	57
FIGURA 4.13 - Fator de pico em função da DPA ^N , identificando as classes 1, 2, 4, 6 e 7.	57
FIGURA 4.14 - Fator de pico em função da DPA ^N , identificando as classes 3, 5, 8 e 9.	58
FIGURA 4.15 - Fator de pico em função da DPA ^W , identificando as classes 1, 2, 3, 4 e 5.	58

FIGURA 4.16 - Fator de pico em função da DPA^W , identificando as classes 6, 7, 8 e 9....	59
FIGURA 4.17 - Fator de pico em função da DPQ_B , identificando as classes 1, 2, 3, 4 e 5.	59
FIGURA 4.18 - Fator de pico em função da DPQ_B , identificando as classes 6, 7, 8, e 9. ..	60
FIGURA 4.19 - Fator de pico em função da DPQ_T , identificando as classes 1, 2, 3, 4 e 5.	60
FIGURA 4.20 - Fator de pico em função da DPQ_T , identificando as classes 6, 7, 8 e 9. ...	61
FIGURA 5.1 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural RBF, tendo as posições das 4 barras de controle como entrada.....	70
FIGURA 5.2 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural MLP, tendo as posições das 4 barras de controle como entrada.	70
FIGURA 5.3 - Estimativa do FP pela rede neural RBF, considerando todos os dados dos subconjuntos de validação, tendo as posições das 4 barras de controle como entrada.	72
FIGURA 5.4 - Estimativa do FP pela rede neural MLP, considerando todos os dados dos subconjuntos de validação, tendo as posições das 4 barras de controle como entrada.	73
FIGURA 5.5 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural RBF, tendo as posições das 4 barra de controle como entrada.	73
FIGURA 5.6 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural MLP, tendo as posições das 4 barra de controle como entrada.	74
FIGURA 5.7 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural RBF, tendo as DPAs e DPQs como entrada.	77
FIGURA 5.8 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural MLP, tendo as DPAs e DPQs como entrada.....	77
FIGURA 5.9 - Estimativa do FP pela rede neural RBF, considerando todos os dados dos subconjuntos de validação, tendo as DPAs e DPQs como entrada.	79
FIGURA 5.10 - Estimativa do FP pela rede neural MLP, considerando todos os dados dos subconjuntos de validação, tendo as DPAs e DPQs como entrada.	79
FIGURA 5.11 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural RBF, tendo as DPAs e DPQs como entrada.....	80
FIGURA 5.12 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural MLP, tendo as DPAs e DPQs como entrada.....	80

1 INTRODUÇÃO

Em reatores de potência, o sistema de proteção monitora variações globais da distribuição de densidade de potência para assegurar que os limites de projeto relacionados à geração e transferência de calor sejam respeitados e, assim, assegurar a integridade do combustível. Esta monitoração é importante para a verificação dos limites de segurança de densidade de potência máxima propriamente dito, e de DNB (*Departure from Nucleate Boiling*), que é o parâmetro que merece mais atenção no tocante ao projeto termo-hidráulico e é fortemente dependente da distribuição da densidade de potência do reator (USNRC, 1995). A precisão da estimativa do fator de pico da densidade de potência pelo sistema de proteção é importante para que se possa diminuir a margem de incerteza associada aos limites de proteção e, assim, aumentar a segurança do reator (Boman, 1981; USNRC, 1995). Adicionalmente, aumentar sua precisão acarreta vantagens em outras áreas, tais como permitir a implementação mais simples e econômica de carregamentos de combustível; permitir maior flexibilidade operacional durante os transientes de seguimento de carga, com forte distribuição assimétrica de xenônio; e, também, aumentar o nível de potência máxima do reator, acima do valor nominal, ampliando sua capacidade de geração (Sipush, et al., 1976; Meyer et al., 1978; Aragonés et al., 1996; Kuehnel et al., 2002).

Em alguns reatores PWR, o fator de pico da densidade de potência é monitorado durante a operação de forma indireta. Em intervalos de tempo estabelecidos, é feito um mapeamento da distribuição de potência com detectores *in-core* móveis. Um programa de computador processa este mapa de densidade de potência para fornecer o fator de pico de potência, que é considerado válido por certo período de tempo. Outros reatores PWR utilizam sistemas de detectores *in-core* fixos que fornecem mapeamentos mais frequentes e que, após processados, fornecem também o fator de pico de potência. As variações na distribuição de potência que ocorrem durante os períodos entre mapeamentos devem ser monitoradas por meio de variáveis medidas (USNRC, 1995). Isto é feito, normalmente, multiplicando-se o fator de pico de potência, obtido previamente, por um fator de correção baseado nas diferenças de potência axial e por quadrante, obtidas dos sinais dos detectores *ex-core*, e nas indicações das inserções das barras de controle.

Os reatores para propulsão naval, em razão do seu modo de operação peculiar e menor porte, apresentam características diferentes dos reatores de geração núcleo-elétrica. Em reatores navais é possível correlacionar com precisão a distribuição da densidade de potência com as informações das posições das barras de controle. Nestes reatores, que não utilizam sistema de diluição de boro no refrigerante para controle da reatividade, as barras de controle passam a ser os únicos meios que possibilitam o controle de reatividade durante a operação do reator. Há, assim, uma relação quase direta entre a queima de combustível, as condições do xenônio, a distribuição de potência e as posições das barras de controle.

Em reatores de pequeno porte, a estimativa do fator de pico utilizando detectores *ex-core* apresenta interrogações quanto a sua precisão, em razão do pequeno tamanho do núcleo do reator, em relação ao tamanho do detector e das pequenas distâncias envolvidas. Diferentemente dos reatores de grande porte, o detector *ex-core* localizado na parte superior do reator monitora quase a totalidade do núcleo. O mesmo acontece com aquele localizado na parte inferior. A instalação de um sistema como este, para determinar o fator de pico a partir dos sinais dos detectores *ex-core*, em um reator de pequeno porte exige que se verifique a precisão deste procedimento para monitorar a variação da distribuição da densidade de potência.

A motivação deste trabalho foi a necessidade de se desenvolver um algoritmo para estimar em tempo real o fator de pico de potência, a ser utilizado no sistema de proteção do reator de pequeno porte que está sendo desenvolvido pelo Centro Tecnológico da Marinha em São Paulo – CTMSP. Assim, iniciaram-se os estudos sobre a monitoração da distribuição de potência por sistemas de proteção de reatores PWR e de sua aplicabilidade em reatores de pequeno porte.

A relação entre as variáveis medidas, isto é, posições das barras de controle e sinais dos detectores *ex-core*, e a distribuição da densidade de potência dentro do núcleo não é obtida com facilidade. No caso das posições das barras de controle, é necessária a solução da equação de transporte ou da equação de difusão de nêutrons, em três dimensões e em vários grupos de energia, para todo o núcleo do reator (Bell e Glasstone, 1970; Duderstadt e Hamilton, 1976; Stacey, 2001). No caso dos sinais dos detectores *ex-core* o problema é mais complexo, pois para obtê-la, com todo rigor teórico, é necessária a solução da equação de transporte de nêutrons, em três dimensões e em vários grupos de energia, para o núcleo, para a blindagem térmica, para a parede do vaso de pressão e para

os detectores *ex-core* (Crump e Lee, 1978). Os sistemas de proteção instalados nos reatores não dispõem de capacidade computacional suficiente para processar em tempo real a solução da equação de transporte de nêutrons. Assim, o procedimento adotado nestes sistemas tem sido o de se estabelecer correlações entre as variáveis medidas e o fator de pico da densidade de potência para se verificar o atendimento aos limites de segurança (Kim e Chang, 1997; Kuehnel et al., 2002; Lee e Chang, 2003).

As incertezas associadas aos limites de segurança dos sistemas de proteção são usualmente grandes porque são utilizados algoritmos pouco sofisticados, devido à necessidade de processamentos em tempo real. A introdução da eletrônica digital no projeto dos sistemas de proteção, ao muni-los com maior capacidade computacional, permite a implementação de correlações mais inteligentes que reduzem as margens de incerteza destes limites de segurança (Aragonés et al., 1996; Kim e Chang, 1997; Kuehnel et al., 2002; Lee e Chang, 2003).

A dificuldade envolvida no desenvolvimento destas correlações mais inteligentes consiste na inexistência de uma relação funcional direta entre o fator de pico de potência e as posições das barras de controle e entre o fator de pico de potência e os sinais dos detectores *ex-core*. Nos últimos anos, a técnica de redes neurais artificiais tem sido utilizada para estabelecer estas correlações, a fim de inferir o fator de pico da densidade de potência a partir das posições das barras de controle e dos sinais dos detectores *ex-core* (Kim e Chang, 1997; Seon et al., 2002; Guanghai et al., 2003; Lee e Chang, 2003; Na et al., 2004). A grande motivação de se considerar as redes neurais é a sua natureza não funcional, que torna possível modelar sistemas não lineares complexos, nos quais somente estão disponíveis dados de entrada e de saída dos sistemas.

A literatura cita diversos casos de utilização de redes neurais em engenharia nuclear. Pode-se dizer que as aplicações mais encontradas são voltadas para o desenvolvimento de sistemas de diagnósticos (Leger, et al., 1995; Pázsit e Garis, 1996; Pázsit e Kitamura, 1996; Reifman, 1997); para a otimização de recarga de combustível (Sadighi et al., 2002; Erdogan e Geçkinli, 2003; Faria e Pereira, 2003; Yamamoto, 2003; Ortiz e Requena, 2004; Ziver et al., 2004); para o controle de variáveis importantes de centrais nucleares (Na e Upadhyaya, 1998; Accorsi et al., 1999; Tambouratzis e Antonopoulos-Domis, 1999; Lin e Shen, 2000; Uluyol et al., 2001; Boroushaki et al., 2003, 2004; Craciunescu, 2004); para a validação de sinal (Ikonomopoulos e Van der Hagen, 1997); para monitoração de anomalias, por meio da observação, ao longo do tempo, das

variáveis do circuito primário (Marseguerra et al., 1996; Nabeshima et al., 1998); e para melhorar a precisão de parâmetros inferidos por meio de medidas indiretas ou a partir de correlações entre as variáveis do sistema (Kim et al., 1993; Kim e Lee, 1993; Kim e Chang, 1997; Kostic, 1997; Lombardi e Mazzola, 1997; Garis et al., 1998; Lindén e Pázsit, 1998; Seon et al., 2002; Seong et al., 2002; Su et al., 2002; Guanghui et al., 2002, 2003; Lee e Chang, 2003; Ortiz e Requena, 2003; Na et al., 2001, 2004).

Este trabalho de pesquisa está inserido na última classe de aplicações citada acima, isto é, inferir o valor do fator de pico de potência estabelecendo uma correlação entre ele e as variáveis disponíveis no sistema de proteção, que são as posições das barras de controle e os sinais de detectores *ex-core*.

Kim e Chang (1997) desenvolveram redes neurais para estimar o DNBR usando, como entrada, variáveis termo-hidráulicas do núcleo e informações sobre a distribuição de potência (fator de pico radial e densidade de potência axial). Na hipótese da distribuição da densidade de potência ser constante e conhecida, eles estimaram o DNBR com 3,5 % de incerteza; e na hipótese da distribuição da densidade de potência ser desconhecida e variável, eles estimaram o DNBR com 11,5 % de incerteza. Eles tentaram descrever a distribuição da densidade de potência axial com 3, 4, 5 e 20 parâmetros e o melhor resultado foi o obtido com 4 parâmetros.

Na et al. (2004) desenvolveram redes neurais fuzzy para estimar a distribuição de DNBR no canal quente. Eles utilizaram como entrada variáveis termo-hidráulicas simuladas, diferenças de potência axial e posições das barras de controle para descrever a distribuição da densidade de potência radial no núcleo. A variável de entrada mais influente foi a diferença axial de potência e o DNBR mínimo foi estimado com 13,6 % de incerteza.

Lee e Chang (2003) utilizaram redes neurais RBF para estimar o DNBR, adotando a distribuição de potência, estimada dos sinais dos detectores *ex-core* e posições das barras de controle. Nos casos em que a distribuição da densidade de potência é variável, o DNBR foi estimado com 10 % de incerteza. Seon et al. (2002) tentaram, com redes neurais com 20 neurônios, obter a distribuição da densidade de potência axial de sinais de detectores *ex-core*. Foram utilizados dados simulados para representar os sinais dos detectores *ex-core* e a distribuição real da densidade de potência. Eles comentaram que, para uma aplicação real em reatores de potência, seriam necessários dados

tridimensionais precisos da distribuição da densidade de potência, para reduzir as margens de incertezas durante o processo de generalização.

A literatura consultada mostrou que muitas aplicações consideraram uma camada oculta suficiente para resolver os problemas e que o número de neurônios na camada oculta variou de acordo com o número de entradas e saídas. A utilização de redes neurais artificiais para obter o fator de pico de potência ou o DNBR mostrou que os resultados com menores incertezas foram os obtidos com redes neurais com menor número de neurônios (Kim e Chang, 1997; Guanghui et al., 2003; Lee e Chang, 2003; Na et al., 2004).

1.1 Objetivos

A motivação deste trabalho foi a necessidade de se desenvolver o sistema de proteção para o reator de pequeno porte do LABGENE (Laboratório de Geração Nucleo-elétrica), em construção em Aramar. Após estudos iniciais, definiu-se que a técnica de redes neurais artificiais seria adequada para correlacionar o fator de pico da distribuição de potência com as variáveis disponíveis no sistema de proteção, pois esta técnica permite modelar sistemas não lineares complexos, para os quais somente estão disponíveis dados de entrada e de saída dos sistemas e se desconhece a relação funcional. Entretanto, algumas dificuldades se apresentavam e deveriam ser resolvidas.

Por ser o reator desta instalação de pequeno porte, fez-se necessário verificar, devido às distâncias reduzidas envolvidas, a existência e a precisão da correlação entre as diferenças de potência axial e por quadrante e o fator de pico da distribuição de densidade de potência. Para se obter correlações precisas era necessário possuir um conjunto de dados precisos que possibilitasse o treinamento da rede neural, relacionando a entrada (posições das barras de controle e/ou sinais dos detectores *ex-core*, na forma de diferenças de potência axial e por quadrante) com a saída (fatores de pico das distribuições de densidade de potência). Assim, decidiu-se fazer experimentos específicos, para se obter este conjunto de dados, no reator de potência zero IPEN/MB-01 do Instituto de Pesquisas Energéticas e Nucleares, que simulassem a real situação que ocorre nos reatores de potência. Finalmente, para a efetiva implantação da correlação desenvolvida em um sistema de proteção era necessário que o procedimento experimental estabelecido no reator IPEN/MB-01 fosse possível de ser realizado em reatores de potência de pequeno ou grande porte.

Assim, os objetivos perseguidos neste trabalho foram:

1. obter um conjunto de dados experimentais que relacionem o fator de pico e as posições das barras de controle para que possam ser usados para treinar uma rede neural;
2. obter um conjunto de dados experimentais que relacionem o fator de pico e os sinais de detectores *ex-core* por meio de diferenças de potência axial e por quadrante para que possam ser usados para treinar uma rede neural;
3. verificar quão forte é a correlação entre as diferenças de potência axial e por quadrante e o fator de pico da distribuição de densidade de potência, em reatores de pequeno porte;
4. utilizar redes neurais para estabelecer as correlações entre as variáveis de entrada (posições das barras de controle e/ou diferenças de potência axiais e por quadrante) e saída (fator de pico de potência), a fim de estimar o fator do pico de potência, e determinar a precisão destas correlações;
5. discutir um possível procedimento para determinar os parâmetros da correlação de redes neurais que seja exequível em reatores de potência.

1.2 Justificativa, Relevância e Originalidade da Pesquisa

Como foi mencionado anteriormente, a motivação inicial deste trabalho foi desenvolver uma correlação para monitorar o fator de pico da densidade de potência que fosse implementada no sistema de proteção no reator do LABGENE.

Um sistema deste tipo também pode ser utilizado no sistema de supervisão e limitação do reator, provendo ao operador informações ligadas à segurança durante a operação.

Entretanto, este trabalho é também de interesse para reatores de potência de grande porte em geral. O desenvolvimento de uma correlação para estimar o fator de pico que seja mais precisa, ao ser aplicada em um sistema de proteção de reatores de potência, permite também aumentar o nível de potência máxima do reator, acima do valor nominal, ampliando sua capacidade de geração. Do ponto de vista de eficiência operacional e econômica, um aumento da precisão permite também o carregamento de combustível de forma mais simples e permite uma operação mais segura e flexível durante os transientes de seguimento de carga, com forte distribuição assimétrica de xenônio (Sipush, et al., 1976; Meyer et al., 1978; Aragonés et al., 1996; Kuehnel et al., 2002).

Os aspectos originais deste trabalho de pesquisa são: a obtenção de dados experimentais no reator IPEN/MB-01, a fim de se estabelecer uma metodologia para se obter uma correlação para determinar o fator de pico da densidade de potência, que seja aplicável em reatores de potência; a metodologia adotada para garantir a precisão da correlação de redes neurais; e a demonstração de que é possível utilizar os sinais dos detectores *ex-core* para se determinar o fator de pico de potência em reatores de pequeno porte.

No Capítulo 2 é apresentada a metodologia que foi adotada no trabalho, uma introdução sobre redes neurais e sua aplicação ao problema proposto. Já no Capítulo 3 são descritos os experimentos e cálculos que foram feitos para a obtenção dos dados de treinamento das redes neurais. No Capítulo 4 é demonstrada a existência e a característica da correlação entre o fator de pico e as posições das barras de controle e as diferenças de potência axial e por quadrante, obtidas de sinais de detectores *ex-core*. No Capítulo 5 são apresentados os resultados obtidos com as redes neurais que foram desenvolvidas, uma análise destes resultados e de como estas correlações podem ser implementadas em reatores de potência. Por fim, no Capítulo 6 são relacionadas as conclusões gerais e as sugestões para trabalhos relacionados ao tema.

2 METODOLOGIA PARA OBTER O FATOR DE PICO UTILIZANDO REDES NEURAIAS

A densidade de potência máxima é um parâmetro importante do ponto de vista operacional e de segurança, e é monitorada, continuamente e em tempo real, pelo sistema de proteção do reator (USNRC, 1995). Outra variável monitorada por este sistema, que visa garantir condições seguras de transferência de calor durante a operação, é a razão de DNB (DNBR) que é definida como a relação entre o fluxo de calor crítico (DNB), calculado numa particular localização do canal mais quente do refrigerante, e o fluxo de calor real, na mesma posição. O DNBR é função das condições locais de transferência de calor, dada em termos de pressão, temperatura e vazão do refrigerante, e também, fortemente, da distribuição de densidade de potência (Boman, 1981; Chiu, 1981; USNRC, 1995; Holowach, et al., 2002; Tsukuda et al., 2003). A densidade de potência máxima e a densidade de potência no local onde ocorre o DNB não são medidas diretamente e são normalmente inferidas por meio de correlações que dependem dos sinais de detectores *ex-core*, de posição das barras de controle e de detectores *in-core* (USNRC, 1995).

O objetivo deste trabalho é obter um conjunto de dados que permita correlacionar o fator de pico de potência com os sinais dos detectores *ex-core* e de posição das barras de controle que possa ser implantado em sistemas de proteção. A correlação será obtida por intermédio da técnica de redes neurais que tem características próprias. Este capítulo discute, inicialmente, como os sinais de detectores *ex-core* se relacionam com a distribuição de densidade de potência do reator e discute como correlacionar o fator de pico da distribuição de densidade de potência com as variáveis disponíveis no sistema de proteção. A seguir, faz-se uma introdução às redes neurais e discute-se os cuidados especiais que se deve ter para determinar o fator de pico utilizando esta técnica.

2.1 Determinação da Distribuição de Potência a Partir de Sinais de Detectores *Ex-core*

A variação na distribuição de potência do reator é inferida indiretamente por meio de diferenças de potência axial e por quadrante (McFarlane, 1970; Sipush, et al.,

1976; Meyer et al., 1978; Sakamoto et al., 1992; Boroushki et al., 2003; Kim e Seong, 2003 a, b). A diferença de potência axial, DPA, é definida como a diferença entre a potência gerada na metade inferior do núcleo, P_B , e a gerada na metade superior, P_T , expressa como uma porcentagem da potência total do reator,

$$DPA = \frac{P_B - P_T}{P_B + P_T}. \quad (2.1)$$

Se a distribuição de potência está deslocada para a parte inferior do núcleo, devido à presença de barras de controle na parte superior, a DPA será mais positiva. Esta grandeza é usada para inferir quão destorcida está a distribuição da densidade de potência na direção axial, durante a operação. Por causa desta característica, a DPA é usada para monitorar fortes assimetrias axiais na distribuição de potência, causadas pelos transientes de envenenamento de xenônio.

A diferença de potência por quadrante, DPQ, é definida em relação ao plano x-y do núcleo do reator. Suponha que o núcleo seja dividido em 4 quadrantes denominados faces Norte, Sul, Leste e Oeste. A diferença de potência por quadrante para duas destas faces, digamos Norte e Oeste, é definida como a diferença entre a potência gerada no quadrante norte do núcleo, P^N , e a gerada no quadrante oeste, P^W , dividida pela soma das potências geradas nestes quadrantes,

$$DPQ^{NW} = \frac{P^N - P^W}{P^N + P^W} \quad (2.2)$$

similarmente, a DPQ é expressa como uma porcentagem. As definições de diferenças de potência para outros quadrantes podem ser feitas de forma semelhante.

As DPA e DPQs fornecem informações complementares sobre a distribuição de densidade de potência do reator. Estas informações juntas podem dar uma indicação das mudanças globais que a distribuição de densidade de potência do reator está sofrendo.

Diferenças de potência semelhantes às DPQs podem ser obtidas para as partes superior e inferior do núcleo do reator. Neste caso, se consideraria a potência gerada em 1/8 ou octante do núcleo. Neste trabalho, considera-se para estas variáveis a nomenclatura de quadrante inferior e quadrante superior e introduzindo os respectivos índices para a identificação.

Os sinais dos detectores *ex-core* são usados para monitorar o nível da potência nuclear para os sistemas de controle e de proteção e, também, para fornecer as potências P_B , P_T , P^N , P^W , etc., dentro do núcleo do reator. Assumindo que o fluxo de nêutrons rápidos na periferia de uma dada região do reator seja proporcional à potência gerada na região, pode-se considerar que os sinais dos detectores *ex-core* sejam bons indicadores das potências nestas regiões do reator. Isto porque os detectores *ex-core* registram, principalmente, os nêutrons rápidos, vindos da periferia do núcleo próximos a eles, e que não são absorvidos pela blindagem térmica e pelas paredes do vaso de pressão (Crump e Lee, 1978; Sengler e Mourlevat, 1985; Kuehnel et al., 2002). A precisão das medidas da distribuição de potência, pelo sistema de monitoração *ex-core*, depende da qualidade do algoritmo ou correlação utilizada para estimá-la e da frequência de calibração com a instrumentação *in-core* (Crump e Lee, 1978; Sengler e Mourlevat, 1985; Borges, 1988; Dio e Gruen, 1988; Matsumoto et al., 1997; Wang et al., 2003).

Supondo que um reator tenha dois canais de instrumentação *ex-core*, localizados nos seus lados norte e oeste, e que cada canal tenha dois detectores, um na parte superior do núcleo e o outro na sua parte inferior, a diferença de potência axial para um dado canal pode ser definida como a diferença entre os sinais dos detectores localizados em cotas abaixo e acima do centro do núcleo, dividido pela soma de ambos os sinais. Para o lado norte, DPA^N será:

$$DPA^N = \frac{C_B^N - C_T^N}{C_B^N + C_T^N} \quad (2.3)$$

onde C_B^N e C_T^N são os sinais dos detectores que monitoram a parte inferior e a superior do lado norte do núcleo, respectivamente. Uma definição similar pode ser feita para a DPA^W , diferença de potência axial do lado oeste, trocando o superescrito “N” por “W”.

As diferenças de potência por quadrante das partes inferior e superior do núcleo indicam quão assimétrica está a distribuição de potência na direção radial. Similarmente, elas podem ser obtidas com a diferença entre os sinais dos detectores colocados do lado norte e oeste dividido pela soma deles. Para a parte inferior do núcleo, DPQ_B é dada por

$$DPQ_B = \frac{C_B^N - C_B^W}{C_B^N + C_B^W}. \quad (2.4)$$

A definição de DPQ_T para a metade superior do núcleo é similar, substituindo o subscrito “B” pelo “T”.

2.2 Correlação do Fator de Pico de Potência com Variáveis do Sistema de Proteção

O fator de pico de potência, FP, é definido como a razão entre o valor máximo da distribuição da densidade de potência e o seu valor médio. A distribuição de potência, dentro do núcleo do reator, é sensível a muitos parâmetros relacionados com o núcleo: a posição das barras de controle, o nível de potência no núcleo, a queima do combustível, a distribuição do xenônio, e, com menos importância, os efeitos de realimentação termo-hidráulica e a concentração de boro (USNRC, 1995; Wang et al., 2003). Se todos estes parâmetros fossem monitorados durante a operação do reator, a correlação para se determinar o fator de pico poderia considerá-los em sua formulação. Entretanto, tal não ocorre e somente as posições das barras de controle, o nível de potência e a concentração de boro solúvel no refrigerante são monitorados. É necessário verificar quais dos parâmetros monitorados devem fazer parte da formulação da correlação e inferir o comportamento dos parâmetros não monitorados e como eles afetam a distribuição de potência.

A operação do reator está sempre acompanhada pelos movimentos das barras de controle, que introduzem um forte absorvedor de nêutrons, em locais designados no núcleo. Tais movimentos induzem intensas perturbações locais e globais na distribuição de potência. Usualmente, a presença da barra de controle na parte superior do núcleo do reator desloca a distribuição de potência em direção à parte inferior e, conseqüentemente, afeta o fator de pico de potência (Stacey, 2001).

Num esquema aproximado para estimar o fator de pico de potência, este pode ser considerado como uma função das posições das barras de controle

$$FP = f_1(\text{posições das barras de controle}). \quad (2.5)$$

Durante as manobras de potência de uma planta nuclear, o núcleo do reator está num estado transiente, induzido pelos efeitos de transientes do xenônio, que é um dos produtos de fissão e um forte absorvedor de nêutrons térmicos. A variação da reatividade do núcleo causa alterações na concentração e na distribuição axial do xenônio, o qual oscila e pode levar o reator a um estado incontrolável, ou, ao desligamento. Logo, evitar estas oscilações é importante. Em reatores de potência, as maiores variações na

distribuição de potência na direção axial são causadas, exatamente, pelo envenenamento por xenônio (Sipush et al., 1976; Borges, 1988; Sakamoto et al., 1992; Na e Upadhyaya, 1998; Stacey, 2001). Como ele não pode ser medido, o efeito do envenenamento por xenônio na distribuição da densidade de potência tem que ser monitorado por meio de detectores *ex-core*. A queima do combustível também não pode ser medida e, conseqüentemente, deve ser considerada de maneira similar.

O efeito da realimentação termo-hidráulica na distribuição da densidade de potência é a redução do fator de pico de potência por causa do efeito Doppler no combustível. A distribuição de potência é deslocada para a parte inferior do núcleo, pois a temperatura do refrigerante é mais baixa nesta posição. Este efeito pode ser monitorado pelos detectores *ex-core* ou pode ser correlacionado com variáveis do estado do núcleo, tais como o nível de potência ou as temperaturas de entrada e saída do refrigerante. Mas, como os efeitos de realimentação termo-hidráulica são pequenos, parece mais apropriado monitorá-los por meio dos detectores *ex-core*, do que introduzir mais variáveis de entrada na correlação com redes neurais.

O boro solúvel, por sua vez, é uniformemente distribuído no refrigerante do reator e não afeta a distribuição da densidade de potência. Ele controla a reatividade do núcleo, compensando os efeitos causados pelo xenônio, pela queima e pela realimentação termo-hidráulica. Contudo, como sua concentração pode variar enquanto ele realiza estas funções de controle, ela não pode ser utilizada para correlacionar as perturbações na distribuição da densidade de potência causadas pelo xenônio ou pela queima.

A responsabilidade pela contabilidade dos efeitos causados pelo xenônio, pela queima e pela realimentação termo-hidráulica na distribuição da densidade de potência é dos detectores *ex-core*. Logo, incluir exemplos que cubram todos estes fenômenos no conjunto de dados de treinamento de uma rede neural é muito importante para o sucesso na obtenção do fator de pico de potência em reatores de potência.

Como as DPAs e DPQs dão informações sobre a distribuição da densidade de potência, é possível considerar, por aproximação, que o fator de pico de potência seja dado por

$$FP = f_2(DPAs, DPQs). \quad (2.6)$$

As posições das barras de controle e as DPAs e DPQs têm diferentes relações com o fator de pico de potência. As barras de controle afetam diretamente a forma da distribuição da densidade de potência, pois existe uma relação de causa-efeito, mas as DPAs e DPQs também são fatores observáveis da distribuição de densidade de potência. Como elas são variáveis independentes e são monitoradas simultaneamente pelo sistema de proteção do reator, FP pode ser considerado como uma função de todas elas, isto é:

$$FP = f_3(\text{posições das barras de controle, DPAs, DPQs}). \quad (2.7)$$

A determinação do FP depende de se encontrar as correlações f_1 , f_2 ou f_3 , e a precisão desta estimativa dependerá de quão exatamente estas correlações podem descrever estas relações.

2.3 Redes Neurais

As Redes Neurais Artificiais (RNAs) representam uma extensa área de pesquisa multidisciplinar. Localizadas dentro do contexto de inteligência artificial, as redes neurais são utilizadas como modelos matemáticos para problemas de classificação e reconhecimento de padrões, aproximação de funções, controle de processos, processamento de sinais, sendo aplicadas em praticamente todas as áreas do conhecimento.

Redes neurais são algoritmos inspirados no comportamento das células do cérebro humano (Tsoukalas e Uhrig, 1997; Haykin, 1999; Braga et al., 2000). Elas apresentam algumas características típicas do cérebro, tais como aprender de experiências anteriores, generalizar a partir dessas experiências para situações novas e extrair informações importantes contidas em dados que também possuam outras informações irrelevantes.

As redes neurais são sistemas paralelos distribuídos, compostos por unidades de processamento de informações simples, os neurônios, ligados por conexões ponderadas, chamadas de pesos, que armazenam conhecimentos e os tornam disponíveis para uso futuro (Wasserman, 1993; Reifman, 1997; Haykin, 1999; Baptista Filho, 2002).

No processo de aprendizagem, que é uma característica importante da metodologia de redes neurais, exemplos representativos do conhecimento são interativamente apresentados à rede, possibilitando a integração deste conhecimento dentro de sua estrutura (os pesos). Por meio deste treinamento, a rede neural é capaz de construir,

internamente, um mapeamento entre a entrada e a saída do problema em estudo. Ao submeter novos conjuntos de entradas à rede, ela é capaz de coletar as informações armazenadas nos pesos das ligações, de forma semelhante à “lembranças” e à análise do cérebro humano, e produzir uma saída coerente com o treinamento realizado.

Existem vários tipos de redes neurais apropriadas para diversos tipos de aplicações (Haykin, 1999). Neste trabalho consideram-se as redes perceptron de múltiplas camadas (MLP) e de função de base radial (RBF), exemplos de redes em camada alimentadas adiante e não lineares. Ambas são aproximadoras universais de funções, ou seja, são capazes de aproximar qualquer função integrável. O problema de se determinar uma correlação entre um conjunto de variáveis pode ser interpretado como o problema de se aproximar a função desconhecida que relaciona este conjunto de variáveis (Wasserman, 1993; Tsoukalas e Uhrig, 1997; Haykin, 1999; Braga et al., 2000). Assim, as redes neurais MLP e RBF podem ser consideradas técnicas apropriadas para o desenvolvimento de correlações e, portanto, para estimar o fator de pico em função das variáveis disponíveis no sistema de proteção de reatores, conforme as Eqs. 2.5, 2.6 e 2.7.

As redes MLP e RBF possuem vantagens e limitações (Haykin, 1999; Braga et al., 2000). As redes MLPs constróem aproximações globais de um mapeamento de entrada-saída não-linear, com maior capacidade de generalização para regiões onde não há dados de treinamento. Por outro lado, as redes RBF, utilizando não linearidades localizadas com decaimento exponencial, constróem aproximações locais para mapeamentos de entrada-saída não lineares, isto é, apenas as regiões do espaço de entrada que apresentam dados de treinamento terão resposta da rede.

As redes RBF possuem melhores resultados para problemas pré-definidos, nos quais as classes possuem um melhor agrupamento de padrões. Para problemas mais complexos, ou melhor, mais distribuídos, as redes MLP apresentam melhores resultados.

O treinamento de redes RBF é bem mais rápido que o de redes MLP mas, após o treinamento, elas são, geralmente, mais lentas na utilização, exigindo maior esforço computacional para o mesmo grau de precisão.

2.3.1 Perceptron de Múltiplas Camadas - MLP

O modelo de rede neural mais utilizado é o perceptron de múltiplas camadas, MLP (*multilayer perceptron*) sem realimentação e com treinamento supervisionado.

Uma rede de múltiplas camadas alimentadas adiante consiste de uma camada de entrada, uma camada de saída de neurônios computacionais e uma ou mais camadas ocultas de neurônios computacionais. O sinal de entrada se propaga para frente através da rede, camada por camada. O aprendizado pode ser realizado pelos métodos supervisionado e não supervisionado.

O algoritmo de aprendizado supervisionado mais conhecido para treinamento destas redes é o algoritmo de retropropagação (*back-propagation*), que minimiza uma função de custo quadrática por um método gradiente descendente. A maioria dos métodos de aprendizado para redes neurais do tipo MLP utiliza variações deste algoritmo.

Durante a fase de treinamento, os pesos são sucessivamente ajustados baseados no conjunto de entradas e o correspondente conjunto de saídas desejadas. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. A fase alimentada adiante (fase *forward*) é utilizada para definir a saída da rede para um dado padrão de entrada. Cada elemento coleta as saídas dos elementos anteriores, ponderadas pelos pesos das ligações, e processa a informação por meio de uma função sigmoideal, remetendo o resultado para os elementos da camada seguinte. A diferença entre a saída fornecida pela rede e a saída desejada representa um erro que é propagado para trás (fase *backward*) através da rede, a fim de ajustar os pesos. Este processo é repetido e o aprendizado continua até que a precisão desejada seja obtida.

A FIG. 2.1 é uma representação típica de uma rede com uma camada oculta, na qual x_i , $i = 1, \dots, M$, representa a entrada, ϕ_j , $j = 1, \dots, N$, representa a função não linear associada à cada neurônio, chamada função de ativação, e y é a saída. O sinal de somatório acima do neurônio de saída significa que seu resultado é a soma das contribuições de todos os neurônios da camada anterior. A rede neural da FIG. 2.1 tem M entradas, N neurônios na camada oculta e uma saída.

Considerando a rede representada na FIG. 2.1, pode-se apresentar de uma maneira simplificada a formulação matemática de redes neurais MLP. Uma descrição detalhada pode ser encontrada em Tsoukalas e Uhrig (1997), Haykin (1999) e Braga et al., (2000). De acordo com a FIG. 2.1, a entrada do j -ésimo neurônio na camada oculta é dado pela equação:

$$v_j = \sum_{i=0}^M w_{ji} x_i \quad (2.8)$$

onde M é o número total de entradas aplicadas ao neurônio j e w_{ji} denota o peso caracterizando a conexão entre a i -ésima entrada e o j -ésimo neurônio da camada oculta. A saída do neurônio j na camada oculta é

$$y_j = \varphi_j(v_j). \quad (2.9)$$

A função de ativação φ utilizada no presente estudo foi a função tangente hiperbólica $\varphi_j(v_j) = \tanh(v_j)$. Na camada de saída a função de ativação é linear e a saída da rede neural é dada por

$$y = \sum_{j=0}^N w_j y_j \quad (2.10)$$

onde w_j é o peso da conexão entre o j -ésimo neurônio da camada oculta e a saída.

O algoritmo de retropropagação aplica correções no peso utilizando a regra delta, que minimiza o erro quadrático médio, E , entre a resposta desejada t_i e a saída da rede neural y_i para K exemplos contidos no conjunto de treinamento. A correção Δw_{ji} aplicada a w_{ji} é definida pela regra delta:

$$\Delta w_{ji} = -\eta \left(\frac{\partial E}{\partial w_{ji}} \right) \quad (2.11)$$

onde η é a taxa de aprendizagem e o erro E é expresso por

$$E = \frac{1}{K} \sum_{i=1}^K (t_i - y_i)^2. \quad (2.12)$$

Este procedimento iterativo é repetido até que se consiga um erro quadrático médio aceitável. Este processo de apresentação dos exemplos à rede neural e correção dos pesos em cada etapa é chamado de treinamento da rede neural (Haykin, 1999; Braga et al., 2000).

2.3.2 Função de Base Radial - RBF

As redes RBF, como dito anteriormente, são aproximadoras universais de funções. Elas possuem uma topologia similar à rede MLP. Em sua forma básica ela possui três camadas: a entrada, a camada oculta e a camada de saída. A FIG. 2.1 também representa um diagrama da topologia de uma rede RBF. A camada oculta é constituída de

unidades de processamento não lineares, que estão conectadas, diretamente, a todos os nodos de entrada (Haykin, 1999; Braga et al., 2000).

A função de ativação aplicada a cada neurônio da camada oculta é uma função de base radial, que apresenta uma resposta localizada, e é radialmente simétrica em relação a um centro. As funções radiais possuem como comportamento fundamental o agrupamento de dados de entrada em conjuntos semelhantes (*clusters*). A função radial adotada neste trabalho foi a função gaussiana.

Cada neurônio da camada oculta calcula a gaussiana seguinte:

$$\varphi_j(x) = \exp\left(-\frac{1}{\sigma^2} \|\mathbf{x} - \boldsymbol{\mu}_j\|^2\right) \quad (2.13)$$

onde $\|\mathbf{x} - \boldsymbol{\mu}_j\|$ é a distância Euclidiana entre o vetor de entrada da rede \mathbf{x} e o centro $\boldsymbol{\mu}_j$ do j -ésimo *cluster*. O raio σ é a largura da função radial e representa a região no espaço do vetor de entrada com propriedades semelhantes que formam o *cluster*. Quando $\mathbf{x} = \boldsymbol{\mu}_j$, $\varphi_j(\mathbf{x})$ é igual a 1, gerando o valor máximo de saída do neurônio. Quando \mathbf{x} se afasta de $\boldsymbol{\mu}_j$ a resposta do neurônio $\varphi_j(\mathbf{x})$ decresce rapidamente, tornando-se desprezível para valores muito distantes uns dos outros. A saída do neurônio tem uma resposta significativa em uma região de valores de \mathbf{x} chamada de campo receptivo do neurônio, determinada pelo σ .

A entrada para cada neurônio na camada oculta é o vetor de entrada da rede neural. A saída do j -ésimo neurônio na camada oculta é dada por

$$y_j = \varphi_j(x). \quad (2.14)$$

A camada de saída consiste de uma unidade linear simples, totalmente conectada à camada oculta. A resposta gerada por um neurônio na camada de saída da rede é expressa como uma combinação linear das funções da camada oculta,

$$y = \sum_{j=0}^N w_j \varphi_j \quad (2.15)$$

onde o parâmetro w_j representa o peso da conexão j entre um neurônio da camada oculta e o neurônio de saída da rede.

Durante o processo de treinamento da rede neural RBF, σ , μ_j e w_j são ajustados para minimizar o erro médio entre a saída da rede e a saída desejada. O treinamento consiste de duas fases: na primeira, tem-se a seleção de centros μ_j e raio σ das funções radiais e na segunda, tem-se o procedimento de ajuste dos pesos w_j da camada de saída. Uma vez que os centros e o raio tenham sido escolhidos, a matriz dos pesos da camada de saída é otimizada pelo treinamento supervisionado. O algoritmo de gradiente descendente é frequentemente utilizado para este propósito (Haykin, 1999; Braga et al., 2000).




FIGURA 2.1 - Arquitetura típica de uma rede neural com uma camada oculta.

2.4 Determinação do Fator de Pico de Potência Utilizando Redes Neurais

O fator de pico da distribuição de potência deve ser estimado com base em correlações definidas por f_1 , f_2 ou f_3 nas Eqs. 2.5, 2.6 e 2.7. Em termos gerais, obter tal correlação, com base em resultados conhecidos, para vários estados do núcleo do reator, é o mesmo que encontrar uma superfície no espaço multidimensional (sinais dos detectores *ex-core* e posições das barras de controle) que proporcione o melhor ajuste dos resultados conhecidos do fator de pico. A técnica de rede neural soluciona este problema de ajuste

multidimensional de curva, no qual o processo de aprendizagem é equivalente a encontrar a melhor superfície ajustada no espaço multidimensional e o processo de generalização é o uso desta superfície para interpolar os dados (Reifman, 1997; Haykin, 1999).

A qualidade dos dados de treinamento é fundamental para que uma correlação de rede neural produza bons resultados. O treinamento da rede neural requer que os dados de entrada sejam representativos e não correlacionados entre si. As variáveis de entrada e de saída do conjunto de dados de treinamento devem ser o mais abrangente possível, cobrindo todos os cenários que possam aparecer, mais tarde, no processo de generalização (Kim e Chang, 1997; Guanghai et al., 2003; Lee e Chang, 2003; Na et al., 2004). É importante prever todas as distribuições de densidade de potência possíveis, que possam surgir durante a operação do reator, e classificá-las em classes de comportamento similar (Haykin, 1999; Reifman, 1997).

As variáveis de interesse neste trabalho, conforme as Eqs. 2.5, 2.6 e 2.7, são as posições das barras de controle, os sinais dos detectores *ex-core*, por meio da DPAs e DPQs, e o fator de pico da densidade de potência. É importante que sejam utilizados dados experimentais reais, obtidos de medidas, das posições das barras de controle e dos sinais dos detectores *ex-core*, como variáveis de entrada. A informação sobre as posições das barras de controle é medida diretamente. Evitou-se utilizar dados simulados dos sinais dos detectores *ex-core* porque suas respostas às variações na distribuição da densidade de potência são difíceis de modelar, pois elas requerem a solução da equação de transporte de nêutrons da região do núcleo até a posição do detector, através da blindagem térmica e das paredes do vazão de pressão (Crump e Lee, 1978).

É importante treinar as redes neurais com dados que tenham valores precisos da distribuição da densidade de potência, a fim de reduzir as margens de segurança (Seon et al., 2002). Como os códigos de projeto de núcleos podem proporcionar valores da distribuição da densidade de potência com incerteza menor do que 2 %, foi decidido utilizar os fatores de pico calculados como saída dos dados de treinamento das redes neurais.

Para assegurar que o fator de pico de potência calculado se refere aos sinais dos detectores *ex-core*, cada estado do reator deve ser cuidadosamente identificado, durante as medidas, para posteriormente se calcular o fator de pico com precisão.

3 EXPERIMENTOS E DADOS OBTIDOS

Os experimentos foram realizados no reator de potência zero IPEN/MB-01 e idealizados para proporcionar dados reais, a fim de inferir o fator de pico da densidade de potência a partir das posições das barras de controle e dos resultados das DPA^N , DPA^W , DPQ_T e DPQ_B obtidos dos sinais dos detectores *ex-core*. Basicamente, os experimentos visaram obter dados para se construir as correlações sugeridas nas Eqs. 2.5, 2.6 e 2.7. As medidas foram feitas com distribuições de densidade de potência bem pronunciadas para demonstrar a viabilidade de aplicação desta técnica no reator do LABGENE.

A movimentação das barras de segurança na Unidade Crítica IPEN/MB-01 é impedida por um intertravamento que atua durante a operação da instalação. No caso deste experimento, que requer a movimentação das barras de segurança e de controle, foram tomadas precauções para se inibir este intertravamento. Os passos necessários para se fazer a inibição e a análise de segurança sobre estas atividades encontram-se na rotina experimental apresentada no APÊNDICE A. Esta rotina foi submetida ao Comitê de Revisão de Segurança do Instituto de Pesquisas Energéticas e Nucleares, IPEN, e foi aprovada para a execução.

No reator IPEN/MB-01, de potência zero, somente a movimentação de barras de controle pode perturbar a distribuição da densidade de potência, conseqüentemente as DPAs e DPQs, pois não há envenenamento por xenônio, queima e efeitos de realimentação termo-hidráulica. Contudo, pode-se considerar que as grandes variações realizadas no posicionamento das barras de controle causaram perturbações nas distribuições axiais de potência similares às que seriam causadas pelo envenenamento por xenônio.

Detectores de nêutrons foram posicionados fora do tanque de aço inoxidável do reator, de tal modo que o conjunto experimental ficasse semelhante à configuração de posicionamento dos detectores *ex-core* encontrada em reatores de potência. Vários estados críticos do reator, com diferentes distribuições da densidade de potência, foram obtidos posicionando as barras de controle em diferentes configurações. Os fatores de pico de potência foram determinados das distribuições da densidade de potência obtidas de cálculos tridimensionais do núcleo. O conjunto de dados obtidos contém, para vários

estados do núcleo, as posições das quatro barras de controle, os sinais dos quatro detectores *ex-core*, as DPAs e DPQs, e o fator de pico de potência.

3.1 Reator IPEN/MB-01

O reator IPEN/MB-01 é um reator de potência zero no qual a reação em cadeia é auto-sustentada e controlada a baixos níveis de potência, de forma que, em operação normal, as perturbações de reatividade provenientes dos efeitos de realimentação de temperatura não são significativas. Este reator se destina à simulação neutrônica de reatores moderados a água leve, possibilitando a verificação experimental de métodos de cálculo, estruturas de células e malhas do reator, efetividade de barras de controle e resposta do núcleo à inserção de reatividade (Maiorino et al., 1989; IPEN, 1988).

O núcleo deste reator é constituído de varetas de combustível revestidas de aço inoxidável, com pastilhas de UO_2 enriquecidas a 4,3 %. As varetas de combustível são colocadas individualmente no núcleo, conforme a configuração geométrica desejada, e elas são posicionadas por meio de placas espaçadoras formando um conjunto semelhante a elementos combustíveis de PWR.

Este arranjo está localizado dentro de um tanque de aço inoxidável aberto, contendo água leve que serve como moderador e refletor. A potência nominal máxima é 100 W, correspondendo a um fluxo de nêutrons térmicos da ordem de 10^9 n/cm²s.

O nível de potência do núcleo é ajustado por meio da inserção ou retirada das barras de controle da região ativa do núcleo. As barras de segurança têm a função de garantir o desligamento do reator quando necessário. Em caso de emergência as barras de controle também são inseridas e são suficientes para desligar o reator. As barras de controle e de segurança possuem características geométricas idênticas, diferindo somente quanto ao material absorvedor no interior das varetas, sendo utilizada a liga de Ag-In-Cd para as barras de controle e B_4C para as barras de segurança. Cada uma das quatro barras de controle e de segurança é formada de 12 varetas absorvedoras conectadas entre si de maneira similar a um PWR. Cada barra de controle/segurança, doravante denominada simplesmente barra de controle, pode ser movida de forma independente. O núcleo é geometricamente dividido em quatro quadrantes, com as barras de controle e de segurança colocadas, respectivamente, em quadrantes diagonalmente opostos. Na TAB. 3.1 apresentam-se algumas informações técnicas sobre o reator IPEN/MB-01.

Uma vista de cima do núcleo do reator é mostrada na FIG. 3.1, onde os pequenos quadrados representam os elementos combustíveis no arranjo; as letras “A” e “B” representam as barras de controle BC1 e BC2; e as letras “R” e “S” as barras de segurança BS1 e BS2, respectivamente.

Na FIG. 3.2 tem-se, esquematicamente, uma vista de cima do núcleo do reator e do tanque moderador. O grande círculo representa o tanque de aço inoxidável. Os pequenos círculos próximos ao núcleo representam os vários detectores de nêutrons disponíveis para a instrumentação de controle do reator e para experimentos. Os dois círculos fora do tanque de aço inoxidável representam os canais dos detectores *ex-core*, localizados nos lados norte e oeste do reator. Cada canal é composto por dois detectores, um na parte superior e outro na parte inferior do núcleo.

TABELA 3.1 - Dados gerais do reator de potência zero IPEN/MB-01 (IPEN, 1988)

Parâmetro	Valor
Combustível	
Diâmetro da pastilha de (UO ₂)	0,849 cm
Enriquecimento em peso	4,3 %
Densidade	94 % da densidade teórica
Comprimento da vareta	119,4 cm
Comprimento ativo	54,6 cm
Diâmetro externo do encamisamento	0,98 cm
Diâmetro interno do encamisamento	0,86 cm
Arranjo	
Altura do núcleo ativo	54,6 cm
Espaçamento entre as varetas, centro a centro	1,5 cm
Varetas de Controle	
Revestimento	Aço inoxidável (AISI 304)
Comprimento ativo	100 cm
Diâmetro externo	0,98 cm
Diâmetro interno	0,86 cm
Material absorvedor da barra de controle	Ag (80%)-In (15%)-Cd (5%)
Diâmetro da barra de controle	0,832 cm
Material absorvedor da barra de segurança	B ₄ C – 52 % da densidade teórica
Diâmetro da barra de segurança	0,86 cm
Tanque	
Material	Aço inoxidável
Diâmetro interno	184
Espessura da parede	0,5 cm
Instrumentação	
Diâmetro interno do tubo de alumínio	9,5 cm
Espessura da parede do tubo	0,25 cm
Distância entre a linha central do tubo da instrumentação e o núcleo	18,5 cm

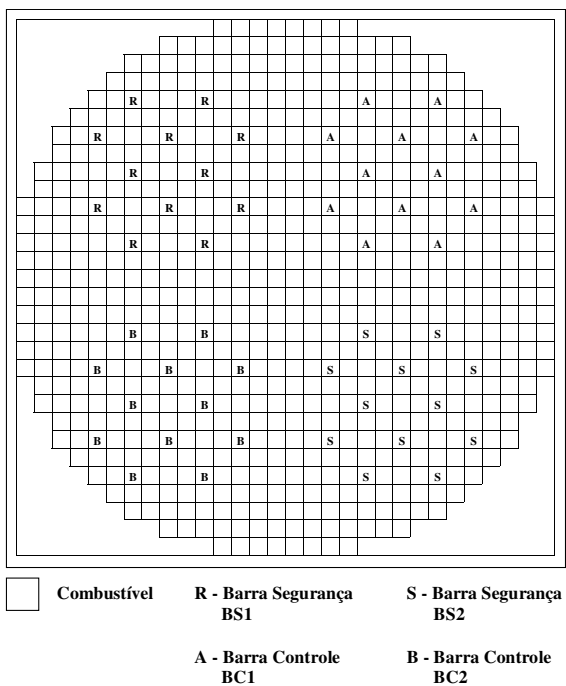


FIGURA 3.1 - Vista do reator de potência zero IPEN/MB-01.




FIGURA 3.2 - Vista do reator de potência zero IPEN/MB-01 representando o núcleo, o tanque moderador, a instrumentação do reator e os detectores *ex-core*.

3.2 Intercalibração dos Detectores *Ex-core*

Os estados do núcleo, com diferentes distribuições de potência, foram obtidos estabelecendo configurações críticas com diferentes posições de barras de controle dentro do núcleo. Para obter um maior número de estados diferentes foi necessário aumentar o excesso de reatividade do núcleo. Assim, foi montada a configuração cilíndrica do reator, conforme pode ser visto na FIG. 3.1, com o máximo de varetas de combustível no núcleo (680 varetas), havendo um ganho de, aproximadamente, 700 pcm em reatividade

O fluxo de nêutrons fora do tanque é da ordem de 10^3 n/cm²s, quando o reator está operando em sua potência máxima, 100 W. Em razão deste baixo fluxo foi necessário utilizar detectores de nêutrons com alta eficiência. Assim, os experimentos foram realizados utilizando quatro detectores de ¹⁰B, nos canais *ex-core*, pertencentes ao acervo instrumental da instalação. Os detectores foram revestidos por uma camada de 0,114 cm de espessura de cádmio, deixando-os com 18 cm de comprimento ativo para monitorar nêutrons térmicos. Tomou-se este cuidado para que a condição experimental se parecesse mais com a instrumentação *ex-core* de PWRs. Na TAB. 3.2 são apresentados dados técnicos sobre os detectores *ex-core*.

A linearidade das respostas dos detectores foi verificada colocando-os fora do tanque de aço inoxidável, na parte inferior do lado norte, e registrando suas contagens em níveis de potência variando entre 1 e 100 W. Os pulsos dos detectores foram processados por sistemas de contagem ORTEC, formados por pré-amplificador, amplificador, analisador monocanal e contador.

A intercalibração dos detectores de ¹⁰B foi realizada posicionando-os, dois a dois, no lado oeste do reator, coincidindo o meio dos seus comprimentos ativos com a meia altura do núcleo. O reator foi colocado crítico a 5 W e 10 W, com todas as barras de controle e de segurança com 67,10 % de seus comprimentos retiradas do reator. Para cada detector foram registradas cinco medidas acumuladas, cada uma, em um tempo de 300 segundos. Concomitantemente, foram registradas as correntes dos detectores colocados sob o tanque e pertencentes à instrumentação do reator, através de medidores denominados Canal 0 e Canal 1. Os valores médios das contagens e das correntes destes detectores foram utilizados no cálculo dos fatores de intercalibração das respostas dos detectores *ex-core*. Estes fatores são mostrados na TAB. 3.2 (Moreira e Souza, 2001).

TABELA 3.2 - Dados técnicos dos detectores de nêutrons de ^{10}B utilizados para simular os detectores *ex-core* e fatores de intercalibração

Parâmetro	Valor
Detectores de ^{10}B (CPNB-35) no Lado Norte	
Diâmetro externo	2,62 cm
Comprimento total	39,64 cm
Comprimento ativo	29,5 cm
Detectores de ^{10}B (RS-P7-0812-117) no Lado Oeste	
Diâmetro externo	7,66 cm
Comprimento total	44,36 cm
Comprimento ativo	28,5 cm
Revestimento de Cádmiio	
Comprimento ativo	18 cm
Espessura	0,114 cm
Fatores de Intercalibração - FI	
Detector inferior colocado no lado norte	$324,4 \pm 0,5$
Detector superior colocado no lado norte	$246,3 \pm 0,4$
Detector inferior colocado no lado oeste	$154,5 \pm 0,3$
Detector superior colocado no lado oeste	$145,6 \pm 0,3$
Fatores de Correção para as Contagens dos Detectores do Lado Norte para Compensar os Volumes Vazios da Instrumentação do Reator	
Detector inferior	0,975
Detector superior	0,733

3.3 Medidas das Contagens dos Detectores *Ex-core* e das Posições das Barras de Controle

Os 4 detectores *ex-core* foram colocados em posições simétricas, fora do tanque de aço inoxidável, nos lados norte e oeste. Seus centros foram localizados a 18 cm acima e abaixo da linha central do núcleo, conforme é ilustrado na FIG. 3.3.

Para estados simétricos do reator, as contagens dos detectores colocados no lado norte devem ser iguais às dos detectores colocados no lado oeste. Todavia, observa-se na FIG. 3.2 que, no lado norte do reator há quatro tubos de instrumentação, entre o núcleo e os detectores *ex-core* que, por causa dos volumes vazios introduzidos na região,

aumentam as respostas dos detectores aí posicionados. Para compensar este efeito, as contagens de cada detector colocado no lado norte foi multiplicada por um fator constante, a fim de reproduzir as contagens dos detectores colocados no lado oeste. Estes fatores de correção foram obtidos de medidas no estado em que todas as barras de controle estavam posicionadas à mesma altura, 67,1 % retiradas, com o reator operando a 10 W. Na TAB. 3.2 são mostrados estes fatores de correção.

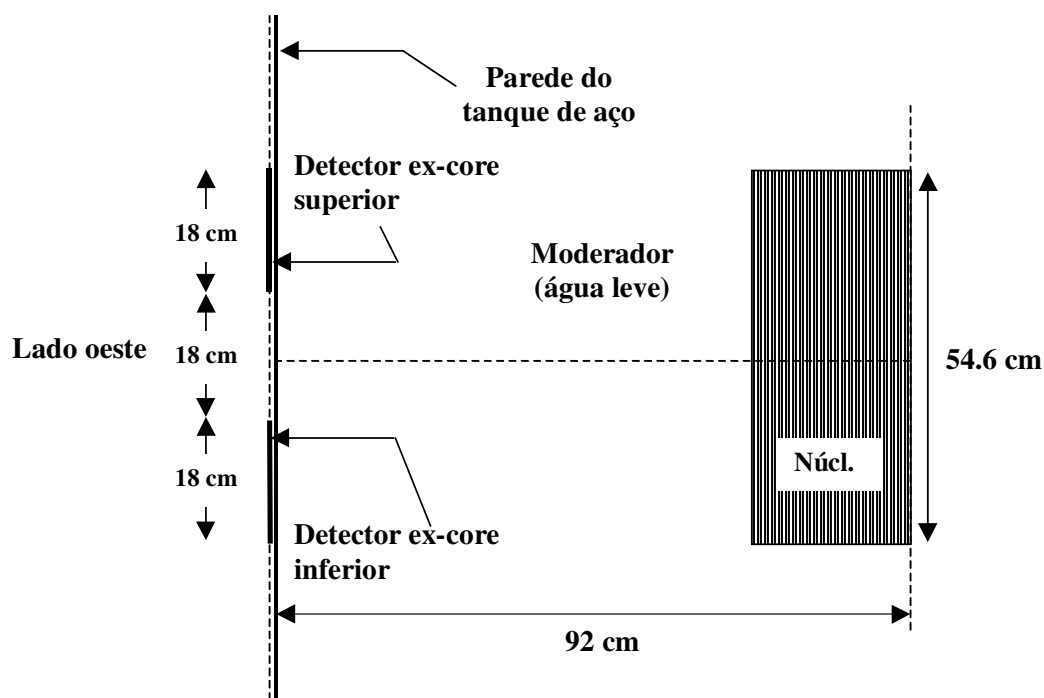


FIGURA 3.3 - Vista lateral do reator IPEN/MB-01, tanque e detectores.

O primeiro estado do núcleo do reator foi obtido com as quatro barras de controle colocadas à mesma altura, ou seja, 67,1 % de seus comprimentos retiradas, a um nível de potência de 10 W. Foram registradas cinco medidas em cada um dos quatro detectores, acumuladas em 300 segundos cada, e as suas contagens médias foram usadas como medidas de referência. Medidas similares foram repetidas com as barras de controle em diferentes configurações, a fim de se estabelecer diferentes distribuições de densidade de potência no núcleo do reator.

Os movimentos das barras de controle pretendem emular aqueles que ocorrem em PWRs durante operações normais e anormais. Há movimentos de barras de

controle que produzem perturbações simétricas na distribuição da densidade de potência, ao passo que outros produzem perturbações assimétricas. A extensão dos movimentos das barras foi tal que cobria todos os estados possíveis do reator.

Os movimentos das barras de controle foram feitos de modo que a reatividade introduzida no núcleo pela retirada de uma ou mais barras fosse compensada pela inserção das outras barras de controle, para manter a criticalidade. No início, todas as barras estavam 67,1 % retiradas. A seguir, uma ou duas barras de controle foram retiradas para as posições 77,1 %, 87,1 % e 100 %. Em cada caso, foi seguido o procedimento descrito na rotina experimental (APÊNDICE A) para manter a criticalidade e, resumidamente, mostrado a seguir:

- inserção de uma barra de controle em diagonal;
- inserção de uma barra de controle em paralelo;
- inserção de duas barras de controle juntas.

Este procedimento foi adotado para cobrir o maior número de estados possíveis com diferentes distribuição de densidade de potência. Conseguiu-se, com este procedimento, 10 classes diferentes de movimentação das barras de controle. Na TAB. 3.3 são mostradas as classes de movimentação das barras de controle que foram escolhidas. Os estados, dentro das classes, foram tais que encerravam a movimentação máxima da barra de controle. Consequentemente, qualquer outro estado com aquele padrão de movimentação de barra de controle poderá ter o resultado de seu FP interpolado dos dados da classe. Ao todo, 56 estados críticos diferentes foram estabelecidos com diferentes configurações de barras de controle.

Na TAB. 3.4 são apresentadas as posições das barras de controle e as contagens normalizadas dos detectores *ex-core* para os 56 estados (Moreira e Souza, 2001). O erro experimental considerando a posição da barra de controle é muito pequeno. O indicador da posição da barra de controle tem um erro de $\pm 0,01$ %, ou 0,0054 cm. Os desvios padrão das contagens normalizadas também são muito pequenos, com um valor máximo de $\pm 4,7 \times 10^{-3}$. Estes erros foram calculados utilizando-se a técnica de propagação de erros, conforme mostrado no APÊNDICE B.

TABELA 3.3 - Classes de movimentação das barras de controle na construção dos 56 estados experimentais com diferentes distribuições de densidade de potência

Classe	Estado	Movimento das Barras de Controle
1	1 e 2 a 7	Barras BC1 e BC2 mantidas numa posição fixa. Inserção e retirada das outras barras de controle em diagonal (se compensando).
2	1 e 8 a 13	Barras BS1 and BS2 mantidas numa posição fixa. Inserção e retirada das outras barras de controle em diagonal (se compensando).
3	1 e 14 a 19	Barras BS1 and BC1 mantidas numa posição fixa. Inserção e retirada das outras barras em paralelo (se compensando).
4	1 e 20 a 25	Barras BS2 and BC1 mantidas numa posição fixa. Inserção e retirada das outras barras em paralelo (se compensando).
5	1 e 26 a 31	Barras BS2 and BC2 mantidas numa posição fixa. Inserção e retirada das outras barras em paralelo (se compensando).
6	1 e 32 a 37	Barras BS1 and BC2 mantidas numa posição fixa. Inserção e retirada das outras barras em paralelo (se compensando).
7	1 e 38 a 43	Barras BS1 and BC1 movendo juntas. As outras barras compensando juntas.
8	1 e 44 a 49	Barras BS2 and BC1 movendo juntas. As outras barras compensando juntas.
9	1 e 50 a 55	Barras BS1 and BS2 movendo juntas. As outras barras compensando juntas.
10	56	Barra BS2 movendo. Compensando com BS1, BC1, BC2.

TABELA 3.4 - Posições das barras de controle e contagens normalizadas dos detectores *ex-core*

Estado	BS1* (%)	BS2* (%)	BC1* (%)	BC2* (%)	C _B ^N (10 ⁻³)	C _T ^N (10 ⁻³)	C _B ^W (10 ⁻³)	C _T ^W (10 ⁻³)
1	67,10	67,10	67,10	67,10	986,8 ± 1,8	698,6 ± 1,4	987,1 ± 2,4	699,2 ± 1,9
2	59,82	77,10	67,10	67,10	943,3 ± 2,3	683,0 ± 1,9	970,6 ± 3,3	683,4 ± 2,7
3	55,86	87,10	67,10	67,10	938,9 ± 2,3	677,7 ± 1,9	964,2 ± 3,3	681,7 ± 2,7
4	53,66	100,00	67,10	67,10	937,7 ± 2,5	671,7 ± 2,0	957,7 ± 3,6	667,4 ± 2,9
5	77,10	59,81	67,10	67,10	993,2 ± 2,5	730,0 ± 2,0	1021,9 ± 3,6	724,8 ± 2,9
6	87,10	55,92	67,10	67,10	1023,2 ± 2,5	764,7 ± 2,1	1044,4 ± 3,6	752,9 ± 3,0
7	100,00	53,71	67,10	67,10	1040,5 ± 2,4	785,8 ± 2,0	1064,5 ± 3,5	779,9 ± 2,9
8	67,10	67,10	77,10	60,00	993,2 ± 2,4	725,9 ± 2,0	981,8 ± 3,4	672,7 ± 2,7
9	67,10	67,10	87,10	56,30	1007,0 ± 2,3	751,6 ± 1,9	970,4 ± 3,2	669,2 ± 2,5
10	67,10	67,10	100,00	54,33	1031,6 ± 2,5	777,6 ± 2,1	962,1 ± 3,4	670,8 ± 2,7
11	67,10	67,10	59,81	77,10	952,9 ± 2,5	670,7 ± 2,0	1021,9 ± 3,7	724,6 ± 3,1
12	67,10	67,10	55,97	87,10	971,2 ± 2,6	660,4 ± 2,0	1035,3 ± 3,9	752,3 ± 3,2
13	67,10	67,10	53,88	100,00	965,9 ± 2,7	662,2 ± 2,1	1053,0 ± 4,0	772,7 ± 3,4
14	67,10	77,10	67,10	59,13	992,1 ± 2,5	685,4 ± 1,9	970,7 ± 3,4	669,6 ± 2,8
15	67,10	87,10	67,10	55,08	995,4 ± 2,5	693,2 ± 2,0	957,4 ± 3,4	665,4 ± 2,8
16	67,10	100,00	67,10	52,85	988,5 ± 2,5	703,8 ± 2,0	953,8 ± 3,5	670,5 ± 2,8
17	67,10	61,01	67,10	77,10	986,3 ± 2,5	681,1 ± 2,0	1013,3 ± 3,6	720,6 ± 3,0
18	67,10	57,87	67,10	87,10	967,2 ± 2,6	687,9 ± 2,1	1028,7 ± 3,8	747,7 ± 3,2
19	67,10	56,18	67,10	100,00	980,5 ± 2,6	695,9 ± 2,1	1046,7 ± 3,9	766,0 ± 3,3
20	61,00	67,10	67,10	77,10	953,9 ± 2,5	660,1 ± 2,0	992,4 ± 3,6	701,2 ± 3,0
21	57,87	67,10	67,10	87,10	951,0 ± 2,6	660,4 ± 2,0	998,8 ± 3,8	715,6 ± 3,1
22	56,17	67,10	67,10	100,00	951,2 ± 2,6	659,3 ± 2,1	1007,7 ± 3,9	730,6 ± 3,2
23	77,10	67,10	67,10	59,18	1005,4 ± 2,5	712,4 ± 2,0	990,4 ± 3,4	697,9 ± 2,8
24	87,10	67,10	67,10	55,01	1048,2 ± 2,5	770,5 ± 2,1	998,0 ± 3,4	721,8 ± 2,8
25	100,00	67,10	67,10	52,79	1079,7 ± 2,6	795,2 ± 2,1	1003,8 ± 3,5	740,2 ± 2,9
26	77,10	67,10	58,96	67,10	1005,5 ± 2,5	715,3 ± 2,0	1014,4 ± 3,6	729,0 ± 3,0
27	87,10	67,10	54,91	67,10	1010,6 ± 2,5	730,7 ± 2,1	1036,8 ± 3,7	760,7 ± 3,1
28	100,00	67,10	52,61	67,10	1015,8 ± 2,6	751,3 ± 2,1	1051,8 ± 3,7	787,7 ± 3,2
29	61,02	67,10	77,10	67,10	999,5 ± 2,5	710,9 ± 2,0	969,4 ± 3,5	680,4 ± 2,8

TABELA 3.4 - Posições das barras de controle e contagens normalizadas dos detectores *ex-core* (continuação)

Estado	BS1* (%)	BS2* (%)	BC1* (%)	BC2* (%)	C _B ^N (10 ⁻³)	C _T ^N (10 ⁻³)	C _B ^W (10 ⁻³)	C _T ^W (10 ⁻³)
30	57,94	67,10	87,10	67,10	1000,8 ± 2,7	730,3 ± 2,0	960,4 ± 3,4	678,3 ± 2,8
31	56,33	67,10	100,00	67,10	1015,3 ± 2,5	743,7 ± 2,1	955,1 ± 3,4	673,3 ± 2,8
32	67,10	61,05	77,10	67,10	1019,9 ± 2,5	727,7 ± 2,0	992,9 ± 3,5	701,7 ± 2,8
33	67,10	57,99	87,10	67,10	1043,9 ± 2,5	758,9 ± 2,1	992,4 ± 3,5	711,2 ± 2,9
34	67,10	56,30	100,00	67,10	1055,6 ± 2,6	783,1 ± 2,1	995,8 ± 3,5	715,4 ± 2,9
35	67,10	77,10	58,97	67,10	976,5 ± 2,5	679,0 ± 2,0	994,5 ± 3,6	700,5 ± 2,9
36	67,10	87,10	54,92	67,10	964,9 ± 2,5	673,0 ± 2,0	1001,4 ± 3,7	714,9 ± 3,0
37	67,10	100,00	52,68	67,10	962,2 ± 2,5	675,3 ± 2,0	1001,6 ± 3,7	716,0 ± 3,1
38	77,10	59,86	77,10	59,86	982,6 ± 2,4	711,2 ± 2,0	981,8 ± 3,4	703,5 ± 2,8
39	87,10	55,80	87,10	55,80	1019,7 ± 2,5	774,3 ± 2,1	996,8 ± 3,4	727,5 ± 2,8
40	100,00	53,30	100,00	53,30	1058,0 ± 2,5	832,9 ± 2,2	1008,7 ± 3,5	755,1 ± 2,9
41	59,75	77,10	59,75	77,10	882,3 ± 2,4	613,6 ± 1,9	975,9 ± 3,6	700,7 ± 3,0
42	55,62	87,10	55,62	87,10	863,9 ± 2,5	603,6 ± 2,0	992,5 ± 3,9	721,8 ± 3,3
43	53,05	100,00	53,05	100,00	862,3 ± 2,6	605,7 ± 2,1	1008,7 ± 4,1	748,9 ± 3,5
44	59,85	77,10	77,10	59,85	925,1 ± 2,3	658,4 ± 1,9	934,3 ± 3,4	649,9 ± 2,7
45	55,75	87,10	87,10	55,75	934,4 ± 2,4	682,6 ± 2,0	915,3 ± 3,4	637,0 ± 2,7
46	53,23	100,00	100,00	53,23	1026,4 ± 2,6	772,7 ± 2,2	919,9 ± 3,4	642,2 ± 2,8
47	77,10	59,77	59,77	77,10	1005,2 ± 2,8	710,2 ± 2,3	1042,8 ± 4,1	757,0 ± 3,5
48	87,10	55,63	55,63	87,10	1020,3 ± 3,0	742,4 ± 2,4	1092,3 ± 4,4	819,8 ± 3,8
49	100,00	53,05	53,05	100,00	1041,0 ± 3,1	777,0 ± 2,6	1138,9 ± 4,7	880,7 ± 4,1
50	61,22	61,22	77,10	77,10	997,2 ± 2,8	706,8 ± 2,3	989,1 ± 4,0	699,3 ± 3,3
51	58,27	58,27	87,10	87,10	1016,1 ± 2,9	731,1 ± 2,4	1000,8 ± 4,1	721,8 ± 3,5
52	56,66	56,66	100,00	100,00	1023,2 ± 3,0	756,9 ± 2,5	1014,1 ± 4,3	742,0 ± 3,6
53	77,10	77,10	59,35	59,35	1000,4 ± 2,7	707,4 ± 2,2	991,5 ± 3,9	698,1 ± 3,2
54	87,10	87,10	55,50	55,50	1017,9 ± 2,8	741,7 ± 2,3	1003,2 ± 4,0	729,8 ± 3,3
55	100,00	100,00	53,28	53,28	1025,4 ± 2,9	765,1 ± 2,4	1020,9 ± 4,1	755,6 ± 3,5
56	64,30	77,10	64,30	64,30	980,6 ± 2,7	682,4 ± 2,2	963,4 ± 3,8	672,8 ± 3,1

* O erro na posição da barra de controle é ± 0,01 % (± 0,0054 cm).

3.4 Dados de Diferenças de Potência Axial e por Quadrante

As diferenças de potência axial, DPA^N e DPA^W foram calculadas pela Eq. 2.3 e as diferenças de potência por quadrante, DPQ_T e DPQ_B , pela Eq. 2.4 considerando, em cada caso, as contagens dos respectivos detectores envolvidos na formulação e apresentadas na TAB. 3.4.

As incertezas das grandezas DPAs e DPQ_S foram determinadas pela técnica de propagação de erros, descrita no APÊNDICE B. As diferenças de potência axial, as diferenças de potência por quadrante e suas incertezas são mostradas na TAB. 3.5.

Os valores das DPAs variam entre 11,90 % e 19,05 %, com um erro máximo de $\pm 0,32$ % para o estado 52 em DPA^W . Comparando este erro máximo com a faixa de variação das DPAs (19,05 % - 11,90 % = 7,15 %) observa-se que o erro é pequeno, mostrando que os dados são precisos e bem definidos no domínio.

A faixa de variação das DPQs é entre -10,57 % e 9,23 % com um erro máximo de $\pm 0,30$ %, que também é pequeno (em DPQ_T para o estado 52). Similarmente, o erro máximo é muito menor do que a variação das DPQs, mostrando que os dados têm boa qualidade.

As DPQs têm muitos valores próximos de zero porque vários estados são simétricos em relação ao eixo diagonal que passa pelas barras de segurança BS1 e BS2. Conforme mostrado na TAB. 3.4, para os estados pertencentes à classe 1, no qual as barras BS1 e BS2 se movem em direções opostas e as outras são mantidas fixas, as contagens normalizadas C_T^N e C_T^W têm valores bem próximos, resultando em valores de DPQ_T pequenos e próximos de zero. O mesmo ocorre com os valores de DPQ_T e DPQ_B na classe 9. Nesta classe, as barras BS1 e BS2 movem juntas e são compensadas com BC1 e BC2 e as contagens C_T^N e C_T^W , e, também, C_B^N e C_B^W têm valores aproximadamente iguais. Entretanto, estes valores de DPQs, indicados na TAB. 3.5, são próximos, mas não iguais a zero. Isto ocorre em razão do erro associado aos fatores de normalização que foram introduzidos para compensar a presença dos tubos de instrumentação no lado norte do núcleo. (Como mencionado anteriormente, eles foram obtidos do estado número 1). Os valores similares destas DPQs e seus respectivos erros não significam dados pobres, uma vez que os valores são próximos de zero.

3.5 Dados do Fator de Pico de Potência

A distribuição da densidade de potência dentro do núcleo pode ser medida por meio da ativação de folhas, ou fios, ou utilizando câmaras de fissão miniaturas. Este procedimento envolveria mapear todos os canais do reator, o que seria muito laborioso, além de ser difícil estimar os respectivos fatores de pico de potência com boa precisão. Por este motivo, foi decidido que os fatores de pico de potência seriam calculados.

A distribuição da densidade de potência e k_{eff} , para cada um dos 56 estados do reator, foram obtidos utilizando o código CITATION (Fowler et al., 1971), que resolve a equação de difusão de nêutrons em multigrupos de energia pelo método de diferenças finitas, pino a pino, no espaço tridimensional. O modelo tridimensional do núcleo representa as posições das barras de controle com detalhe e produz distribuições da densidade de potência com incerteza menor do que 2 % na área central do núcleo. Foram usados 4 grupos de energia e o critério de convergência para a distribuição da densidade de potência no cálculo de difusão foi 10^{-4} . As seções de choque utilizadas no cálculo foram geradas por uma versão modificada do código de célula unitária HAMMER/TECHNION (Barhen et al., 1978).

As densidades de potência local máxima ou os fatores de pico de potência, FP, para os 56 estados, foram obtidos das distribuições da densidade de potência produzidas pelo código CITATION. Os resultados dos fatores de pico de potência também são mostrados na TAB. 3.5.

Nas FIG. 3.4 a 3.9 estão representadas as distribuições da densidade de potência normalizada radial, no plano X-Y, e axial, no plano Z-Y, nos quais ocorrem os fatores de pico de potência, para os estados 1, 40 e 43, como exemplos.

TABELA 3.5 - Posições das barras de controle, diferenças de potência axiais, diferenças de potência por quadrante e fatores de pico para os 56 estados críticos

Estado	BS1 (%)	BS2 (%)	BC1 (%)	BC2 (%)	DPA ^N (%)	DPA ^W (%)	DPQ _B (%)	DPQ _T (%)	FP*
1	67,10	67,10	67,10	67,10	17,10 ± 0,13	17,07 ± 0,18	-0,01 ± 0,15	-0,05 ± 0,16	2,247
2	59,82	77,10	67,10	67,10	16,01 ± 0,18	17,37 ± 0,25	-1,43 ± 0,21	-0,03 ± 0,24	2,261
3	55,86	87,10	67,10	67,10	16,16 ± 0,18	17,17 ± 0,25	-1,33 ± 0,21	-0,29 ± 0,24	2,258
4	53,66	100,00	67,10	67,10	16,53 ± 0,20	17,86 ± 0,28	-1,06 ± 0,23	0,31 ± 0,27	2,228
5	77,10	59,81	67,10	67,10	15,28 ± 0,18	17,01 ± 0,26	-1,42 ± 0,21	0,35 ± 0,25	2,261
6	87,10	55,92	67,10	67,10	14,46 ± 0,18	16,22 ± 0,26	-1,03 ± 0,21	0,77 ± 0,24	2,258
7	100,00	53,71	67,10	67,10	13,94 ± 0,17	15,43 ± 0,24	-1,14 ± 0,20	0,38 ± 0,22	2,228
8	67,10	67,10	77,10	60,00	15,55 ± 0,18	18,68 ± 0,26	0,58 ± 0,21	3,80 ± 0,25	2,259
9	67,10	67,10	87,10	56,30	14,53 ± 0,17	18,37 ± 0,24	1,85 ± 0,20	5,79 ± 0,23	2,249
10	67,10	67,10	100,00	54,33	14,04 ± 0,18	17,84 ± 0,26	3,49 ± 0,21	7,37 ± 0,24	2,237
11	67,10	67,10	59,81	77,10	17,38 ± 0,19	17,02 ± 0,27	-3,49 ± 0,22	-3,86 ± 0,26	2,259
12	67,10	67,10	55,97	87,10	19,05 ± 0,20	15,83 ± 0,28	-3,20 ± 0,23	-6,51 ± 0,26	2,249
13	67,10	67,10	53,88	100,00	18,65 ± 0,20	15,35 ± 0,28	-4,31 ± 0,23	-7,70 ± 0,27	2,237
14	67,10	77,10	67,10	59,13	18,28 ± 0,18	18,36 ± 0,26	1,09 ± 0,22	1,17 ± 0,25	2,243
15	67,10	87,10	67,10	55,08	17,90 ± 0,18	18,00 ± 0,27	1,95 ± 0,22	2,05 ± 0,25	2,228
16	67,10	100,00	67,10	52,85	16,82 ± 0,19	17,45 ± 0,27	1,79 ± 0,22	2,43 ± 0,25	2,202
17	67,10	61,01	67,10	77,10	18,30 ± 0,19	16,88 ± 0,27	-1,35 ± 0,22	-2,82 ± 0,25	2,247
18	67,10	57,87	67,10	87,10	16,88 ± 0,19	15,82 ± 0,27	-3,08 ± 0,23	-4,17 ± 0,26	2,243
19	67,10	56,18	67,10	100,00	16,98 ± 0,20	15,49 ± 0,28	-3,26 ± 0,23	-4,80 ± 0,26	2,221
20	61,00	67,10	67,10	77,10	18,21 ± 0,19	17,19 ± 0,27	-1,98 ± 0,22	-3,02 ± 0,26	2,247
21	57,87	67,10	67,10	87,10	18,03 ± 0,20	16,52 ± 0,28	-2,45 ± 0,23	-4,01 ± 0,27	2,242
22	56,17	67,10	67,10	100,00	18,13 ± 0,20	15,94 ± 0,29	-2,89 ± 0,24	-5,14 ± 0,27	2,220
23	77,10	67,10	67,10	59,18	17,05 ± 0,18	17,33 ± 0,26	0,75 ± 0,21	1,03 ± 0,24	2,243
24	87,10	67,10	67,10	55,01	15,27 ± 0,18	16,06 ± 0,26	2,45 ± 0,21	3,27 ± 0,24	2,228
25	100,00	67,10	67,10	52,79	15,17 ± 0,18	15,12 ± 0,26	3,64 ± 0,21	3,59 ± 0,24	2,202
26	77,10	67,10	58,96	67,10	16,86 ± 0,18	16,37 ± 0,26	-0,44 ± 0,22	-0,95 ± 0,25	2,243
27	87,10	67,10	54,91	67,10	16,08 ± 0,18	15,36 ± 0,26	-1,28 ± 0,22	-2,01 ± 0,25	2,228
28	100,00	67,10	52,61	67,10	14,97 ± 0,19	14,36 ± 0,26	-1,74 ± 0,22	-2,37 ± 0,25	2,202
29	61,02	67,10	77,10	67,10	16,87 ± 0,18	17,51 ± 0,26	1,53 ± 0,22	2,19 ± 0,25	2,247

TABELA 3.5 - Posições das barras de controle, diferenças de potência axiais, diferenças de potência por quadrante e fatores de pico para os 56 estados críticos (continuação)

Estado	BS1 (%)	BS2 (%)	BC1 (%)	BC2 (%)	DPA ^N (%)	DPA ^W (%)	DPQ _B (%)	DPQ _T (%)	FP*
30	57,94	67,10	87,10	67,10	15,62 ± 0,19	17,22 ± 0,27	2,06 ± 0,23	3,70 ± 0,25	2,243
31	56,33	67,10	100,00	67,10	15,44 ± 0,18	17,30 ± 0,27	3,05 ± 0,22	4,97 ± 0,25	2,221
32	67,10	61,05	77,10	67,10	16,72 ± 0,18	17,19 ± 0,26	1,34 ± 0,21	1,82 ± 0,25	2,247
33	67,10	57,99	87,10	67,10	15,81 ± 0,18	16,51 ± 0,26	2,53 ± 0,21	3,25 ± 0,24	2,242
34	67,10	56,30	100,00	67,10	14,82 ± 0,18	16,38 ± 0,26	2,92 ± 0,21	4,51 ± 0,24	2,220
35	67,10	77,10	58,97	67,10	17,97 ± 0,19	17,35 ± 0,27	-0,91 ± 0,22	-1,56 ± 0,25	2,243
36	67,10	87,10	54,92	67,10	17,82 ± 0,19	16,69 ± 0,27	-1,85 ± 0,22	-3,01 ± 0,26	2,228
37	67,10	100,00	52,68	67,10	17,52 ± 0,19	16,63 ± 0,28	-2,00 ± 0,23	-2,92 ± 0,26	2,202
38	77,10	59,86	77,10	59,86	16,03 ± 0,18	16,52 ± 0,26	0,04 ± 0,21	0,54 ± 0,24	2,247
39	87,10	55,80	87,10	55,80	13,68 ± 0,18	15,62 ± 0,25	1,14 ± 0,21	3,12 ± 0,24	2,227
40	100,00	53,30	100,00	53,30	11,90 ± 0,18	14,38 ± 0,25	2,38 ± 0,21	4,90 ± 0,23	2,178
41	59,75	77,10	59,75	77,10	17,96 ± 0,20	16,41 ± 0,28	-5,04 ± 0,23	-6,63 ± 0,27	2,247
42	55,62	87,10	55,62	87,10	17,73 ± 0,21	15,79 ± 0,29	-6,93 ± 0,24	-8,91 ± 0,28	2,227
43	53,05	100,00	53,05	100,00	17,48 ± 0,22	14,78 ± 0,30	-7,82 ± 0,25	-10,57 ± 0,29	2,178
44	59,85	77,10	77,10	59,85	16,85 ± 0,19	17,95 ± 0,27	-0,50 ± 0,22	0,65 ± 0,25	2,248
45	55,75	87,10	87,10	55,75	15,57 ± 0,19	17,92 ± 0,27	1,03 ± 0,22	3,45 ± 0,26	2,228
46	53,23	100,00	100,00	53,23	14,10 ± 0,19	17,78 ± 0,28	5,47 ± 0,22	9,23 ± 0,26	2,179
47	77,10	59,77	59,77	77,10	17,20 ± 0,21	15,88 ± 0,29	-1,84 ± 0,24	-3,19 ± 0,28	2,248
48	87,10	55,63	55,63	87,10	15,76 ± 0,21	14,25 ± 0,30	-3,41 ± 0,25	-4,95 ± 0,28	2,228
49	100,00	53,05	53,05	100,00	14,52 ± 0,22	12,78 ± 0,31	-4,49 ± 0,26	-6,26 ± 0,29	2,179
50	61,22	61,22	77,10	77,10	17,04 ± 0,21	17,16 ± 0,30	0,41 ± 0,24	0,53 ± 0,28	2,215
51	58,27	58,27	87,10	87,10	16,31 ± 0,21	16,20 ± 0,31	0,76 ± 0,25	0,64 ± 0,29	2,181
52	56,66	56,66	100,00	100,00	14,96 ± 0,22	15,50 ± 0,32	0,45 ± 0,26	0,99 ± 0,30	2,142
53	77,10	77,10	59,35	59,35	17,15 ± 0,20	17,37 ± 0,29	0,45 ± 0,24	0,66 ± 0,28	2,199
54	87,10	87,10	55,50	55,50	15,70 ± 0,20	15,77 ± 0,29	0,73 ± 0,24	0,80 ± 0,28	2,151
55	100,00	100,00	53,28	53,28	14,54 ± 0,21	14,93 ± 0,30	0,22 ± 0,24	0,63 ± 0,28	2,088
56	64,30	77,10	64,30	64,30	17,93 ± 0,20	17,76 ± 0,30	0,88 ± 0,24	0,71 ± 0,28	2,248

* O critério de convergência para a distribuição da densidade de potência foi 10^{-4} .




FIGURA 3.4 - Distribuição radial da densidade potência normalizada - estado 1.




FIGURA 3.5 - Distribuição axial da densidade potência normalizada - estado 1.




FIGURA 3.6 - Distribuição radial da densidade potência normalizada - estado 40.




FIGURA 3.7 - Distribuição axial da densidade potência normalizada - estado 40.




FIGURA 3.8 - Distribuição radial da densidade potência normalizada - estado 43.




FIGURA 3.9 - Distribuição axial da densidade potência normalizada - estado 43.

4 CORRELAÇÕES PARA O FATOR DE PICO

Uma correlação com rede neural necessita que os dados de treinamento apresentem uma relação significativa entre as entradas e as saídas da rede. Os dados de treinamento serão úteis, apenas, se apresentarem relações claras entre as entradas e as saídas, com padrões identificáveis. Os vetores de entrada deverão ser capazes de identificar estados diferentes e fazer associações corretas. Neste capítulo são apresentados como o fator de pico se correlaciona com os vetores de entrada, identificando as classes de comportamento bem determinadas que facilitam o desenvolvimento de correlações.

4.1 Correlação entre FP e as Posições das Barras de Controle

Nas FIG. 4.1 a 4.4 são apresentados os fatores de pico de potência em função das posições das barras de controle BS1, BS2, BC1 e BC2, respectivamente. As figuras são todas similares, com os dados apresentando uma correlação típica, mas de difícil identificação. Os 56 estados do reator produziram fatores de pico de potência variando entre 2,088 e 2,261. Os fatores de pico de potência mostram um máximo relativamente plano entre as posições das barras de controle de, aproximadamente, 60 % a 80 %. Isto significa que o fator de pico é o mesmo para várias configurações das barras, mudando, porém, a sua localização no reator. Quando a barra de controle é inserida no núcleo até a posição 50 %, ou quando ela é retirada até 100 %, os valores do FP diminuem (Moreira e Souza, 2002; Souza e Moreira, 2002 a, b).

Este comportamento das curvas acontece porque quando uma barra de controle que está completamente retirada é inserida no núcleo do reator, ela empurra o fluxo de nêutrons ou a densidade de potência para baixo do núcleo, causando uma distribuição assimétrica com fatores de pico maiores. Após certo ponto, o fluxo de nêutrons move-se para outros quadrantes, causando um decréscimo nos fatores de pico. Quando a barra de controle é mais inserida, o fluxo de nêutrons tende a retornar à parte superior do núcleo para alcançar uma distribuição mais simétrica. Para a configuração do núcleo do reator IPEN/MB-01 verifica-se que, quando as barras de controle passam em torno da posição

60 % existe a transição entre empurrar o fluxo de nêutrons da parte de baixo do núcleo para as direções laterais (Souza e Moreira, 2002 a, b; Souza e Moreira, 2003).

Os mesmos resultados das figuras anteriores são mostrados nas FIG. 4.5 a 4.8, identificando, também, as classes definidas na TAB. 3.3 e a qual classe cada estado pertence. São apresentadas só as nove primeiras classes, pois a décima é composta de apenas um ponto. Observando estas figuras, pode-se ver mais claramente os padrões seguidos pelos dados em cada classe. Há vários estados que apresentam diferentes valores de fator de pico, mas com a mesma posição das barras de controle. Alguns deles pertencem a classes similares como, por exemplo, as classes 2, 3 e 6 mostradas na FIG. 4.5; e outros pertencem a classes diferentes. Isto ocorre porque vários estados foram obtidos com uma ou duas barras de controle numa posição fixa e as outras se compensando a fim de obter a criticalidade. Estes resultados indicam que correlacionar o fator de pico com a posição de apenas uma barra de controle não é suficiente para se obter uma boa estimativa do FP. É necessário considerar as posições das outras barras de controle a fim de identificar mais claramente um dado estado do núcleo e ser capaz de estimar o seu fator de pico (Souza e Moreira, 2002; Moreira e Souza, 2002).

Os resultados apresentados pelas FIG. 4.5 a 4.8 mostram que a Eq. 2.5 é válida para cada classe e que é possível achar uma correlação f_1 (*posições das barras de controle*) para se obter o fator de pico de potência. Observa-se nestas figuras que a correlação entre o fator de pico e as posições das barras de controle é forte e que, conseqüentemente, os dados podem ser usados para treinar uma rede neural a fim de determinar o fator de pico, a partir dos sinais das posições das barras de controle (Souza e Moreira, 2005 a).




FIGURA 4.1 - Fator de pico em função da posição da barra de controle BS1.

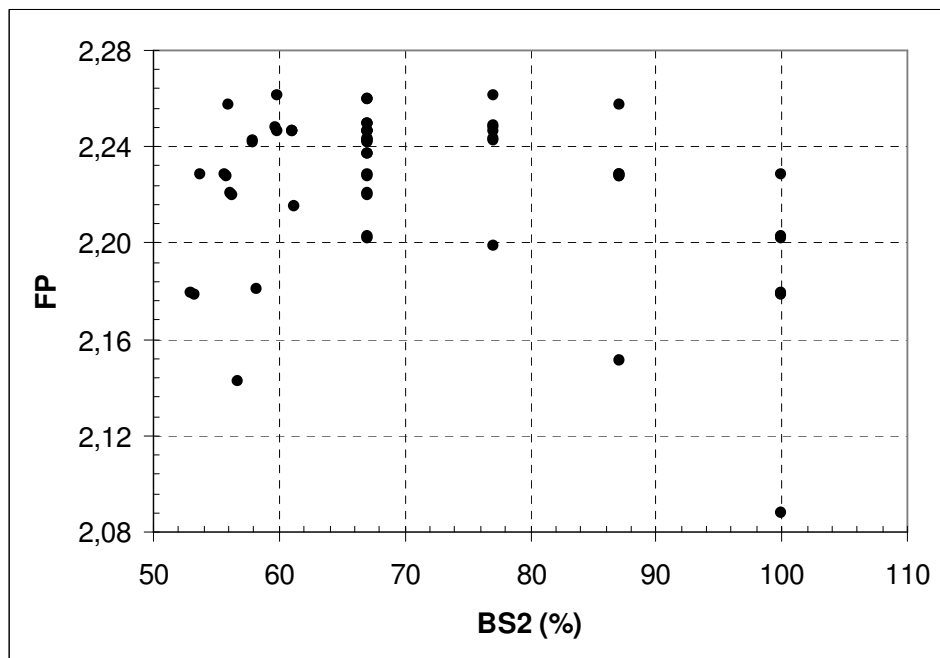


FIGURA 4.2 - Fator de pico em função da posição da barra de controle BS2.




FIGURA 4.3 - Fator de pico em função da posição da barra de controle BC1.

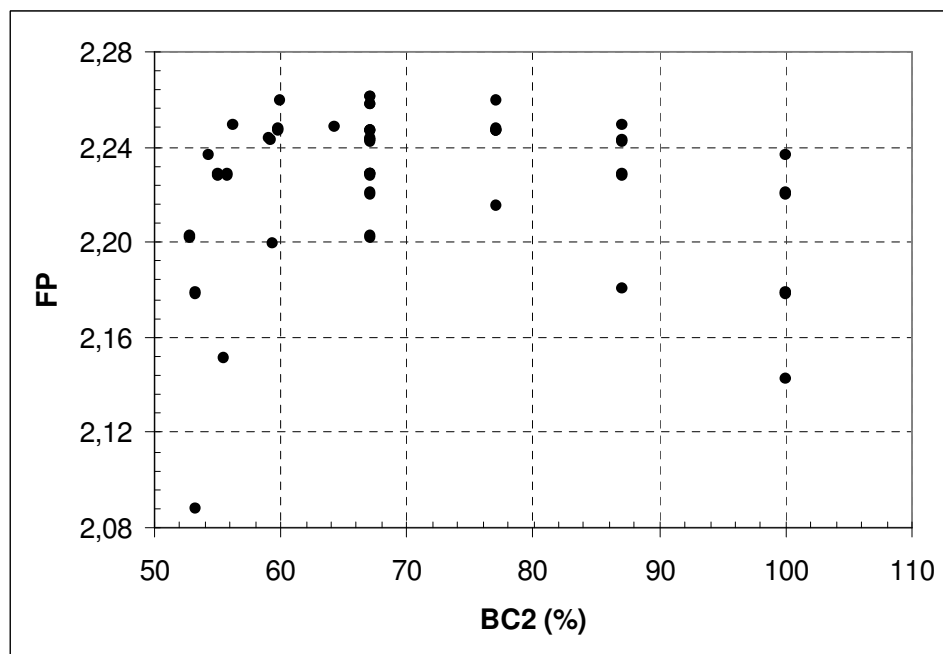


FIGURA 4.4 - Fator de pico em função da posição da barra de controle BC2.




FIGURA 4.5 - Fator de pico em função da posição da barra de controle BS1, identificando as 9 diferentes classes do conjunto de dados.




FIGURA 4.6 - Fator de pico em função da posição da barra de controle BS2, identificando as 9 diferentes classes do conjunto de dados.




FIGURA 4.7 - Fator de pico em função da posição da barra de controle BC1, identificando as 9 diferentes classes do conjunto de dados.




FIGURA 4.8 - Fator de pico em função da posição da barra de controle BC2, identificando as 9 diferentes classes do conjunto de dados.

4.2 Correlação entre FP e as DPAs e DPQs

O comportamento dos fatores de pico com as DPA^N , DPA^W , DPQ_B e DPQ_T , obtidos dos detectores *ex-core* são mostrados nas FIG. 4.9, 4.10, 4.11 e 4.12, respectivamente. A correlação entre o fator de pico e as diferenças de potência axial e por quadrante não é muito clara. Os detectores *ex-core*, localizados longe do núcleo, não são capazes de registrar pequenas diferenças na distribuição da densidade de potência dentro do núcleo. Alguns estados têm distribuições da densidade de potência tais que diferentes FPs acabam produzindo DPAs e DPQs semelhantes (Souza e Moreira, 2002 a; Moreira e Souza, 2002).

As FIG. 4.13 e 4.14 reproduzem a FIG. 4.9 e as FIG. 4.15 e 4.16 reproduzem a FIG. 4.10, incluindo a identificação das classes definidas na TAB. 3.3. Nestas figuras pode-se seguir o comportamento do FP como uma função da DPA^N e DPA^W para cada classe. Com exceção da classe 9, todas as outras têm valores dos fatores de pico entre 2,178 e 2,261, na faixa de variação de DPA^N entre 11,9 % e 19,05 % e de variação de DPA^W entre 12,78 % e 18,68 %. É difícil distinguir as várias classes porque os valores do FP apresentam comportamento irregular nestes intervalos. Esta é uma indicação de que seria difícil identificar, claramente, os estados usando somente DPAs. Dentro de cada classe é possível, com alguma dificuldade, seguir o comportamento do FP como uma função das DPA^N e DPA^W .

Nas FIG. 4.17 e 4.18 tem-se o fator de pico de potência em função de DPQ_B , e nas FIG. 4.19 e 4.20 em função de DPQ_T , onde a classe a qual cada ponto pertence é identificada. Nestes casos, as classes têm padrões mais bem definidos, indicando que as DPQs podem claramente identificar alguns estados e que elas se correlacionam bem com FP.

Observando as FIG. 4.18, 4.19 e 4.20 vê-se que as classes 1 e 9 apresentam valores de DPQ_B e de DPQ_T próximos de zero. Estes estados são simétricos, como visto anteriormente, em relação ao eixo, ao longo das barras de controle BS1 e BS2. As DPQs não são capazes de distinguir tais estados e, nestes casos, as DPAs devem ser consideradas para identificá-los. As FIG. 4.13 a 4.16 mostram que para as classes 1 e 9, FP pode ser facilmente correlacionado com as DPAs.

As FIG. 4.13 a 4.20 mostram que, para cada classe, a Eq. 2.6 é válida e que é possível achar uma correlação do tipo f_2 (DPAs, DPQs) para se obter o fator de pico de

potência. Os resultados apresentados acima mostram que existe uma correlação entre o fator de pico de potência e as diferenças de potência axial e por quadrante, obtidas de detectores *ex-core*. As classes definidas têm padrões claros, mas é necessário uma análise detalhada dos dados a fim de associá-los à cada classe (Souza e Moreira, 2005 a).

Em reatores de potência, as principais perturbações na distribuição da densidade de potência são causadas pelo movimento das barras de controle e pelo envenenamento de xenônio durante os transientes de seguimento de carga. Logo, a correlação dada pela Eq. 2.7, ou seja, f_3 (*posições das barras de controle, DPAs, DPQs*) seria a melhor escolha para se obter o fator de pico de potência, pois ela contempla no vetor de entrada as variáveis responsáveis pelas principais perturbações na distribuição da densidade de potência (Souza e Moreira, 2005 a).

Finalmente, os resultados apresentados permitem dizer que os dados obtidos constituem um bom conjunto de treinamento para o fornecimento do FP pelas redes neurais. Os dados apresentam classes de comportamento nas quais são identificados correlações claras entre os vetores de entrada e de saída.




FIGURA 4.9 - Fator de pico em função da diferença de potência axial do lado norte.

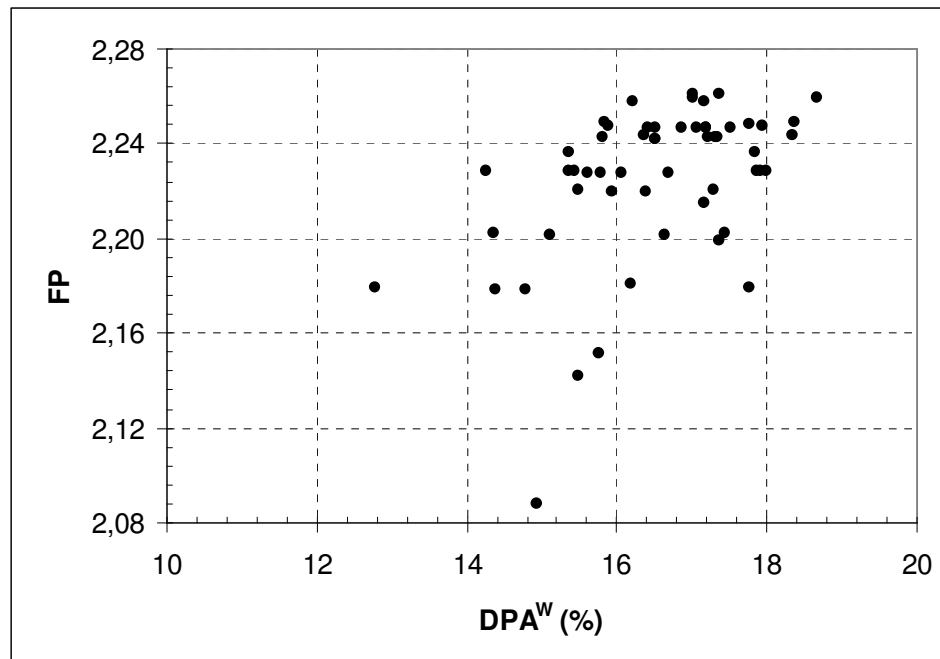


FIGURA 4.10 - Fator de pico em função da diferença de potência axial do lado oeste.




FIGURA 4.11 - Fator de pico em função da diferença de potência por quadrante para a parte inferior do núcleo.




FIGURA 4.12 - Fator de pico em função da diferença de potência por quadrante para a parte superior do núcleo.

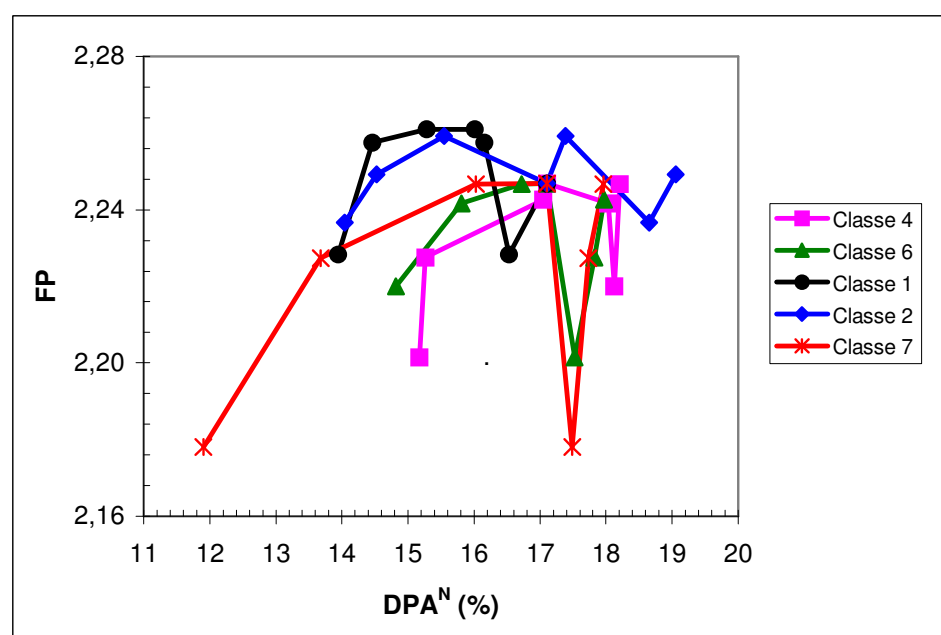


FIGURA 4.13 - Fator de pico em função da DPA^N, identificando as classes 1, 2, 4, 6 e 7.




FIGURA 4.14 - Fator de pico em função da DPA^N , identificando as classes 3, 5, 8 e 9.




FIGURA 4.15 - Fator de pico em função da DPA^W , identificando as classes 1, 2, 3, 4 e 5.




FIGURA 4.16 - Fator de pico em função da DPA^W , identificando as classes 6, 7, 8 e 9.




FIGURA 4.17 - Fator de pico em função da DPQ_B , identificando as classes 1, 2, 3, 4 e 5.




FIGURA 4.18 - Fator de pico em função da DPQ_B , identificando as classes 6, 7, 8, e 9.

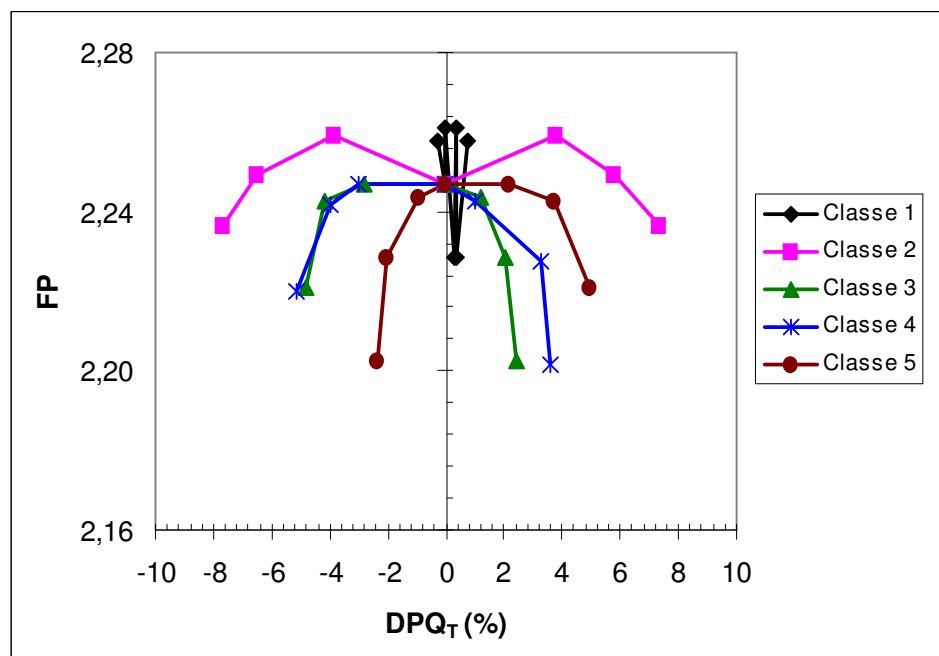


FIGURA 4.19 - Fator de pico em função da DPQ_T , identificando as classes 1, 2, 3, 4 e 5.




FIGURA 4.20 - Fator de pico em função da DPQT, identificando as classes 6, 7, 8 e 9.

5 ESTIMATIVA DO FATOR DE PICO UTILIZANDO REDES NEURAIAS

As redes neurais foram usadas para determinar a superfície, no espaço multidimensional das variáveis de entrada (posições das barras de controle e/ou DPAs e DPQs), que proporciona o melhor ajuste de resultados conhecidos do FP. Para a presente aplicação foram testadas as redes neurais MLP e RBF, com aprendizado supervisionado, e comparados os seus desempenhos. As redes neurais foram implementadas utilizando o Toolbox de Redes Neurais do MATLAB (Dermuth e Beale, 2001).

5.1 Geração dos Dados para Treinamento das Redes Neurais

Os 56 dados experimentais apresentados na TAB. 3.5 foram utilizados para desenvolver as redes neurais a fim de se obter o fator de pico de potência (FP). O conjunto de dados foi dividido em dois subconjuntos: o primeiro subconjunto foi usado para treinar as redes neurais e o segundo foi usado para validar as redes treinadas.

A seleção de um conjunto adequado de exemplos de entrada para o treinamento é importante para o bom desempenho da rede neural. Assim, 80 % dos dados foram retirados, aleatoriamente, de cada classe de movimentação das barras para constituírem o conjunto de treinamento da rede neural. Os 20 % dos dados restantes foram separados para constituírem o conjunto de validação. Como estes exemplos não foram apresentados à rede durante o processo de aprendizagem, eles formam um conjunto adequado para validação.

O número de exemplos era limitado a 56. O procedimento citado acima foi repetido 11 vezes, de modo que foram obtidos 11 conjuntos de treinamento diferentes, com 45 exemplos cada um. O aumento do número de conjuntos de treinamento permitiu uma validação mais geral e evitou a escolha de conjuntos particulares que, por acaso, pudessem dar bons ou maus resultados, evitando, portanto, tendências. Os 11 subconjuntos aleatórios de treinamento e seus correspondentes subconjuntos de validação são apresentados na TAB. 5.1.

TABELA 5.1 - Estados pertencentes aos subconjuntos de treinamento e de validação

Conjunto	Subconjunto de Treinamento	Subconjunto de Validação
1	1, 2, 4, 5, 6, 8, 9, 11, 12, 13, 14, 15, 16, 17, 18, 20, 21, 23, 25, 26, 27, 28, 30, 31, 32, 34, 35, 36, 37,38, 40, 41, 42, 43, 45, 46, 47, 48, 49, 50, 51, 53, 54, 55, 56	3, 7, 10, 19, 22, 24, 29, 33, 39, 44, 52
2	1, 2, 3, 4, 6, 7, 8, 9, 10, 11, 13, 14, 15, 17, 18, 19, 20, 22, 23, 24, 26, 27, 29, 30, 32, 33, 34, 35, 36, 37, 38, 39, 42, 43, 44, 45, 46, 47, 48, 49, 51, 52, 53, 55, 56	5, 12, 16, 21, 25, 28, 31, 40, 41, 50, 54
3	1, 2, 3, 4, 6, 7, 8, 9, 10, 11, 13, 14, 15, 17, 18, 19, 20, 22, 23, 24, 26, 27, 29, 30, 31, 32, 33, 34, 36, 37, 38, 39, 40, 42, 43, 44, 46, 47, 48, 49, 51, 52, 53, 55, 56	5, 12, 16, 21, 25, 28, 35, 41, 45, 50, 54
4	1, 3, 4, 5, 6, 7, 8, 10, 11, 12, 13, 15, 16, 17, 19, 21, 22, 23, 24, 25, 26, 27, 28, 29, 31, 32, 33, 34, 35, 37, 39, 40, 41, 42, 43, 45, 46, 48, 49, 50, 51, 52, 53, 54, 56	2, 9, 14, 18, 20, 30, 36, 38, 44, 47, 55
5	1, 2, 3, 5, 6, 7, 9, 10, 11, 12, 13, 14, 16, 17, 18, 19, 20, 21, 22, 24, 25, 27, 28, 29, 30, 31, 32, 33, 35, 37, 39, 40, 41, 42, 44, 45, 46, 47, 48, 49, 50, 52, 54, 55, 56	4, 8, 15, 23, 26, 34, 36, 38, 43, 51, 53
6	1, 2, 3, 4, 5, 7, 8, 9, 10, 12, 14, 15, 16, 18, 19, 20, 21, 22, 23, 25, 26, 28, 29, 30, 31, 33, 34, 35, 36, 38, 39, 40, 41, 43, 44, 45, 47, 48, 49, 50, 51, 52, 54, 55, 56	6, 11, 13, 17, 24, 27, 32, 37, 42, 46, 53
7	1, 3, 4, 5, 6, 7, 8, 9, 10, 12, 13, 14, 15, 16, 18, 19, 20, 21, 22, 23, 25, 27, 28, 30, 31, 32, 33, 34, 35, 36, 38, 39, 41, 42, 44, 45, 47, 48, 49, 50, 51, 52, 53, 55, 56	2, 11, 17, 24, 26, 29, 37, 40, 43, 46, 54
8	1, 3, 4, 6, 7, 8, 9,10, 11, 12, 13, 15, 16, 17, 18, 19, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 34, 35, 36, 38, 41, 43, 44, 45, 46, 48, 49, 50, 51, 52, 53, 54, 55, 56	2, 5, 14, 20, 32, 33, 37, 39, 40, 42, 47
9	1, 2, 3, 4, 5, 6, 7, 9, 11, 12, 13, 14, 16, 17, 20, 21, 23, 24, 25, 26, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 51, 52, 53, 56	8, 10, 15, 18, 19, 22, 27, 49, 50, 54, 55
10	1, 2, 3, 4, 5, 7, 8, 9, 10, 11, 12, 14, 15, 16, 18, 20, 21, 23, 24, 25, 27, 28, 29, 30, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 44, 45, 46, 47, 49, 50, 51, 53, 54, 55, 56	6, 13, 17, 19, 22, 26, 31, 42, 43, 48, 52
11	1, 2, 3, 4, 5, 6, 9, 11, 12, 13, 14, 15, 16, 17, 18, 19, 20, 21, 22, 25, 26, 27, 28, 30, 31, 32, 34, 35, 36, 38, 39, 41, 42, 43, 44, 45, 47, 48, 49, 50, 51, 52, 53, 54, 56	7, 8, 10, 23, 24, 29, 33, 37, 40, 46, 55

A precisão das redes neurais foi avaliada analisando dois tipos de erros: a raiz quadrada do erro médio quadrático, denominada de S, obtida por

$$S = \left[\frac{1}{M} \sum_{i=1}^M (FP_i - FP_i^{RN})^2 \right]^{1/2} \quad (5.1)$$

e o erro relativo médio, em valor absoluto, dado pela equação

$$E = \frac{1}{M} \sum_{i=1}^M \left| \frac{FP_i^{RN} - FP_i}{FP_i} \right| = \frac{1}{M} \sum_{i=1}^M |E_i| \quad (5.2)$$

onde M é o número de dados no subconjunto, FP_i^{RN} é o fator de pico de potência estimado pela rede neural e FP_i é o valor do fator de pico desejado, apresentado na TAB. 3.5. O erro relativo máximo é denominado E_{MAX} . Em relação a todos os subconjuntos de treinamento, os erros correspondem à média dos 11 subconjuntos formados.

5.2 Treinamento das Redes Neurais

O treinamento de redes neurais pode tornar-se mais eficiente se forem realizados certos pré-processamentos nos dados de entrada e saída da rede. Com este procedimento, todos os dados passam a ter valores dentro de uma mesma faixa, sendo considerados de igual importância na estimativa da saída desejada. Neste trabalho, para alguns casos considerados, os dados de entrada e saída do conjunto de treinamento foram escalonados, de modo que os dados normalizados tenham média zero e desvio padrão unitário. Isto é feito através de uma mudança de variáveis, na qual o valor de x, na nova distribuição, será representado pelo seu desvio em relação à média, medido em unidades de desvio padrão. O algoritmo utilizado para a mudança de escala é dado por:

$$x_n = \frac{x - \bar{x}}{\sigma_x} \quad (5.3)$$

onde x são os dados de entrada, ou de saída, \bar{x} e σ_x as respectivas média e desvio padrão. Este escalonamento foi feito utilizando a função *prestd* do Toolbox de Redes Neurais do MATLAB.

Todas as entradas subseqüentes necessitam ser transformadas usando a mesma normalização, o que foi feito pela função *trastd* do MATLAB. O pós-processamento dos dados do conjunto de treinamento, reconvertendo-os aos valores não normalizados, foi feito utilizando a função *poststd* do mesmo software.

O conjunto de treinamento das redes neurais, utilizado neste trabalho, era composto de dados experimentais que continham erros inerentes aos processos de amostragem. Desta forma, a aproximação por meio de redes neurais deve ser feita visando à obtenção de uma estrutura de rede que seja capaz de modelar os dados, sem modelar o ruído contido neles. Com este fim, foi utilizada a técnica chamada “Método de Treinamento com Parada Antecipada” (Haykin, 1999; Braga et al., 2000), para evitar que a rede fosse excessivamente ajustada (*overfitting*). O *overfitting* ocorre quando, após um certo ciclo de treinamento, a rede começa a piorar a sua taxa de acertos para padrões diferentes daqueles utilizados para o ajuste dos pesos, ou seja, ela perde a habilidade de generalizar. Diz-se então que a rede memorizou os exemplos de treinamento, gravando suas peculiaridades e ruídos, mas não a função subjacente que deve ser modelada. Esta técnica é descrita a seguir:

- o treinamento é interrompido periodicamente, após um determinado número de épocas. Os pesos e os bias são todos fixados e o erro de validação é medido para cada exemplo do conjunto de validação;
- quando a fase de validação é completada, o treinamento é reiniciado;
- o processo é repetido até que o erro médio quadrático de validação seja mínimo. Este é o critério para encerrar o treinamento. (O que a rede aprende após este ponto é, essencialmente, o ruído contido nos dados de treinamento.)

O número de neurônios na camada oculta depende de vários fatores, a saber: do número de exemplos de treinamento, da quantidade de ruídos presente nos exemplos, da complexidade da função a ser aprendida e da distribuição estatística dos dados de treinamento.

5.2.1 Treinamento da Rede MLP

O treinamento da rede MLP foi implementado pelo algoritmo Rprop, (*resilient back-propagation*), disponível no Toolbox de Redes Neurais do MATLAB, que é uma

variação do algoritmo *back-propagation* padrão. Ele é um algoritmo de adaptação global que realiza treinamento supervisionado por lote (*batch*). Na aprendizagem por lote, o ajuste dos pesos é realizado após a apresentação de todos os exemplos de treinamento que constituem uma época. O algoritmo Rprop procura eliminar a influência negativa do valor da derivada parcial na definição do ajuste dos pesos e utiliza apenas o sinal da derivada e não o seu valor. O sinal indica a direção do ajuste dos pesos (aumentar ou diminuir o peso anterior) (Dermuth e Beale, 2001; Haykin, 1999; Braga et al., 2000). Este algoritmo, além de convergir mais rapidamente, foi o que obteve, dentre os pesquisados, o melhor desempenho na solução do problema.

Inicialmente, foi pesquisada a estrutura da rede MLP que melhor se adequava à solução dos problemas. Os resultados indicaram que uma rede com uma camada oculta, com topologia similar àquela mostrada na FIG. 2.1, era suficiente para mapear as entradas para a saída. O treinamento foi feito utilizando a técnica da parada antecipada e o critério de decisão para a escolha do melhor modelo de rede foi aquele que minimizava o erro médio quadrático de validação. O treinamento terminava quando o número de interações excedia o número de épocas (igual a 10^6 neste trabalho), ou o erro médio quadrático fosse menor do que 10^{-6} .

A rotina de treinamento da rede MLP, implementada na linguagem de programação do software MATLAB, é apresentada no APÊNDICE C.

5.2.2 Treinamento da Rede RBF

No APÊNDICE C está descrita a rotina de treinamento da rede RBF. A rotina varre um intervalo de raios e , para cada valor de raio, realiza-se o treinamento por meio da função *newrb*, disponível no Toolbox de Redes Neurais do MATLAB. Para um valor fixo do raio, esta função insere um neurônio na camada oculta e o valor do erro na saída da rede é calculado. Se o valor estipulado do erro de treinamento não é obtido, um novo neurônio é adicionado e as funções radiais da camada oculta são ajustadas novamente. O treinamento é encerrado quando o valor estipulado do erro de treinamento é alcançado (neste trabalho foi considerado 10^{-6}) ou o número máximo de neurônios é inserido (igual a 45, que é o número de exemplos no conjunto de treinamento). O erro de validação é calculado após cada interação. A solução dada pela rotina de treinamento é aquela cujo o erro de validação é mínimo. O máximo valor do raio considerado foi tal que era capaz de cobrir a faixa inteira de variação dos dados de entrada.

5.3 Estimativa dos Fatores de Pico de Potência

Os dados apresentados na TAB. 3.5 e nas FIG. 4.5 a 4.8 e 4.13 a 4.20 mostram que o fator de pico de potência pode ser correlacionado com as variáveis: posições das barras de controle BS1, BS2, BC1 e BC2; diferenças de potência axial DPA^N e DPA^W , e por quadrante, DPQ_B e DPQ_T . Todas as redes neurais consideradas tinham como saída, somente, o fator de pico de potência.

Foram estudados diferentes vetores de entrada, a fim de se determinar a influência destas variáveis no resultado final. As DPAs e DPQs são variáveis complementares e devem aparecer juntas nos vetores de entrada, com o objetivo de distinguir diferentes valores dos fatores de pico das distribuições que apresentam DPAs ou DPQs semelhantes (Souza e Moreira, 2005 b).

O primeiro vetor de entrada foi constituído de sinais das posições das quatro barras de controle BS1, BS2, BC1 e BC2. O valor do FP, estimado pela rede neural, foi dado por

$$FP = f(BS1, BS2, BC1, BC2) \quad (5.4)$$

onde f é a correlação dada pela rede neural.

No segundo caso considerado, a posição da barra de controle BS1 foi retirada do vetor de entrada, a fim de se avaliar a ausência de uma barra na estimativa do FP. Assim, este parâmetro foi estimado por

$$FP = f(BS2, BC1, BC2). \quad (5.5)$$

O terceiro vetor de entrada foi constituído de duas diferenças de potência axial e de duas diferenças por quadrante,

$$FP = f(DPA^N, DPA^W, DPQ_B, DPQ_T). \quad (5.6)$$

O quarto vetor de entrada foi constituído de todas as oito variáveis e FP foi dado por

$$FP = f(BS1, BS2, BC1, BC2, DPA^N, DPA^W, DPQ_B, DPQ_T). \quad (5.7)$$

O quinto vetor de entrada era similar ao quarto, exceto pelas DPQs retiradas, gerando um vetor de entrada com seis variáveis. O objetivo deste procedimento foi avaliar as ausências das DPQs na estimativa do FP,

$$FP = f(BS1, BS2, BC1, BC2, DPA^N, DPA^W) \quad (5.8)$$

e, finalmente, o sexto vetor de entrada também era similar ao quarto vetor, exceto pela barra de controle BS1 retirada, gerando um vetor com sete variáveis. O objetivo foi verificar se a ausência da posição de uma barra de controle pode ser compensada pelas presenças das DPAs e DPQs, no vetor de entrada,

$$FP = f(BS2, BC1, BC2, DPA^N, DPA^W, DPQ_B, DPQ_T). \quad (5.9)$$

Nas seções seguintes são apresentados os resultados obtidos para estes diferentes vetores de entrada.

5.3.1 Estimativa do FP a partir dos Sinais das Posições das Barras de Controle

A entrada apresentada às redes neurais RBF e MLP foi constituída pelos quatro sinais das posições das barras de controle e a saída foi o correspondente valor do FP, conforme a correlação dada pela Eq. 5.4. Não foi necessário normalizar os dados de entrada, pois os valores das posições das barras de controle estavam uniformemente distribuídos na faixa entre 50 % e 100 %. A topologia das redes neurais RBF e MLP e a raiz quadrada do erro médio quadrático, S, obtidas do treinamento utilizando cada um dos 11 conjuntos formados (conforme a TAB. 5.1), são mostrados na TAB. 5.2.

Para as redes RBF, a pesquisa do número ótimo de neurônios na camada oculta resultou em números que variaram entre 16 e 34, mostrando que diferentes topologias são obtidas quando diferentes subconjuntos de treinamento são usados. O raio, σ , variou entre 12,9 e 41,9, que é comparável à distância Euclidiana entre os vários vetores de entrada dos subconjuntos de treinamento (<50). Isto indica que a saída de um neurônio da camada oculta tem contribuição de todas as entradas, mas, como são calculadas pela Eq. 2.13, o dado da entrada mais próximo do centro do neurônio contribui mais para o neurônio de saída. O processo de treinamento convergiu bem, resultando em pequenos erros finais no treinamento. O valor médio da raiz quadrada do erro médio quadrático, considerando os 11 subconjuntos de treinamento, foi 0,0043.

Para as redes neurais MLP, o número ótimo de neurônios pesquisado na camada oculta foi 5, para todos os 11 subconjuntos de treinamento. Isto significa que a topologia da rede independe do subconjunto considerado. O processo convergiu bem para todos os subconjuntos, produzindo pequenos erros finais. O erro S médio obtido foi igual a 0,0035.

Nas FIG. 5.1 e 5.2 estão registrados os erros relativos de treinamento de todos os estados pertencentes aos 11 subconjuntos, usando as redes RBF e MLP, respectivamente. Os erros relativos médio, E, e máximo, E_{MAX} , foram 0,14 % e 0,67 % para a rede RBF, e 0,12 % e 0,70 % para a rede MLP. Em ambos os casos mais de 95 % dos dados estavam dentro da faixa de erro relativo de $\pm 0,50$ %.

O resultado da aplicação da técnica da parada antecipada no treinamento do conjunto 7, utilizando a rede MLP, é mostrado, como exemplo, no APÊNDICE D.

TABELA 5.2 - Arquitetura e a raiz quadrada do erro médio quadrático obtido no treinamento com as redes RBF e MLP, tendo as posições das 4 barras de controle como entrada (Eq. 5.4)

Conjunto	RBF			MLP	
	Arquitetura		Erro no Treinamento	Arquitetura	Erro no Treinamento
	Número de Neurônios	Raio	S	Número de Neurônios	S
1	27	21,9	0,0040	5	0,0023
2	34	12,9	0,0030	5	0,0051
3	30	21,8	0,0030	5	0,0035
4	25	19,6	0,0041	5	0,0027
5	22	17,9	0,0042	5	0,0035
6	25	26,1	0,0036	5	0,0046
7	16	26,5	0,0059	5	0,0040
8	23	24,4	0,0044	5	0,0028
9	23	33,1	0,0044	5	0,0025
10	23	31,5	0,0048	5	0,0038
11	18	41,9	0,0054	5	0,0030
Erro S Médio			0,0043	Erro S Médio	0,0035




FIGURA 5.1 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural RBF, tendo as posições das 4 barras de controle como entrada.

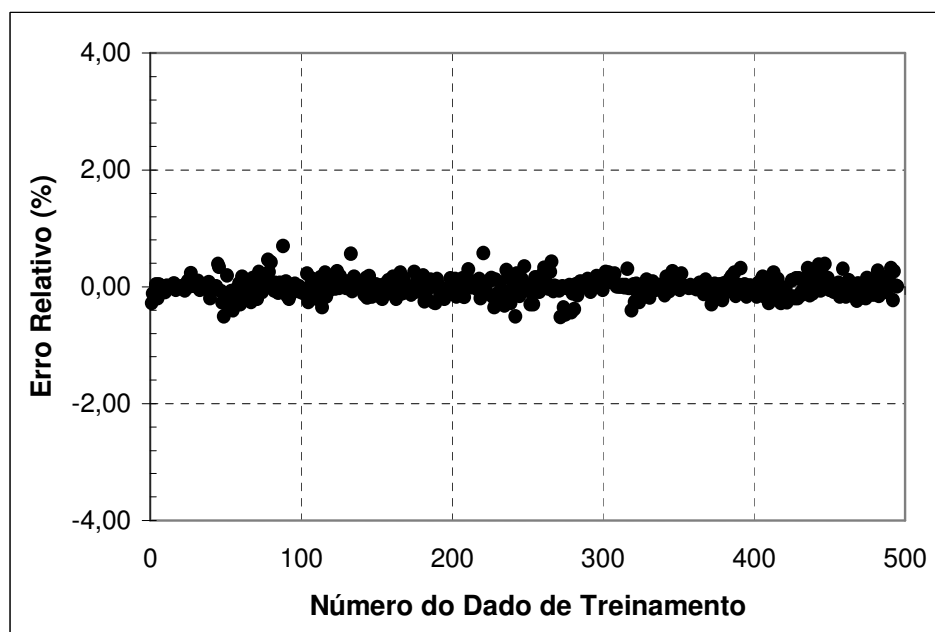


FIGURA 5.2 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural MLP, tendo as posições das 4 barras de controle como entrada.

O desempenho das redes treinadas foi avaliado com os dados de validação. As posições das barras de controle foram processadas pelas redes neurais treinadas e as saídas das redes, chamadas de FP^{RN} , foram comparadas com os respectivos valores desejados do FP dos subconjuntos de validação. Os resultados da raiz quadrada do erro médio quadrático S, e os erros relativos médios E, obtidos para ambos os tipos de rede, são mostrados na TAB. 5.3. Para as redes RBF e MLP, os valores médios dos erros S foram 0,0053 e 0,0068, respectivamente, e a média dos erros relativos E foram 0,19 % e 0,26 %, respectivamente. A comparação entre os valores dos FP e FP^{RN} apresentou uma ótima concordância para todos os 11 subconjuntos de validação.

Nas FIG. 5.3 e 5.4 são comparados os resultados do fator de pico estimado pelas redes, FP^{RN} , e os valores desejados dos subconjuntos de validação, calculado pelo código CITATION. As linhas tracejadas nas figuras representam a faixa de erro relativo de $\pm 0,5$ % e a linha cheia representa a coincidência entre o valor real do parâmetro e seu valor estimado. Para as redes neurais RBF e MLP, os resultados mostram que 95 % e 92 % dos fatores do pico de potência foram estimados, respectivamente, dentro desta faixa de erro.

Os erros relativos de cada um dos 121 dados, dos 11 subconjuntos de validação, considerando as redes RBF e MLP, são mostrados nas FIG. 5.5 e 5.6, respectivamente. Os erros relativos máximos (E_{MAX}) foram 0,76 % para a rede RBF e 0,90 % para a rede MLP.

TABELA 5.3 - Estatística da estimativa do FP pelas redes RBF e MLP, tendo as posições das 4 barras de controle como entrada (Eq. 5.4)

Conjunto	Erro na Validação			
	RBF		MLP	
	S	E (%)	S	E (%)
1	0,0044	0,16	0,0054	0,21
2	0,0053	0,19	0,0068	0,26
3	0,0052	0,19	0,0055	0,21
4	0,0039	0,14	0,0084	0,32
5	0,0051	0,15	0,0071	0,29
6	0,0062	0,19	0,0075	0,24
7	0,0040	0,13	0,0050	0,19
8	0,0041	0,16	0,0051	0,19
9	0,0079	0,29	0,0084	0,31
10	0,0068	0,27	0,0079	0,31
11	0,0058	0,23	0,0074	0,30
Erros Médios	0,0053	0,19	0,0068	0,26




FIGURA 5.3 - Estimativa do FP pela rede neural RBF, considerando todos os dados dos subconjuntos de validação, tendo as posições das 4 barras de controle como entrada.




FIGURA 5.4 - Estimativa do FP pela rede neural MLP, considerando todos os dados dos subconjuntos de validação, tendo as posições das 4 barras de controle como entrada.




FIGURA 5.5 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural RBF, tendo as posições das 4 barra de controle como entrada.




FIGURA 5.6 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural MLP, tendo as posições das 4 barra de controle como entrada.

Considere a situação em que o fator de pico de potência foi estimado pela rede RBF, que teve como vetor de entrada as posições das três barras de controle (BS2, BC1 e BC2), dado pela Eq. 5.5. Neste caso, foi utilizada, somente, a rede neural RBF, para efeito de comparação. Os exemplos usados no treinamento foram normalizados, conforme a Eq. 5.3.

Os 11 subconjuntos de dados de treinamento, apresentados na TAB. 5.1, foram usados para treinar a rede. Os resultados obtidos no treinamento das redes e nas suas respectivas validações são apresentados na TAB. 5.4. O número de neurônios na camada oculta variou entre 16 e 35, e o valor do raio entre 1,9 e 11,1, conforme o conjunto de dados de treinamento usado. Os valores médios da raiz quadrada do erro médio quadrático e dos erros relativos, obtidos durante o procedimento de treinamento, foram 0,0052 % e 0,18 %, respectivamente. E os erros obtidos durante o procedimento de validação foram 0,0083 % e 0,30 %, respectivamente. Os erros na estimativa do FP foram pequenos, mas maiores do que aqueles obtidos considerando-se as 4 barras de controle como entrada.

TABELA 5.4 - Erros de treinamento e de validação das redes RBF, tendo as posições de três barras de controle como entrada (Eq. 5.5)

Conjunto	Arquitetura		Treinamento	Validação	
	Número de Neurônios	Raio	S	S	E (%)
1	18	9,8	0,0055	0,0090	0,31
2	20	8,8	0,0057	0,0069	0,22
3	18	8,2	0,0059	0,0076	0,25
4	23	5,1	0,0055	0,0043	0,17
5	16	7,8	0,0077	0,0097	0,35
6	35	6,3	0,0026	0,0091	0,31
7	30	4,5	0,0037	0,0080	0,32
8	21	11,1	0,0059	0,0061	0,23
9	22	4,8	0,0053	0,0081	0,30
10	21	1,9	0,0062	0,0110	0,41
11	28	2,5	0,0035	0,0115	0,38
Erros Médios			0,0052	0,0083	0,30

5.3.2 Estimativa do FP a partir das Diferenças de Potência Axial e por Quadrante

Neste item, os parâmetros de entrada das redes neurais foram as diferenças de potência axial dos lados norte e oeste e as diferenças de potência por quadrante das partes de cima e de baixo do núcleo do reator, conforme a Eq. 5.6. A saída foi o correspondente valor do FP. Como pode ser visto na TAB. 3.5, os valores de DPQs, muito menores do que os de DPAs, poderiam ser interpretados durante o processo de treinamento como menos importantes. Para evitar este problema, foi feita a normalização dos dados do vetor de treinamento da rede RBF, a fim de que o processo de treinamento tivesse sucesso. Já no caso da MLP, este procedimento não foi necessário.

Na TAB. 5.5 são apresentadas as arquiteturas das redes e a raiz quadrada dos erros médios quadráticos (S), obtidos durante o processo de treinamento. Para as redes neurais RBF, a média dos 11 valores dos erros S foi 0,0111. O número mínimo de neurônios na camada oculta foi 10 e o máximo 37, e o raio variou entre 0,42 e 2,10. Como anteriormente, o número de neurônios na camada oculta das redes RBF variou de acordo com o subconjunto de treinamento utilizado. Todas as redes MLP tinham 9 neurônios na única camada oculta e a média dos erros S foi 0,0134.

TABELA 5.5 - Arquitetura e a raiz quadrada do erro médio quadrático obtido no treinamento com as redes RBF e MLP, tendo as DPAs e DPQs como entrada (Eq. 5.6)

Conjunto	RBF			MLP	
	Arquitetura		Erro no Treinamento	Arquitetura	Erro no Treinamento
	Número de Neurônios	Raio	S	Número de Neurônios	S
1	22	0,42	0,0096	9	0,0139
2	26	0,97	0,0102	9	0,0219
3	28	1,09	0,0104	9	0,0130
4	20	1,49	0,0133	9	0,0114
5	10	2,10	0,0218	9	0,0127
6	22	1,99	0,0113	9	0,0111
7	37	0,92	0,0080	9	0,0138
8	28	1,35	0,0095	9	0,0102
9	27	1,90	0,0122	9	0,0131
10	24	1,28	0,0119	9	0,0168
11	36	1,07	0,0040	9	0,0096
Erro S Médio			0,0111	Erro S Médio	0,0134

Os erros relativos obtidos durante o processo de treinamento podem ser vistos nas FIG. 5.7 e 5.8. Para as redes RBF, 99 % dos dados estimados do FP têm erros dentro da faixa $\pm 1,70$ %. Os erros relativos máximo (E_{MAX}) e médio (E) foram 3,05 % e 0,35 %, respectivamente. Para as redes MLP, estes erros foram 3,84 % e 0,44 %, respectivamente, e 98 % dos dados estimados apresentaram erros dentro da mesma faixa, $\pm 1,70$ %.

Os resultados obtidos durante o processo de validação para ambos os tipos de redes são apresentados na TAB. 5.6. Observa-se que os erros são, em geral, pequenos. O valor médio da raiz quadrada do erro médio quadrático foi igual a 0,0184 para a rede RBF e 0,0167 para a MLP. Os erros relativos médios (E) foram 0,67 % e 0,60 % para as redes RBF e MLP, respectivamente. Os erros médios foram calculados a partir dos resultados dos 11 subconjuntos de validação.




FIGURA 5.7 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural RBF, tendo as DPAs e DPQs como entrada.




FIGURA 5.8 - Erro relativo entre FP e FP^{RN} , obtido no treinamento com a rede neural MLP, tendo as DPAs e DPQs como entrada.

TABELA 5.6 - Estatística da estimativa do FP pelas redes RBF e MLP, tendo as DPAs e DPQs como entrada (Eq. 5.6)

Conjunto	Erro na Validação			
	RBF		MLP	
	S	<i>E</i> (%)	S	<i>E</i> (%)
1	0,0131	0,50	0,0132	0,51
2	0,0196	0,79	0,0167	0,58
3	0,0148	0,49	0,0080	0,26
4	0,0163	0,61	0,0165	0,55
5	0,0217	0,91	0,0195	0,70
6	0,0203	0,67	0,0156	0,50
7	0,0187	0,72	0,0212	0,75
8	0,0175	0,60	0,0164	0,56
9	0,0215	0,81	0,0183	0,66
10	0,0148	0,55	0,0166	0,70
11	0,0241	0,77	0,0219	0,81
Erros Médios	0,0184	0,67	0,0167	0,60

Comparações entre os valores estimados do FP^{RN} , pelas redes neurais RBF e MLP, e os valores desejados do FP são mostradas nas FIG. 5.9 e 5.10. Para as redes RBF e MLP, 96 % e 93 % dos valores do FP^{RN} foram estimados dentro da faixa de erro relativo de $\pm 1,70$ %, respectivamente. Os erros relativos entre FP e FP^{RN} , para todos os dados usados para testar as redes neurais treinadas, são mostrados nas FIG. 5.11 e 5.12. A partir da análise destas figuras, observa-se que os erros relativos máximos, em valor absoluto, apresentados pelas redes RBF e MLP, foram 2,35 % e 1,97 %, respectivamente.




FIGURA 5.9 - Estimativa do FP pela rede neural RBF, considerando todos os dados dos subconjuntos de validação, tendo as DPAs e DPQs como entrada.




FIGURA 5.10 - Estimativa do FP pela rede neural MLP, considerando todos os dados dos subconjuntos de validação, tendo as DPAs e DPQs como entrada.




FIGURA 5.11 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural RBF, tendo as DPAs e DPQs como entrada.




FIGURA 5.12 - Erro relativo entre FP e FP^{RN} , obtido na validação com a rede neural MLP, tendo as DPAs e DPQs como entrada.

5.3.3 Estimativa do FP a partir das Posições das Barras de Controle e das Diferenças de Potência Axial e por Quadrante

Neste item, são apresentados os resultados das estimativas do FP para os casos nos quais os vetores de entrada da rede incluíam informações sobre as posições das barras de controle e as diferenças de potência axial e por quadrante, isto é, FP dado pelas Eq. 5.7, 5.8 e 5.9. No caso cujo vetor de entrada era constituído pelas posições das 4 barras de controle e pelas DPAs e DPQs (Eq. 5.7) e no caso formado pelas 3 barras mais as DPAs e DPQs (Eq. 5.9) os exemplos de treinamento foram normalizados pela Eq. 5.3. Já para os dados seguindo a Eq. 5.8, ou seja, as posições das 4 barras de controle e as DPAs, este procedimento não foi necessário.

Os resultados obtidos no treinamento e na validação dos 11 conjuntos formados, para estes três tipos de vetores de entrada, são apresentados nas TAB. 5.7, 5.8 e 5.9. Como anteriormente, a rede RBF produziu modelos com diferentes números de neurônios na camada oculta, de acordo com o conjunto de entrada utilizado. O número máximo e mínimo de neurônios na camada oculta variou entre 10 e 41 para os três vetores de entrada. O valor do raio variou de acordo com o número de neurônios nas redes.

Na TAB. 5.10, estão relacionados os principais parâmetros das redes neurais RBF, obtidos com estes vetores de entrada. Os erros de treinamento e de validação foram pequenos em todos os casos. Comparando seus erros, é possível ter uma indicação sobre a importância relativa de cada variável de entrada para o resultado da rede. Considerando o resultado da rede cujo vetor de entrada era representado pela Eq. 5.7, que tem 8 variáveis, o erro relativo médio na estimativa do fator de pico foi 0,21 % e a média da raiz quadrada do erro médio quadrático (S) foi 0,0057. Excluindo as DPQs do vetor de entrada e obtendo-se, por conseguinte, a rede definida pela Eq. 5.8, o resultado da determinação do FP melhorou levemente, diminuindo o erro relativo para 0,19 % e o erro médio, S, para 0,0052. Por outro lado, excluindo uma variável de barra de controle do vetor de entrada, como ocorre na rede definida pela Eq. 5.9, o resultado da estimativa do FP piorou, aumentando o erro relativo para 0,27 % e o erro médio, S, para 0,0076.

TABELA 5.7 - Erros de treinamento e de validação das redes RBF, tendo as posições das 4 barras de controle, DPAs e DPQs, normalizadas, como entrada (Eq. 5.7)

Conjunto	Arquitetura		Treinamento	Validação	
	Número de Neurônios	Raio	S	S	E (%)
1	26	5,2	0,0036	0,0032	0,11
2	33	5,3	0,0019	0,0061	0,21
3	41	1,6	0,0007	0,0050	0,19
4	29	4,8	0,0033	0,0022	0,08
5	29	8,8	0,0026	0,0068	0,27
6	20	5,2	0,0043	0,0088	0,28
7	26	5,0	0,0036	0,0063	0,24
8	31	5,3	0,0030	0,0043	0,14
9	30	5,8	0,0021	0,0062	0,25
10	27	10,5	0,0034	0,0074	0,32
11	11	28,4	0,0117	0,0064	0,22
Erros Médios			0,0037	0,0057	0,21

TABELA 5.8 - Erros de treinamento e de validação das redes RBF, tendo as posições das 4 barras de controle e DPAs, sem normalizar, como entrada (Eq. 5.8)

Conjunto	Arquitetura		Treinamento	Validação	
	Número de Neurônios	Raio	S	S	E (%)
1	23	28,8	0,0048	0,0043	0,16
2	36	13,4	0,0021	0,0047	0,19
3	32	23,4	0,0035	0,0054	0,18
4	25	19,5	0,0041	0,0038	0,14
5	22	18,0	0,0042	0,0053	0,15
6	28	26,1	0,0034	0,0064	0,21
7	15	28,4	0,0056	0,0043	0,15
8	26	24,4	0,0041	0,0036	0,14
9	22	35,7	0,0042	0,0073	0,28
10	23	20,3	0,0047	0,0066	0,26
11	18	26,9	0,0053	0,0051	0,20
Erros Médios			0,0042	0,0052	0,19

TABELA 5.9 - Erros de treinamento e de validação das redes RBF, tendo as posições das 3 barras de controle, DPAs e DPQs, normalizadas, como entrada (Eq. 5.9)

Conjunto	Arquitetura		Treinamento	Validação	
	Número de Neurônios	Raio	S	S	E (%)
1	29	4,0	0,0035	0,0063	0,22
2	15	4,3	0,0081	0,0095	0,31
3	21	2,5	0,0058	0,0075	0,24
4	31	6,4	0,0042	0,0028	0,11
5	31	5,8	0,0028	0,0117	0,40
6	32	15,0	0,0037	0,0096	0,34
7	20	3,8	0,0052	0,0054	0,22
8	26	9,9	0,0056	0,0042	0,16
9	20	18,1	0,0072	0,0116	0,42
10	10	14,4	0,0140	0,0069	0,24
11	26	3,3	0,0050	0,0078	0,31
Erros Médios			0,0059	0,0076	0,27

TABELA 5.10 - Erros na estimativa do FP pelas redes neurais RBF, tendo as posições das barras de controle, DPAs e DPQs como entrada (Eq. 5.7, 5.8 e 5.9)

	4 Barras de Controle, DPAs e DPQs (Eq. 5.7)	4 Barras de Controle e DPAs (Eq. 5.8)	3 Barras de Controle, DPAs e DPQs (Eq. 5.9)
Número máximo de neurônios	41	36	32
Número mínimo de neurônios	11	15	10
Raio máximo	28,4	35,7	18,1
Raio mínimo	1,6	13,4	2,5
Erro S médio de treinamento	0,0037	0,0042	0,0059
Erro S médio de validação	0,0057	0,0052	0,0076
Erro relativo médio de validação	0,21 %	0,19 %	0,27 %

5.4 Discussão dos Resultados das Estimativas do FP

A performance das redes na determinação dos fatores de pico de potência está resumida na TAB. 5.11. As rede neurais estão ordenadas em ordem crescente de seus erros relativos médios de determinação do FP, os quais variam entre 0,19 % e 0,67 %, e dos erros S médios, os quais variam entre 0,0052 e 0,0184. Na prática, os pequenos erros indicariam que todas as redes são adequadas para estimar o fator de pico da densidade de potência, mas algumas considerações podem ser feitas sobre os modelos estudados.

Para as redes com as posições das barras de controle como entrada (Eq. 5.4), a comparação entre os dois tipos de redes neurais, MLP e RBF, mostra que as redes RBF apresentaram resultados um pouco melhores. Inversamente, para as redes tendo as DPAs e DPQs como entrada (Eq. 5.6), os melhores resultados foram das redes MLP. As pequenas diferenças nos erros indicam que ambos tipos de redes possuem precisão semelhante.

Os dados, com muitos padrões de movimentação das barras de controle, foram caracterizados por perturbações localizadas na distribuição da densidade de potência. Comparando as FIG. 5.5 e 5.6 com as FIG. 5.11 e 5.12, é possível notar que os erros de validação das redes que têm as posições das barras de controle como entrada são aproximadamente a metade daquelas que têm DPAs e DPQs como entrada. A maioria dos erros relativos são menores do que $|1|$ % e $|2|$ %, respectivamente. As redes neurais que tinham no vetor de entrada informações sobre as posições das barras de controle foram mais eficientes ao descrever as variações localizadas na distribuição da densidade de potência.

Pode-se concluir que as posições das barras de controle contêm informações detalhadas e localizadas sobre a distribuição da densidade de potência e que as DPAs e DPQs, obtidas dos sinais dos detectores *ex-core*, descrevem sua variação global nas direções axial e radial. Como nesta pesquisa as perturbações no reator foram causadas pelos movimentos das barras de controle, as redes contendo estas informações nos vetores de entrada apresentaram as melhores performances. Se o reator tivesse sido perturbado pelo envenenamento de xenônio, que causa perturbações globais na distribuição da densidade de potência, as redes contendo na entrada informações sobre as DPAs e DPQs teriam, provavelmente, apresentado melhor performance.

A melhor estimativa do FP foi obtida com a rede neural contendo as posições das quatro barras de controle e as DPAs no vetor de entrada (Eq. 5.8). A inclusão das

DPQs no vetor de entrada, obtendo a rede definida pela Eq. 5.7, não melhorou os resultados. Uma explicação possível é que a informação global trazida pelas DPQs era excessiva, complicando a solução do problema. Por outro lado, a inclusão das DPAs no vetor de entrada que só continha informações sobre as barras (Eq. 5.8), melhorou a estimativa do FP. A informação global levada à rede pelas DPAs foi complementar e ajudou na determinação do FP (Souza e Moreira, 2005 a).

Este comportamento complementar também foi observado quando a posição da barra de controle BS1 foi retirada do vetor de entrada. Quando os vetores de entrada continham somente informações sobre as posições das barras de controle (redes definidas pelas Eq. 5.4 e 5.5), a falta da posição da barra de controle BS1 aumentou o erro S médio da estimativa do FP em 56,6 %. Quando o vetor de entrada continha, também, informações sobre as DPAs e DPQs (redes definidas pelas Eq. 5.7 e 5.9), a falta da posição da barra de controle BS1 aumentou o erro S médio da estimativa do FP em somente 33,3 %. Este resultado mostra que as DPAs e DPQs forneceram informações redundantes que substituíram à fornecida pela barra de controle BS1.

Os resultados mostraram que 45 exemplos, mesmo não sendo um número muito grande, foram suficientes para treinar adequadamente as redes neurais. Os dados de treinamento continham exemplos de todas as classes que foram identificadas como importantes para descrever o comportamento do fator do pico de potência. As redes neurais RBF realizaram dois trabalhos a fim de produzir bons resultados. Inicialmente, elas identificaram a classe do vetor de entrada. Posteriormente, interpolaram os valores do FP de acordo com o vetor de entrada e a classe identificada. Na solução deste problema, as redes neurais identificaram padrões e interpolaram variáveis (Souza e Moreira, 2005 b).

A incerteza máxima na estimativa do fator de pico, utilizando a técnica de redes neurais, conforme pode ser visto na TAB. 5.11, foi menor do que a incerteza obtida em medidas detalhadas, realizadas em arranjo experimental, a partir de mapeamentos da distribuição da densidade de potência com detectores *in-core*, que foi 5 % na região central do núcleo do reator IPEN/MB-01 (Miranda e Moreira, 1997).

Outro ponto importante diz respeito à capacidade apresentada pelos detectores *ex-core* para estimar o fator de pico da densidade de potência em reatores com núcleos pequenos. No reator IPEN/MB-01, no qual os dados de treinamento foram obtidos, um detector *ex-core* colocado na parte superior, ou inferior, do núcleo, que tem uma altura de somente 54,6 cm, monitora quase a totalidade do núcleo, devido às pequenas dimensões

envolvidas. No entanto, os resultados demonstraram que, mesmo com esta dificuldade, os detectores *ex-core* também são capazes de dar informação sobre a distribuição da densidade de potência em reatores com núcleos pequenos. Em grandes núcleos, devido às grandes dimensões envolvidas, é de se considerar que um detector *ex-core* colocado na parte superior do núcleo detecta somente nêutrons provenientes desta parte. Isto porque os nêutrons que contribuem para o sinal de um detector *ex-core* vêm das partes do núcleo que estão próximos ao detector.

TABELA 5.11 - Performance de todas as redes neurais na estimativa do fator de pico

	Entrada	Tipo de Rede	Erro S Médio	Erro Relativo Médio (%)	Erro Relativo Máximo (%)
Eq. 5.8	BS1, BS2, BC1, BC2, DPA ^N , DPA ^W	RBF	0,0052	0,19	0,74
Eq. 5.4	BS1, BS2, BC1, BC2	RBF	0,0053	0,19	0,76
Eq. 5.7	BS1, BS2, BC1, BC2, DPA ^N , DPA ^W , DPQ _B , DPQ _T	RBF	0,0057	0,21	1,07
Eq. 5.4	BS1, BS2, BC1, BC2	MLP	0,0068	0,26	0,95
Eq. 5.9	BS2, BC1, BC2, DPA ^N , DPA ^W , DPQ _B , DPQ _T	RBF	0,0076	0,27	1,28
Eq. 5.5	BS2, BC1, BC2	RBF	0,0083	0,30	1,41
Eq. 5.6	DPA ^N , DPA ^W , DPQ _B , DPQ _T	MLP	0,0167	0,60	1,97
Eq. 5.6	DPA ^N , DPA ^W , DPQ _B , DPQ _T	RBF	0,0184	0,67	2,35

5.5 Robustez das Redes Neurais RBF e MLP

A possibilidade de falha dos detectores *ex-core* e dos sensores de posição das barras pode prejudicar a atuação da rede neural. É importante no evento de falha de um dos sensores que os outros consigam prover informação suficiente para que a rede neural ainda produza um bom resultado, em outras palavras, é importante verificar se os componentes do vetor de entrada apresentam informação redundante. Para averiguar esta redundância,

foram realizados testes com as redes neurais RBF e MLP, considerando duas situações: a primeira, com os vetores de entrada contendo informações sobre as posições das quatro barras de controle, conforme a Eq. 5.4, (para as redes RBF e MLP); e, a segunda, com os vetores de entrada contendo as informações anteriores mais as DPA^N e DPA^W , Eq. 5.8, (para a rede RBF).

As avaliações consistiram na determinação do fator de pico admitindo uma falha por vez. A simulação da falha foi realizada considerando-se cada uma das variáveis do vetor de entrada com sinal nulo. Os testes foram realizados com todos os 11 estados que formam o subconjunto 7 de validação e os resultados são mostrados, em detalhes, nas TAB. E.7 a E.17, no APÊNDICE E. Não se considerou falhas múltiplas nos testes, pois, nesta situação, o sistema de proteção automaticamente já deve causar o desligamento do reator.

No caso cujo vetor de entrada continha as informações das posições das barras de controle, observou-se que, no caso da rede MLP, o valor da incerteza na estimativa do FP depende, em geral, da barra cujo sinal é nulo. Por exemplo, na TAB. E.7, que mostra os resultados para o estado 2, a falta do sinal da barra BS1 resultou em um erro relativo de -0,27 % e na falta da BS2 o erro foi -0,71 %; enquanto para a falta das barras BC1 e BC2 os erros foram -5,71 % e -4,38 %, respectivamente. Já para a rede RBF não há esta dependência, sendo os erros resultantes na estimativa do FP aproximadamente iguais, para cada estado considerado.

Na TAB. 5.12 são apresentadas, em resumo, as incertezas médias obtidas na determinação do FP, considerando os 11 estados do subconjunto 7 de validação (APÊNDICE E). O erro relativo médio, em valor absoluto, no caso em que o vetor de entrada consistia nos sinais das posições das 4 barras de controle foi 0,13 % para a rede RBF e 0,19 % para a MLP. Quando há falha em qualquer uma das barras, o erro da rede RBF aumenta para da ordem de 5 % e o erro da MLP para, em média, 2,2 %. A incerteza média associada à rede MLP na determinação de FP é, aproximadamente, a metade da incerteza da rede RBF, o que demonstra uma maior robustez da rede neural MLP à falhas nos sensores das barras.

Considerando a situação cujo o vetor de entrada da rede RBF continha as posições das 4 barras e as DPAs, o FP foi estimado com um erro relativo médio de 0,15 %. Quando falha qualquer uma das barras, o erro vale, aproximadamente, 4,5 %; e quando a falha ocorre na DPA^N ou na DPA^W o erro relativo médio é da ordem de 1 %. Estes

resultados mostram que a rede neural RBF é mais robusta à falhas nos sinais dos detectores *ex-core*.

Comparando os resultados obtidos com a rede RBF, para as situações cujos vetores de entrada são dados pelas posições das 4 barras de controle e as DPAs e pelas posições das 4 barras, observa-se que a falta do sensor de qualquer uma das barras no primeiro caso leva a uma incerteza 10 % menor na estimativa do FP do que no segundo caso. As informações das DPAs compensam a falta do sinal da barra de controle.

É interessante ressaltar que a incerteza máxima (5 %) obtida na estimativa do FP pela rede neural RBF, no caso de falha em qualquer uma das barras, é igual ao valor da incerteza das medidas da distribuição da densidade de potência realizadas por Miranda e Moreira (1997).

TABELA 5.12 - Avaliação dos erros na estimativa do FP em caso de falha, dando sinal nulo, em cada uma das variáveis do vetor de entrada do subconjunto 7

		Erro Relativo Médio (%)		Erro Relativo Médio (%)	
Número de Falhas	Descrição da Entrada	RBF	Descrição da Entrada	RBF	MLP
0	BS1, BS2, BC1, BC2, DPA ^N , DPA ^W	0,15	BS1, BS2, BC1, BC2	0,13	0,19
Variável em Falha com Sinal Nulo		Variável em Falha com Sinal Nulo			
1	BS1	4,46	BS1	4,96	1,81
1	BS2	4,47	BS2	4,96	1,89
1	BC1	4,52	BC1	4,97	2,58
1	BC2	4,53	BC2	4,97	2,54
1	DPA ^N	1,03	----	----	----
1	DPA ^W	1,05	----	----	----

5.6 Discussão sobre Possível Aplicação em Reator de Potência

Neste item, são feitos alguns comentários sobre como implementar este esquema de redes neurais em reatores de potência. O sistema de proteção de um reator de

potência requer informação em tempo real sobre a distribuição da densidade de potência ou o fator de pico. Esta informação poderá ser fornecida por uma rede neural dedicada, que tenha como vetor de entrada as variáveis que são monitoradas pelo próprio sistema de proteção. Baseando-se no que foi discutido, é possível dizer que as redes neurais podem estimar o fator de pico de potência com precisão, desde que certos pontos sejam observados:

1. os dados de treinamento devem incluir todos os estados possíveis que serão monitorados no futuro;
2. os dados de treinamento devem ser agrupados em classes, com comportamentos similares de fatores de pico de potência, de modo que a rede neural RBF possa, primeiro, identificar as classes e, então, interpolar os fatores de pico de potência;
3. as variáveis dos vetores de entrada devem ser constituídas de dados reais medidos (sinais dos detectores *ex-core* e das posições das barras de controle) para evitar a inclusão de incertezas desconhecidas que podem surgir quando são usados dados simulados;
4. os valores dos fatores de pico de potência, usados no treinamento da rede, devem ser calculados com boa precisão para garantir que a rede neural faça uma boa estimativa deste parâmetro, pois o erro de interpolação introduzido pela rede neural é pequeno.

Os dados de treinamento, com as características descritas acima, podem ser obtidos pela aquisição dos dados de entrada (posição das barras de controle e sinais dos detectores *ex-core*) de estados críticos do reator, ou próximos da criticalidade, estabelecidos durante os testes de partida ou durante a operação. Como a operação do reator é realizada com padrões específicos de posições e movimentos de barras de controle, é importante escolher, adequadamente, os estados que farão parte dos dados de treinamento. Este treinamento poderá ser realizado de forma supervisionada ou não supervisionada.

Estima-se que uma tomada de dados referente a um estado do reator demore cerca de 10 minutos (sendo nove minutos para a estabilização do reator e um minuto para a coleta de dados das posições das barras de controle e dos sinais dos detectores *ex-core*). A cada 30 dias é necessário obter-se novos estados que levarão em conta a queima do

combustível. O número de estados que serão necessários para compor o conjunto de dados de treinamento é uma questão a ser estudada.

Durante os transientes de seguimento de carga, a distribuição da densidade de potência varia, continuamente, em razão do envenenamento do xenônio e da realimentação termo-hidráulica. As posições das barras de controle não são variáveis importantes para registrar estas perturbações porque, em muitos estados, durante tais transientes, a distribuição da densidade de potência varia enquanto as barras de controle são mantidas em posições fixas. A perturbação global na distribuição da densidade de potência deverá ser levada em conta pelas DPAs e DPQs. Todas as perturbações possíveis devem ser consideradas por meio de exemplos no conjunto de treinamento e, seguramente, elas constituirão diferentes classes com comportamentos particulares dos fatores de pico de potência. Neste caso, os exemplos do conjunto de dados de treinamento deverão ser obtidos de estados quase-estáticos do reator durante transientes com variações temporais lentas, ou por meio de simulações numéricas. A rede neural deverá conter, no vetor de entrada, as posições das barras de controle e as DPAs e DPQs (Eq. 5.7) para identificar estas novas classes de comportamento e para interpolar o fator de pico de potência.

5.6.1 Vantagens e Dificuldades na Aplicação em Reatores de Potência

A incerteza no limite de densidade de potência está relacionada à habilidade do sistema de proteção em monitorar o nível de potência do reator e sua distribuição de densidade de potência durante a operação. Em reatores que dispõem de sistemas de detectores *in-core* fixos, a incerteza na monitoração do fator de pico é de 6 W/cm^2 ou, aproximadamente, 4,5 %, onde, da ordem de 1,3 % é referente à incerteza na medida de potência e 3,2 % é referente à estimativa da distribuição de potência (Kuehnel et al., 2002). Esta incerteza é comparável às obtidas em mapeamentos detalhados de distribuição de densidade de potência com detectores *in-core* do tipo mini-câmara de fissão realizados no reator IPEN/MB-01, que produzem erros máximos em torno de 5 % (Miranda e Moreira, 1997). Em reatores que utilizam sinais de detectores *ex-core* e mapeamentos da distribuição da densidade de potência periódicos, estas incertezas podem ainda ser maiores.

Os resultados apresentados nas quatro primeiras correlações da TAB. 5.11 indicam que o fator de pico é estimado com um erro máximo em torno de 1 %. A diferença de 1 % para 3,2 % ou 2,2 % pode ser considerada o ganho obtido utilizando estas correlações de redes neurais para estimar o fator de pico, desde que em reatores de

potência os resultados tenham precisão semelhante. Nota-se que o ganho pode ser maior para reatores que não dispõem de sistemas de monitoração *in-core* fixos, nos quais as incertezas são um pouco maiores.

Kuehnel et al. (2002) indicam que o impacto de uma melhoria na estimativa da densidade de potência local na estimativa de DNBR é de cerca de um fator 2, isto é, uma diminuição de 1 % na incerteza da densidade de potência local pode levar a uma diminuição de 2 % na incerteza da estimativa do DNBR. Resultados semelhantes são apresentados para os reatores coreanos, nos quais as incertezas nas estimativas de DNBR diminuem de 11,5 % para 3,5 % quando são eliminados os erros na distribuição de potência utilizada nas correlações (Lee e Chang, 2003). Em relação ao DNBR, o ganho que se teria utilizando as correlações de redes neurais desenvolvidas neste trabalho seria uma diminuição da ordem de 4 % na incerteza deste parâmetro.

Estes resultados são potencialmente interessantes, pois permitem, por exemplo, o aumento da potência de operação de reatores de potência, desde que nesses reatores os resultados de estimativa do fator de pico tenham incertezas semelhantes às apresentadas neste trabalho. A potência de operação do reator poderia aumentar em 2,2 % nas condições de atuação do desligamento de sobre-potência e em 4 % nas condições de atuação do limite de sobre-temperatura ou DNB (USNRC, 1995).

A maior dificuldade que se apresenta para a aplicação destas correlações em reatores de potência está ligada ao fato de se tratar de um software e de um sistema digital de elevado grau de segurança. É necessário garantir que se possa cumprir um rigoroso processo de verificação e validação, V&V, para a certificação e aceitação de tal sistema pelo órgão regulador (ANSI/ANS-10.4, 1998; USNRC, 1999). O processo de V&V pode ser dividido em duas partes: uma refere-se ao software e a outra ao conhecimento implícito dos parâmetros da rede neural. As atividades de V&V para um software ocorrem nas fases de definição, codificação, integração e teste, instalação e manutenção. As maiores preocupações estão ligadas à complexidade e tamanho do algoritmo do software que dificulta a execução de V&V nas últimas quatro fases citadas.

Embora o desenvolvimento e treinamento de uma rede neural seja uma atividade complexa e de muitas fases, a sua utilização prática é simples. Um sistema de proteção digital, com capacidade computacional similar à de processadores Pentium, pode realizar estas operações em tempo real sem maiores dificuldades. Exemplos da implementação, em um sistema de proteção, de algoritmos de estimativa do fator de pico

de potência utilizando redes neurais MLP e RBF são mostrados no APÊNDICE F. O fator de pico de potência é determinado por meio de redes neurais do tipo MLP e RBF em 3 ou 4 etapas de operações de soma e multiplicação de matrizes e cálculo de funções, respectivamente. Verifica-se que não há necessidade de sistemas operacionais ou pacotes de software específicos, tornando factível a realização das várias etapas de V&V.

A validação do conhecimento implícito da rede neural requer que se faça um trabalho semelhante ao que se apresenta nesta pesquisa, ou seja, determinar a precisão da correlação baseada em redes neurais para estimar o fator de pico de potência, caracterizando bem as fronteiras de validade desta correlação.

A manutenção do sistema de proteção está ligada a atualização dos parâmetros da rede neural em intervalos de tempo pré determinados. Esta atualização significa alterar os coeficientes das matrizes que é um conjunto de dados pequeno. Para redes neurais MLP, com N entradas e M neurônios na camada oculta, a quantidade de parâmetros é $(N+2)M+1$. Por exemplo, para 8 entradas e 9 neurônios tem-se um total de 91 números a serem atualizados.

6 CONCLUSÕES

Este trabalho considerou o problema de desenvolver uma correlação precisa para inferir o fator de pico da densidade de potência, que possa ser incorporado ao sistema de proteção de reatores de pequeno porte. Um sistema deste tipo também pode ser utilizado no sistema de supervisão e limitação do reator, provendo ao operador informações ligadas à segurança durante a operação. A técnica de rede neural artificial foi escolhida para desenvolver esta correlação, devido à sua habilidade para resolver problemas complexos e não lineares em tempo real.

Um conjunto de dados de treinamento foi obtido experimentalmente para estimar o fator de pico de potência, em reator de pequeno porte, utilizando como entrada os sinais reais das posições das barras de controle e das diferenças de potência axial e por quadrante, obtidas de sinais dos detectores *ex-core*. Os experimentos foram realizados no reator de potência zero IPEN/MB-01 e reproduziram, tanto quanto possível, a situação real encontrada em PWRs. Obteve-se um conjunto de dados com 56 exemplos diferentes da distribuição da densidade de potência dentro do núcleo. Para obtê-los, as barras de controle foram movimentadas em diferentes configurações, cobrindo o máximo de posições possíveis. Os fatores de pico de potência foram obtidos de detalhados cálculos tridimensionais, com o código CITATION.

Relação entre o Fator de Pico e as Posições das Barras de Controle

Os resultados experimentais obtidos no reator mostraram que há correlação entre o fator de pico de potência e as posições das barras de controle, conforme é mostrado no Capítulo 4. Os dados puderam ser agrupados em 10 classes diferentes de comportamento dos fatores de pico, com um padrão claro em suas relações que possibilita a determinação do fator de pico de potência por meio das posições das barras de controle.

Relação entre o Fator de Pico e os Sinais de Detectores *Ex-core*

Os dados experimentais também mostraram que há uma clara relação entre o fator de pico de potência e a diferença de potência por quadrante; já a relação com a diferença de potência axial é mais complexa. Neste caso, os padrões não eram facilmente

identificáveis, quando comparados com os dados das posições das barras de controle ou com os dados da diferença de potência por quadrante. Estes resultados indicaram que as informações das diferenças de potência axial e por quadrante devem ser complementares, numa correlação para se obter o fator de pico de potência.

Uso de Sinais de Detectores *Ex-core* para Monitorar a Distribuição de Potência em Reatores de Pequeno Porte

Esta investigação demonstrou a viabilidade de se obter correlações, com boa precisão, entre o fator de pico de potência e os sinais dos detectores *ex-core*, para reatores de pequeno porte. Os experimentos realizados no reator IPEN/MB-01 produziram dados que apresentaram uma correlação forte entre estas variáveis, conforme mostra o Capítulo 4. Os resultados foram muito bons, mesmo sendo este reator de dimensões pequenas, de aproximadamente 0,5 m de altura ativa. As correlações de redes neurais se mostram adequadas para implementação no sistema de proteção do reator da Marinha.

Correlações para Reatores de Potência

Considerando o problema de reatores de potência, foi analisado como uma rede neural deve considerar as perturbações na distribuição da densidade de potência causadas pelos movimentos das barras de controle, transientes de xenônio, queima de combustível e realimentação termo-hidráulica.

Em reatores de potência, uma rede neural deve conter, no seu vetor de entrada, informações das posições das barras e dos sinais dos detectores *ex-core*.

O procedimento para determinar os parâmetros da correlação de redes neurais em reatores de potência deve seguir os passos sugeridos no item 5.5. O treinamento da rede neural seria feito periodicamente, de forma supervisionada ou não supervisionada, utilizando dados obtidos de estados estáticos e quase-estáticos.

Precisão das Redes Neurais para Determinar o Fator de Pico

Foram utilizadas as redes neurais RBF e MLP para estabelecer essas correlações e inferir o fator de pico no canal quente. Os resultados indicaram a importância dos dados de treinamento serem agrupados em diferentes classes de comportamento dos fatores de pico de potência, nas quais podiam ser identificadas correlações claras entre os vetores de entrada e as saídas. As redes neurais RBF realizaram dois trabalhos, a fim de

produzir bons resultados. Primeiro, identificaram a qual classe o vetor de entrada pertencia e, segundo, interpolaram os valores do FP, de acordo com o vetor de entrada e a classe identificada.

As redes RBF e MLP, tendo as posições das barras de controle como entrada, estimaram o fator de pico de potência com 95 % e 92 % das predições, com erros relativos dentro do intervalo $\pm 0,50$ %, respectivamente. Considerando as redes RBF, os valores do FP foram estimados com erro relativo médio de 0,19 %. Para as redes MLP este erro foi de 0,26 %. Os valores médios da raiz quadrada do erro médio quadrático foram 0,0053 e 0,0068 para as redes RBF e MLP, respectivamente. Os erros na determinação do FP, utilizando as posições das barras de controle, foram muito pequenos, apresentando grande exatidão e precisão nos resultados finais.

Considerando o caso de ter as DPAs e DPQs como dados de entrada das redes, os resultados também foram bons, mas com erros um pouco maiores. Com as redes RBF e MLP, 96 % e 93 % dos valores estimados do FP, respectivamente, tiveram erros relativos dentro do intervalo $\pm 1,70$ %. Para as redes RBF, os fatores de pico foram estimados com erro relativo médio de 0,67 %, e para a MLP, de 0,60 %. Os valores médios da raiz quadrada do erro médio quadrático foram 0,018 e 0,017 para as redes RBF e MLP, respectivamente.

Os pequenos erros obtidos, utilizando-se as redes RBF e MLP, indicam que ambos os tipos de redes podem ser considerados de similar precisão e exatidão na solução do problema proposto. A incerteza máxima na estimativa dos fatores de pico de potência, obtida utilizando-se a técnica de redes neurais, foi menor do que a obtida construindo-se um mapa da distribuição de fluxo com detectores *in-core* no reator IPEN/MB-01.

Como as perturbações no reator foram causadas pela movimentação das barras de controle, as redes neurais que continham no seu vetor de entrada informações sobre as posições das mesmas apresentaram os melhores resultados. Se o reator tivesse sido perturbado pelo envenenamento de xenônio, as redes com diferenças de potência axial e por quadrante no vetor de entrada teriam apresentado melhores resultados.

A possibilidade de falha dos detectores *ex-core* e dos sensores de posição das barras podem prejudicar a atuação da rede neural. Para averiguar a robustez das redes à falhas nestes sensores, foram realizados testes estimando-se os fatores de pico de potência, admitindo uma falha por vez, com sinal nulo, em cada variável do vetor de entrada das

redes. Os resultados mostraram que a rede MLP apresenta uma maior robustez à falhas nos sensores das barras, se comparada à rede RBF. Considerando a rede RBF, ela é mais robusta à falhas nos sinais dos detectores *ex-core*, ou nas DPAs, do que nos sensores das barras de controle.

Originalidade e Trabalhos Futuros

Os objetivos propostos foram alcançados. Alguns dos resultados obtidos conferem originalidade a este trabalho, a saber: os experimentos realizados no reator IPEN/MB-01 para a obtenção dos dados para treinamento de redes neurais para determinação de fator de pico; a demonstração de que os sinais de detectores *ex-core* podem monitorar a distribuição de potência em reatores de pequeno porte; e, finalmente, a metodologia que sistematiza a forma de se obter dados de treinamento para as redes neurais, identificando classes de perturbações na distribuição de potência.

Contudo, estudos adicionais devem ser realizados visando a implantação propriamente dita desta metodologia no sistema de proteção de reatores de potência. Os principais estudos seriam a obtenção de dados de reatores de potência, a fim de confirmar que os transientes de xenônio possam ser monitorados pelas diferenças de potência axial e por quadrante com precisão semelhante a que obtivemos nestes experimentos. Outro estudo importante diz respeito ao licenciamento junto ao órgão regulador de um sistema digital com estas características, especialmente ligados às atividades de verificação e validação do software a ser instalado no sistema de proteção e do conhecimento implícito dos parâmetros da rede neural.

APÊNDICE A - Rotina Experimental

A seguir tem-se a rotina experimental que foi submetida e aprovada, para execução, pelo Comitê de Revisão de Segurança do Instituto de Pesquisas Energéticas e Nucleares, IPEN.

Esta rotina descreve os passos para se inibir o intertravamento das barras de segurança e a análise de segurança sobre estas atividades. Este intertravamento atua durante a operação normal do reator.

Ela também fornece um guia para a realização dos experimentos cujo objetivo é obter o maior número possível de estados críticos do reator, com diferentes distribuições de potência, por meio do posicionamento das barras de controle e de segurança em diferentes alturas.

Os itens 4.8.2 a 4.8.8 e o 4.10 não foram executados, pois considerou-se suficiente, para a solução do problema proposto, o conjunto de dados até então obtido, contendo 56 estados críticos do reator com diferentes distribuições de potência.

Determinação de Fator de Pico Utilizando Detectores Externos ao Tanque de Moderador

**Rose Mary Gomes do Prado Souza
João Manoel Losada Moreira**

Rotina Experimental

ÍNDICE

Seção 0 - Índice	1
Seção 1 - Objetivo	2
Seção 2 - Condições Iniciais e Precauções	2
Seção 3 - Instrumentos e Equipamentos Especiais	3
Seção 4 - Rotina	3
Seção 5 - Critérios de Aceitação	9
Seção 6 - Condições Finais e Precauções	9
Seção 7 - Conclusões e Recomendações	9
Seção 8 - Documentos de Referência	9
Seção 9 - Anexos - Análise de Segurança	10

1. OBJETIVO

O objetivo desta rotina experimental é fornecer um guia para a realização dos experimentos para medida de fatores de pico utilizando detectores de nêutrons posicionados externamente ao núcleo, com o reator operando a uma potência de até 100 W, estando as barras de controle e de segurança posicionadas em diferentes alturas.

Busca-se obter uma correlação que produza os valores de fatores de pico local em um reator a partir de informações disponíveis sobre as características do reator nuclear, dos sinais dos detectores externos e da posição das barras de controle.

Pretende-se demonstrar, com este experimento, a viabilidade de se obter os fatores de pico, de forma apropriada para se monitorar a densidade de potência máxima em reatores de pequeno porte.

2. CONDIÇÕES INICIAIS E PRECAUÇÕES

Os experimentos serão realizados utilizando-se detectores de nêutrons com dois comprimentos ativos diferentes, colocando-os em posições simétricas em relação ao centro do núcleo. Em cada uma das medidas, o reator deverá ser colocado crítico com todas as barras de controle colocadas à mesma altura.

As medidas serão repetidas para várias configurações de barras de controle. As seguintes ações devem ser realizadas antes de se iniciar as medidas:

1. Montar a configuração cilíndrica do reator com o máximo de varetas de combustível no núcleo.
2. Inibir o intertravamento que impede a movimentação das barras de segurança durante a operação do reator. As ações para se fazer esta inibição estão na Seção 2.1.
3. Montar o dispositivo que permite o posicionamento de detectores de nêutrons, em alturas diferentes, fora do tanque de moderador.
4. Montar o detector de nêutrons e eletrônica associada.

Neste experimento, a cota zero no eixo axial é considerada o centro do núcleo ativo do reator. O posicionamento axial dos detectores será indicado segundo esta referência.

2.1. Inibição do Intertravamento de Movimentação das Barras de Segurança

Para se proceder a inibição do intertravamento das barras de segurança deve-se tomar as ações indicadas no Quadro 1. O intertravamento existente no reator IPEN/MB-01 permite as seguintes situações:

- a) que se movimente as barras de segurança somente quando as barras de controle estão completamente inseridas no núcleo;
- b) que se movimente as barras de controle somente quando as barras de segurança estão completamente retiradas do núcleo.

Devido a estas condições e existirem 2 barras de segurança e duas barras de controle é necessário fazer quatro intervenções nos armários da instrumentação, conforme mostra o Quadro 1. Na instrumentação do reator as barras de segurança e controle têm a seguinte identificação: BS1 – barra 1, BS2 – barra 2, BC1 – barra 3, BC2 – barra 4.

Quadro 1 - Ações para inibir o intertravamento de movimentação das barras de segurança.

Barra	Ações
BS1	Colocar jumps nos bornes 111 e 112 da borneira No. 1 do armário de movimentação de barras.
BS2	Colocar jumps nos bornes 113 e 114 da borneira No. 1 do armário de movimentação de barras.
BC1	Colocar jumps nos bornes 65 e 66 da borneira No. 1 do armário de movimentação de barras.
BC2	Colocar jumps nos bornes 67 e 68 da borneira No. 1 do armário de movimentação de barras.

Fonte: Eng. Mariano da Divisão RN4.

Estas intervenções devem ser feitas pelos Eng. Jaime e Mariano da Divisão RN4, sob a supervisão do chefe da instalação.

3. INSTRUMENTOS E EQUIPAMENTOS ESPECIAIS

Para a realização do experimento são necessários os seguintes equipamentos em estado operacional.

1. Dois detectores CPNB 35;
2. Dois detectores de ^{10}B ;
3. Eletrônica associada;
4. Estrutura de suporte externo ao tanque moderador.

4. ROTINA

4.1. Teste de Funcionalidade

4.1.1 Verificar se os 4 detectores estão operacionais; determinar o tempo morto e a tensão de operação.

4.1.2 Determinar a eficiência do Cd na atenuação de nêutrons da seguinte forma:

- a) Contagem C1, dos nêutrons provenientes de uma fonte de Am-Be de 1 Ci, com o detector com 18 cm de janela;
- b) Contagem C2, com o detector com 9 cm de janela;
- c) Calcular a razão C2/C1 e verificar se está próximo de 0,5.

4.2. Preparação do Experimento

4.2.1 Colocar os 4 detectores de nêutrons externamente ao tanque de moderador, em posição axial conforme indicado abaixo:

Detector 1 (CPNB-35) –	Face Norte	Cota _____
Detector 2 (CPNB-35) –	Face Norte	Cota _____
Detector 3 (Boro-10) –	Face Oeste	Cota _____
Detector 4 (Boro-10) –	Face Oeste	Cota _____

4.2.2 Ligar o reator de acordo com a rotina de procedimento de partida /1/, na configuração indicada abaixo:

Configuração: _____

4.2.3 Verificar a potência de saturação de todos os 4 detectores. Determinar a menor potência de operação, denominada potência de medida (acumular da ordem de 10^5 contagens).

Potência de medida - _____

4.3. Intercalibração dos Detectores para a Potência de 10 W

4.3.1 Posicionar os Detectores 1 e 2 na face oeste, na cota –18 cm.

4.3.2 Ligar o reator de acordo com a rotina de procedimento de partida /1/, na configuração de referência, isto é, com todas as barras à mesma altura. Estabilizar o reator na potência de 10 W e anotar a contagem.

Contagem do Detector 1 - _____.

Contagem do Detector 2 - _____.

4.3.3 Desligar o reator.

4.3.7 Posicionar os Detectores 3 e 4 na face oeste, na cota –18 cm.

4.3.8 Ligar o reator de acordo com a rotina de procedimento de partida /1/, na configuração de referência, isto é, com todas as barras à mesma altura. Estabilizar o reator na potência de 10 W e anotar a contagem.

Contagem do Detector 3 - _____.

Contagem do Detector 4 - _____.

4.3.12 Desligar o reator.

4.4. Contagem dos Detectores Externos em Função da Posição das Barras

4.4.1 Colocar o reator crítico na potência de medida com as barras de controle e de segurança à mesma altura. Anotar as posições das barras na Tabela 1.

4.4.2 Acumular a contagem de nêutrons por um tempo suficiente, para se ter uma boa estatística. Registrar na Tabela 1.

4.5. Compensação Cruzada de Barras

4.5.1 Retirar a barra BS2 entre 5 e 10%, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS1 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.5.2 Retirar a barra BS1 entre 5 e 10%, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.5.3 Retirar a barra BC1 entre 5 e 10%, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.5.4 Retirar a barra BC2 entre 5 e 10 %, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC1 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.6. Compensação Paralela de Barras

4.6.1 Retirar a barra BS2 entre 5 e 10 %, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.6.2 Retirar a barra BC2 entre 5 e 10 %, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.6.3 Retirar a barra BC2 entre 5 e 10 %, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS1 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.6.4 Retirar a barra BS1 entre 5 e 10 %, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.6.5 Retirar a barra BS1, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC1 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.6.6 Retirar a barra BC1, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS1, de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.6.7 Retirar a barra BC1, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

- 4.6.8 Retirar a barra BS2, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC1 de modo a manter a criticalidade.
- Registrar as posições das barras de controle na Tabela 1.
 - Registrar a contagem de nêutrons na Tabela 1.
 - Repetir este procedimento três vezes.

4.7. Compensação de Barras Emparelhadas Duas a Duas

- 4.7.1 De forma emparelhada, retirar as barras BC1 e BS1, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BC2 e BS2 de modo a manter a criticalidade.

- Registrar as posições das barras de controle na Tabela 1.
- Registrar a contagem de nêutrons na Tabela 1.
- Repetir este procedimento três vezes.

- 4.7.2 De forma emparelhada, retirar as barras BC2 e BS2, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BC1 e BS1 de modo a manter a criticalidade.

- Registrar as posições das barras de controle na Tabela 1.
- Registrar a contagem de nêutrons na Tabela 1.
- Repetir este procedimento três vezes.

- 4.7.3 De forma emparelhada, retirar as barras BC1 e BS2, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BC2 e BS1 de modo a manter a criticalidade.

- Registrar as posições das barras de controle na Tabela 1.
- Registrar a contagem de nêutrons na Tabela 1.
- Repetir este procedimento três vezes.

- 4.7.4 De forma emparelhada, retirar as barras BC2 e BS1, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BC1 e BS2, de modo a manter a criticalidade.

- Registrar as posições das barras de controle na Tabela 1.
- Registrar a contagem de nêutrons na Tabela 1.
- Repetir este procedimento três vezes.

- 4.7.5 De forma emparelhada, retirar as barras BC1 e BC2, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BS1 e BS2 de modo a manter a criticalidade.

- Registrar as posições das barras de controle na Tabela 1.
- Registrar a contagem de nêutrons na Tabela 1.
- Repetir este procedimento três vezes.

4.7.6 De forma emparelhada, retirar as barras BS1 e BS2, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BC1 e BC2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8. Compensação Emparelhada Tripla de Barras

4.8.1 Retirar a barra BS2, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BC1, BC2 e BS1 emparelhadas de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8.2 Retirar as barras BC1, BC2 e BS1, de forma emparelhada, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8.3 Retirar a barra BC2, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BS2, BC1 e BS1 emparelhadas de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8.4 Retirar as barras BS2, BC1 e BS1, de forma emparelhada, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC2 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8.5 Retirar a barra BS1, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BC1, BS2 e BC2 emparelhadas de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8.6 Retirar as barras BC1, BS2 e BC2, de forma emparelhada, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BS1 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8.7 Retirar a barra BC1, além da posição indicada na configuração de referência (item 4.3.2), compensando com as barras BS2, BC2 e BS1 emparelhadas de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.8.8 Retirar as barras BS2, BC2 e BS1, de forma emparelhada, além da posição indicada na configuração de referência (item 4.3.2), compensando com a barra BC1 de modo a manter a criticalidade.

- a) Registrar as posições das barras de controle na Tabela 1.
- b) Registrar a contagem de nêutrons na Tabela 1.
- c) Repetir este procedimento três vezes.

4.9. Desligar o reator, conforme /2/.

4.10. Repetir os itens 4.5 a 4.8 para uma nova configuração do núcleo do reator com um excesso de reatividade menor cerca de 300 pcm. Estas configurações serão repetidas de acordo com a solicitação do experimentador.

5. CRITÉRIOS DE ACEITAÇÃO

A rotina será aceita estando todos os itens devidamente assinados pelo operador e experimentador. No caso de algum item não ser realizado, o experimentador e o operador devem redigir um pequeno texto explicativo das razões, na própria rotina.

6. CONDIÇÕES FINAIS E PRECAUÇÕES

6.1 Ao término das operações previstas, proceder à rotina de desligamento do reator IPEN/MB-01 de acordo com a rotina de procedimento de desligamento do reator /6/.

6.2 Eliminar as inibições de intertravamento realizadas na seção 2.

7. CONCLUSÕES E RECOMENDAÇÕES

Esta rotina é um guia para a obtenção de dados para a determinação do fator de pico a partir de sinais de detectores externos ao núcleo e posições de barras de controle.

8. DOCUMENTOS DE REFERÊNCIA

/1/ - *Rotina de Procedimento de Partida do Reator IPEN/MB-01* - 16-OP-037 - 18/10/89

/2/ - *Rotina de Procedimento de Desligamento do Reator IPEN/MB-01* - 16-OP-038 - 16/04/93

9. ANEXOS

ANÁLISE DE SEGURANÇA

As intervenções propostas na Seção 2.1 para permitir a movimentação das barras de segurança do reator não afetam a segurança do reator. Os critérios de segurança exigem que se desligue o reator em caso de potência superior a 110 W, período inferior a 17 s e que se tenha reatividade nas barras de controle e de segurança suficiente para absorver 1,5 vezes o excesso de reatividade do núcleo. Estes critérios não são violados com a inibição do intertravamento.

A operação do reator IPEN/MB-01 com as barras de segurança dentro do núcleo será semelhante ao regime de operação do reator IEA-R1m, onde as barras de segurança e controle estão normalmente inseridas no reator. Uma operação nestas condições não apresenta nenhuma condição insegura para o reator, operadores e meio ambiente, conforme a operação deste reator tem demonstrado.

Tabela 1 - Anotações dos Resultados

Descrição da Configuração:							
Indicação do Detector:							
Item	Posição das Barras				Posição Detector	Taxa Contagem (cps)	DATA
	BC1	BC2	BS1	BS2			
4.4.1, 4.4.2							
4.5.1							
4.5.2							
4.5.3							
4.5.4							
4.6.1							
4.6.2							
4.6.3							
4.6.4							
4.6.5							
4.6.6							
4.6.7							

Tabela 1 - Anotações dos Resultados (continuação)

Descrição da Configuração:							
Indicação do Detector:							
Item	Posição das Barras				Posição Detector	Taxa Contagem (cps)	DATA
	BC1	BC2	BS1	BS2			
4.6.8							
4.7.1							
4.7.2							
4.7.3							
4.7.4							
4.7.5							
4.7.6							
4.8.1							
4.8.2							
4.8.3							
4.8.4							
4.8.5							
4.8.6							
4.8.7							
4.8.8							

APÊNDICE B - Avaliação das Incertezas pela Fórmula de Propagação de Erros

São apresentadas as expressões utilizadas no cálculo das incertezas das contagens normalizadas dos detectores *ex-core* e das grandezas DPAs e DPQs. São levadas em consideração as propagações das incertezas a partir das medidas experimentais das contagens dos detectores *ex-core*.

Em medidas nucleares os dados, muitas vezes, são processados por meio de multiplicação, adição, ou outra manipulação funcional para se ter o valor da grandeza de interesse. Supondo que uma grandeza F de um parâmetro seja função de várias variáveis independentes x, y, z, \dots , e que pode ser representada por:

$$F = F(x, y, z, \dots). \quad (\text{B.1})$$

A incerteza no parâmetro F será dada pela fórmula de propagação de erros (Knoll, 1979)

$$\sigma(F) = \left[\left(\frac{\partial F}{\partial x} \sigma_x \right)^2 + \left(\frac{\partial F}{\partial y} \sigma_y \right)^2 + \left(\frac{\partial F}{\partial z} \sigma_z \right)^2 + \dots \right]^{\frac{1}{2}} \quad (\text{B.2})$$

sendo $\sigma_x, \sigma_y, \sigma_z, \dots$ as incertezas das variáveis x, y, z, \dots .

As incertezas das grandezas apresentadas neste trabalho foram determinadas aplicando a Eq. B.2, como mostrado a seguir:

- no caso de serem registradas N contagens independentes, repetidas em tempos de contagem iguais, o desvio padrão da média das contagens é dado por:

$$\sigma(\bar{x}) = \sqrt{\frac{\bar{x}}{N}} \quad (\text{B.3})$$

- o desvio padrão $\sigma(C)$ da contagem normalizada C , apresentado na TAB. 3.4, é calculado por:

$$\sigma(C) = C \left\{ \left[\frac{\sigma(\bar{x})}{\bar{x}} \right]^2 + \left[\frac{\sigma(FI)}{FI} \right]^2 \right\}^{\frac{1}{2}} \quad (\text{B.4})$$

sendo $\sigma(FI)$ a incerteza do fator de intercalibração FI do detector *ex-core* considerado, conforme mostrado na TAB. 3.2;

- a incerteza em DPA^N é dada por

$$\sigma(DPA^N) = \frac{2}{(C_T^N + C_B^N)^2} \left\{ [C_B^N \sigma(C_T^N)]^2 + [C_T^N \sigma(C_B^N)]^2 \right\}^{\frac{1}{2}} \quad (\text{B.5})$$

onde $\sigma(C_T^N)$ é a incerteza da contagem normalizada C_T^N e $\sigma(C_B^N)$ é a incerteza da contagem normalizada C_B^N . As incertezas em DPA^W , DPQ_B e DPQ_T são calculadas de modo similar, considerando, em cada caso, as contagens e os erros dos detectores *ex-core* envolvidos (TAB. 3.5).

APÊNDICE C - Programas para Treinamento das Redes Neurais

As rotinas de treinamento das redes neurais RBF e MLP, para determinação do fator de pico de potência, FP, utilizando as posições das barras de controle e/ou as DPAs e DPQs nos vetores de entrada, foram feitas em linguagem de programação com características próprias do MATLAB, no seu arquivo de comando, ou arquivo M (Dermuth e Beale, 2001).

C.1 Rotina de Treinamento da Rede RBF

```
%=====
% Rede Neural RBF – Rotina de Treinamento para Determinação do FP
%=====
% Limpando Tela e Memória
    clc
    clear all;
    close all;

% Carregando Arquivo Fonte de Dados
    load Tabela_escolhida7.txt
    Tabela_completa = Tabela_escolhida7;
%=====
% Parâmetros para Utilização da Rotina

% Caracterização dos Dados de Entrada

    caso = 1;    % 1, 2, 3, 4, 5, 6    Escolha dos dados de entrada (tipo de utilização)
                                     % 1 - Posição das 4 barras de controle
                                     % 2 – Posição das 4 barras e DPA's
                                     % 3 - DPA's e DPQ's
                                     % 4 - Posição das 3 barras de controle (sem a
                                     %       BS1)
                                     % 5 - Posição de 3 barras, DPA's e DPQ's
```


% 6 - Posição das 4 barras, DPA's e DPQ's

```

=====
% Carregando Arquivo Fonte de Dados
% Escolhendo Entrada para a Rede, a partir do Arquivo de Dados
    if caso == 1    % caso 1 - Problema de determinação do FP a partir de posições das
                   barras de controle
        Entrada = Tabela_completa(:,2:5);
        Saida = Tabela_completa(:,14);
    end

    if caso == 2    % caso 2 - Problema de determinação do FP a partir das posições das
                   4 barras e DPAs
        Entrada1 = Tabela_completa(:,2:5);
        Entrada2 = Tabela_completa(:,10:11);
        Entrada = [Entrada1 Entrada2];
        Saida = Tabela_completa(:,14);
    end

    if caso == 3    % caso 3 - Problema de determinação do FP a partir de DPAs e
                   DPQs
        Entrada = Tabela_completa(:,10:13);
        Saida = Tabela_completa(:,14);
    end

    if caso == 4    % caso 4 - Problema de determinação do FP a partir de posições de 3
                   barras
        Entrada = Tabela_completa(:,3:5);
        Saida = Tabela_completa(:,14);
    end

    if caso == 5    % caso 5 - Problema de determinação do FP a partir de 3 posições de
                   barras, DPAs e DPQs
        Entrada1 = Tabela_completa(:,3:5);
        Entrada2 = Tabela_completa(:,10:13);
        Entrada = [Entrada1 Entrada2];
        Saida = Tabela_completa(:,14);
    end
end

```

```

if caso == 6    % caso 6 - Problema de determinação do FP a partir de 4 posições de
                barras, DPAs e DPQs
    Entrada1 = Tabela_completa(:,2:5);
    Entrada2 = Tabela_completa(:,10:13);
    Entrada = [Entrada1 Entrada2];
    Saida = Tabela_completa(:,14);

end
%-----
    n_dados = size(Entrada, 1);

% Invertendo para Manter Compatibilidade com Rotina de Treinamento
    Entrada = Entrada';
    Saida = Saida';

% Selecionando Porcentagem de Dados de Treinamento e Validação
    n_trein = round(0.8*n_dados);
    n_valid = n_dados - n_trein;
    indice = 1:n_dados;

% Separando Conjunto de Dados de Treinamento X e Saída D
    for i = 1:n_trein
        X(:,i) = Entrada(:, indice(i));
        D(:,i) = Saida(:, indice(i));
    end

% Separando Conjunto de Dados de Validação Xaux e Saída Daux
    for i = 1:n_valid
        Xaux(:, i) = Entrada(:, indice(i+n_trein));
        Daux(:, i) = Saida(:, indice(i+n_trein));
    end
%-----
% Normalização de dados 0 - nenhum; 1 - normalização com prestd
    utilizar_normalizacao = 0;

% Aplicando Transformações nos Dados de Treinamento e Validação
    if utilizar_normalizacao == 1

% Normalizando Dados de Treinamento

```

```

% Prestd – processa o conjunto de treinamento normalizando as entradas e saídas tal que
elas tenham médias zero e desvios padrão 1
    [Xn, meanX, stdX, Dn, meanD, stdD] = prestd(X, D);
    X_orig = X;
    D_orig = D;
    X = Xn;
    D = Dn;

% Normalizando Dados de Validação
    [Xauxn] = trastd(Xaux, meanX, stdX);
    Xaux = Xauxn;

end % Final da Normalização
%-----
% Iniciando e Treinando uma Rede RBF
    goal = 1e-6; % erro mse de treinamento a ser alcançado
    spread = 0.1:0.1:45; % intervalo de abertura dos raios
    max_neuron = 2:1:45; % máximo número de neurônios
    display = 1; % atualização do gráfico de treinamento

% Criando Loop para Escolha de Spread
    n_spread = size(spread, 2); % quantidade dos valores de raios a serem
                                avaliados
    n_neuron = size(max_neuron, 2); % quantidade dos valores de neurônios
                                    máximos a serem avaliados
%-----
% Iniciando Treinamento
    erro_valid_menor = 100000000;

    for i = 1:n_spread % loop para valores de raio
        for j = 1:n_neuron % loop para valores máximos de número de neurônios
            spread1 = spread (i);
            max_neuron1 = max_neuron (j);
            % Chamada de função de treinamento do toolbox MATLAB – Neural Networks
            net = newrb(X, D, goal, spread1, max_neuron1, display);

% Verificando Conjunto Treinamento
    % Calculando Saída
    Y = sim(net, X);

```

```

    % Calculando Erro Treinamento
    E = D - Y;
    Erro_trein = mse(E);          % erros médios quadrados

% Verificando Conjunto Validação
    % Calculando Saída
    Yaux = sim(net, Xaux);

    % Calculando Erro Validação
    Eaux = Daux-Yaux;
    Erro_valid = mse(Eaux);      % erros médios quadrados

% Verificando se a solução é melhor do que as anteriores
    if Erro_valid < erro_valid_menor
        erro_valid_menor = Erro_valid
        net_melhor = net;
        erro_trein_menor = Erro_trein;
        spread_melhor = spread1;
        max_neuron_melhor = max_neuron1;
    end
end
end
%-----
% Recalculando a Saída para a Melhor Solução
    Y = sim(net_melhor, X);
    Yaux = sim(net_melhor, Xaux);
%-----
% Desnormalizando
    if utilizar_normalizacao == 1
        [Y] = poststd(Yn, meanD, stdD);
        [Yaux] = poststd(Yauxn, meanD, stdD);
        D = poststd(D, meanD, stdD);
        % Recalculando o Erro
        erro_valid_menor = mse(Daux-Yaux);
        erro_trein_menor = mse(D - Y);
    end
%-----

```

```

% Calculando o Erro da Melhor Solução da Validação
Ev = (Daux-Yaux)*100;
Ev1 = ((Yaux-Daux)./Daux)*100;
emaev_V = mae(Daux-Yaux) % Erro médio absoluto de validação
emre_V = mae(Ev1) % Erro médio relativo de validação
[Daux' Yaux' Ev1' Ev']

% Calculando o Erro da Melhor Solução do Treinamento
Et = ((Y-D)./D)*100;
Et1 = (D-Y)*100;
emaev_T = mae(D-Y)
emre_T = mae(Et)
[D' Y' Et' Et1']

%-----
% Plotando Resultados
t = 1:n_trein;
v = 1:n_valid;

% Treinamento
figure
plot(t, D, 'ro', t, Y, 'k*')
legend('Resposta desejada', 'Saída da rede')
ylabel('FP');
XLIM([0 46])
YLIM([2.05 2.3])
title('TREINAMENTO');

% Validação
figure
plot(v, Daux, 'ro', v, Yaux, 'k*')
legend('Resposta desejada', 'Saída da rede')
ylabel('FP');
XLIM([0 12])
YLIM([2.05 2.3])
title('VALIDAÇÃO');

```

```

% Coeficientes da Regressão Linear
% Treinamento
    figure;
    [m, b, r] = postreg(Y, D);
    ylabel('FP-RN'); xlabel('FP');
    title('TREINAMENTO');
    XLIM([2.05 2.3])
    YLIM([2.05 2.3])

% Validação
    figure;
    [m1, b1, r1] = postreg(Yaux, Daux);
    ylabel('FP-RN'); xlabel('FP');
    title('VALIDAÇÃO');
    XLIM([2.1 2.3])
    YLIM([2.1 2.3])

%-----
% Imprimindo Valores Interessantes
    fprintf('=====\n');
    fprintf('\t\t\tResultados de treinamento \n\n');
    fprintf('Numero de vetores de treinamento : %i\n',n_trein);
    fprintf('Numero de vetores de validação : %i\n',n_valid);
    fprintf('Erro médio quadrático de treinamento : %i\n',erro_trein_menor);
    fprintf('Erro médio absoluto de treinamento : %i\n',emae_T);
    fprintf('Erro médio relativo de treinamento : %i\n',emre_T);
    fprintf('Erro médio quadrático de validação : %i\n',erro_valid_menor);
    fprintf('Erro médio absoluto de validação : %i\n',emae_V);
    fprintf('Erro médio relativo de validação : %i\n',emre_V);
    fprintf('Melhor valor de spread : %i\n',spread_melhor);
    fprintf('Melhor numero de neurônios na camada oculta : %i\n',max_neuron_melhor);
    fprintf('=====\n');
%-----
% Salvando a Rede
    save caso1_rbf_solmelhor7 net_melhor X Xaux D Daux spread_melhor
max_neuron_melhor erro_trein_menor erro_valid_menor n_trein n_valid
%-----

```

C.2 Rotina de Treinamento da Rede MLP

```

%-----
% Rede Neural MLP – Rotina de Treinamento para Determinação do FP
%=====
% Limpando Tela e Memória
    clc
    clear all;
    close all;

% Carregando Arquivo Fonte de Dados
    load Tabela_escolhida7.txt
    Tabela_completa = Tabela_escolhida7;
%=====
% Parâmetros para Utilização
% Caracterização dos Dados de Entrada

    caso = 1;          % 1, 2 - Escolha dos dados de entrada (tipo de utilização)
                    % 1 – Posição das 4 barras de controle
                    % 2 - DPA's e DPQ's
%-----
% Carregando Arquivo Fonte de Dados

% Escolhendo Entrada para a Rede, a partir do Arquivo de Dados

    if caso == 1      % caso 1 - Problema de determinação do FP a partir das posições
                    % das 4 barras de controle
        Entrada = Tabela_completa(:,2:5);
        Saida = Tabela_completa(:,14);
    end

    if caso == 2      % caso 2 - Problema de Determinação do FP a partir de DPAs e
                    % DPQs
        Entrada = Tabela_completa(:,10:13);
        Saida = Tabela_completa(:,14);
    end
%-----
    n_dados = size(Entrada,1);

```

```

% Invertendo para Manter Compatibilidade com Rotina de Treinamento
    Entrada = Entrada';
    Saida = Saida';

% Selecionando Porcentagem de Dados de Treinamento e Validação
    n_trein = round(0.8*n_dados);
    n_valid = n_dados - n_trein;

    indice = 1:n_dados;

% Separando Conjunto de Dados de Treinamento X e Saída D
    for i = 1:n_trein
        X(:,i) = Entrada(:, indice(i));
        D(:,i) = Saida(:, indice(i));
    end

% Separando Conjunto de Dados de Validação Xaux e Saída Daux
    for i = 1:n_valid
        Xaux(:,i) = Entrada(:, indice(i+n_trein));
        Daux(:,i) = Saida(:, indice(i+n_trein));
    end

%-----
% Normalização de Dados 0 - nenhum; 1 - Normalização com prestd
    utilizar_normalizacao = 0;

% Aplicando Transformações nos Dados de Treinamento e Validação
    if utilizar_normalizacao == 1

% Normalizando Dados de Treinamento
        [Xn, meanX, stdX, Dn, meanD, stdD]= prestd(X, D);
        X_orig = X;
        D_orig = D;
        X = Xn;
        D = Dn;

% Normalizando Dados de Validação
        [Xauxn] = trastd(Xaux, meanX, stdX);
        Xaux = Xauxn;

```



```

end          % Final da Normalização
%-----
% Iniciando uma Rede Feed Foward (MLP)
    n_nodos_hidden = 5;
    n_nodos_out = 1;
    PR = minmax(X);

% Escolhendo Método de Treinamento
% Treinamento com RProp
    net = newff(PR,[n_nodos_hidden n_nodos_out],{'tansig', 'purelin'}, 'trainrp');

% Treinamento com LM
    % net = newff(PR,[n_nodos_hidden n_nodos_out],{'tansig', 'purelin'}, 'trainlm');
%=====
% Loop para Escolha de Solução de Menor Erro de Validação

    n_epocas = 100;          % O número de épocas total será
                            % (n_epocas * net.trainParam.epochs)
                            % Uma rede será testada no conjunto validação a cada
                            % net.trainParam.epochs épocas.

% Inicializações
    erro_trein_menor = 100000000;
    erro_valid_menor = 100000000;

    for i = 1 : n_epocas
% Treinamento da Rede
        net.trainParam.epochs=1000;
        net.trainParam.show=10;
        net.trainParam.goal=0.000001;

        [net,tr,Y,E] = train(net, X, D);

% Resultados do Treinamento
        Erro_trein(i) = mse(E);
%-----
% Verificando Conjunto Validação
% Calculando Saída da Rede
        Yaux = sim(net, Xaux);

% Calculando Erro

```

```

    Eaux = Daux-Yaux;
    Erro_valid(i) = mse(Eaux);

% Teste para Selecionar Nova Solução
    if (erro_valid_menor > Erro_valid(i))
        % Salvar Solução
        net_melhor = net;
        erro_valid_menor = Erro_valid(i);
        erro_trein_menor = Erro_trein(i);
        epoca_melhor = i;
    end    % Final do if
end    % Final do loop total
%-----
% Trabalhando com a Melhor Solução
% Recuperando as saídas desejadas e as saídas da melhor solução - da melhor rede
    Y = sim(net_melhor, X);
    Yaux = sim(net_melhor, Xaux);
%-----
% Desnormalizando
    if utilizar_normalizacao == 1
        Y = poststd(Y, meanD, stdD);
        Yaux = poststd(Yaux, meanD, stdD);
        D = poststd(D, meanD, stdD);

        % Recalculando o Erro
        erro_valid_menor = mse(Daux-Yaux);
        erro_trein_menor = mse(D- Y);
    end
%-----
% Calculando o Erro da Melhor Solução da Validação
    Ev = (Daux-Yaux)*100;
    Ev1 = ((Yaux-Daux)./Daux)*100;
    emae_V = mae(Daux-Yaux)
    emre_V = mae(Ev1)
    [Daux' Yaux' Ev1' Ev']

```

```

% Calculando o Erro da Melhor Solução do Treinamento
    Et = ((Y-D)./D)*100;
    Et1 = (D-Y)*100;
    emae_T = mae(D-Y)
    emre_T = mae(Et)
    [D' Y' Et' Et1']

%-----
% Plotando Resultados

    t = 1:n_trein;
    v = 1:n_valid;
    e = 1:n_epocas;

% Treinamento
    figure
    plot(t, D, 'ro', t, Y, 'k*')
    legend('Resposta desejada', 'Saída da rede')
    ylabel('FP');
    XLIM([0 46])
    YLIM([2.05 2.3])
    title('TREINAMENTO');

% Validação
    figure
    plot(v, Daux, 'ro', v, Yaux, 'k*')
    legend('Resposta desejada', 'Saída da rede')
    ylabel('FP');
    XLIM([0 12])
    YLIM([2.05 2.3])
    title('VALIDAÇÃO');

% Evolução dos Erros de Treinamento e de Validação
    figure
    plot(e, Erro_trein, 'r*', e, Erro_valid, 'b*')
    legend('Erro de treinamento', 'Erro de validação')
    ylabel('MSE');
    title(['Comportamento dos erros de treinamento e validação Época escolhida: ',num2str(epoca_melhor)]);

```

```
% Coeficientes de Regressão Linear
```

```
% Treinamento
```

```
figure;
[m, b, r] = postreg(Y, D);
ylabel('FP-RN'); xlabel('FP');
title('TREINAMENTO');
XLIM([2.05 2.3])
YLIM([2.05 2.3])
```

```
% Validação
```

```
figure;
[m1, b1, r1] = postreg(Yaux, Daux);
ylabel('FP-RN'); xlabel('FP');
title('VALIDAÇÃO');
XLIM([2.05 2.3])
YLIM([2.05 2.3])
```

```
%-----
```

```
% Imprimindo Valores Interessantes
```

```
fprintf('=====\n');
fprintf('\t\t\tResultados de treinamento \n\n');
fprintf('Numero de vetores de treinamento : %i\n',n_trein);
fprintf('Numero de vetores de validacao : %i\n',n_valid);
fprintf('Erro medio quadratico de treinamento : %i\n',erro_trein_menor);
fprintf('Erro medio absoluto de treinamento : %i\n',emae_T);
fprintf('Erro medio relativo de treinamento : %i\n',emre_T);
fprintf('Erro medio quadratico de validacao : %i\n',erro_valid_menor);
fprintf('Erro medio absoluto de validacao : %i\n',emae_V);
fprintf('Erro medio relativo de validacao : %i\n',emre_V);
fprintf('Epoca de menor erro medio quadratico de validacao : %i\n',epoca_melhor);
fprintf('=====\n');
```

```
%-----
```

```
% Salvando Solução
```

```
save caso1_mlp_sol7 net_melhor X Xaux D Daux erro_trein_menor
erro_valid_menor n_trein n_valid epoca_melhor ;
```

```
%-----
```

APÊNDICE D - Aplicação do Método da Parada Antecipada no Treinamento de RN

Neste Apêndice, é apresentado um exemplo do resultado da aplicação do método da parada antecipada no treinamento do conjunto 7. A mesma metodologia foi utilizada no treinamento de todas as redes consideradas neste trabalho.

Na FIG. D.1, é apresentada a evolução dos erros médios quadrados de treinamento e de validação em função do número de épocas, obtidos no treinamento do conjunto 7 com a rede neural MLP. O ponto considerado para o encerramento do treinamento foi determinado utilizando a metodologia da parada antecipada, segundo a qual após cada etapa do treinamento o erro médio quadrado de validação é avaliado e quando seu valor for mínimo o treinamento é interrompido, conforme explicado no item 5.2. Como pode ser visto na figura, o erro médio quadrado do treinamento é grande no início, decresce rapidamente e então continua diminuindo lentamente; ao passo que o erro de validação inicia com um valor máximo, passa por um valor mínimo e depois volta a crescer, conforme o número de épocas aumenta. O treinamento foi encerrado quando o erro médio quadrado de validação era mínimo, $2,486 \times 10^{-5}$, correspondendo a 5000 épocas, ou seja, 5000 apresentações de todo os dados de treinamento.

Os resultados do treinamento e da validação do conjunto 7 estão mostrados nas FIG. D.2 e D.3, nas quais os pequenos círculos mostram os valores desejados do FP e os asteriscos indicam os valores estimados do FP pela rede neural.

A performance da rede treinada foi medida realizando uma regressão linear entre a resposta da rede e as correspondentes saídas. A análise da regressão retorna três parâmetros m , b e R . Os dois primeiros parâmetros correspondem à inclinação e ao intercepto do eixo y , iguais a um e zero para um ajuste perfeito, respectivamente. O terceiro valor é o coeficiente de correlação R do ajuste. Se o valor de R é igual a 1, a correlação entre a saída desejada e a saída da rede é quase perfeita.

Nas FIG. D.4 e D.5, são mostradas as análises de regressão entre as respostas da rede para o conjunto de treinamento e de validação e as correspondentes saídas. Os valores de m , b e R valem 0,984, 0,037 e 0,992 para o treinamento, e 0,978, 0,049 e 0,991

para a validação, respectivamente. Os coeficientes de correlação das retas ajustadas indicam bons ajustes.




FIGURA D.1 - Evolução dos erros médio quadrado de treinamento e de validação usando a rede MLP – conjunto 7.




FIGURA D.2 - Comparação entre os valores desejados do FP e os valores de saída da rede no treinamento com MLP – conjunto 7.




FIGURA D.3 - Comparação entre os valores reais do FP e os valores de saída da rede neural na validação com MLP – conjunto 7.




FIGURA D.4 - Análise de regressão após o treinamento da rede neural MLP - conjunto 7.

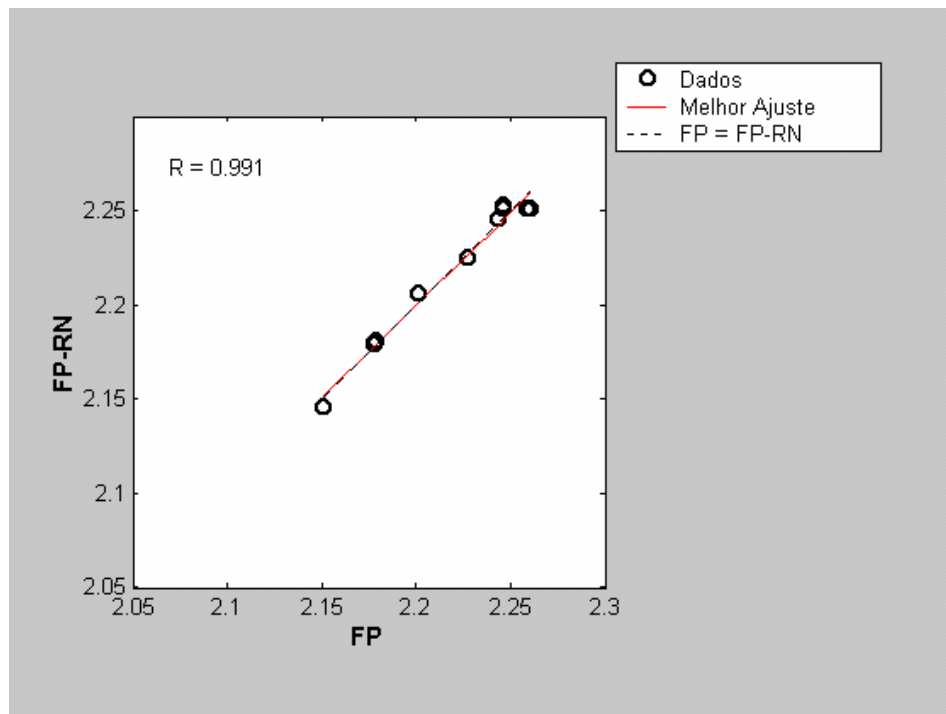


FIGURA D.5 - Análise de regressão após o teste da rede neural MLP – conjunto 7.

APÊNDICE E – Teste de Robustez das Redes RBF e MLP

O teste para avaliação da robustez das redes RBF e MLP consistiu em estimar os valores dos fatores de pico de potência, FP, em todos os estados que formam o subconjunto 7 de validação, utilizando os parâmetros das redes RBF e MLP obtidos no treinamento e considerando, em cada momento, um dos sinais do vetor de entrada, dados pelas Eq. 5.4 e 5.8, como nulo.

As TAB. E.1 e E.2 contêm as matrizes dos centros, raios, bias e pesos que resultaram do treinamento do conjunto 7 com a rede RBF, tendo no vetor de entrada as informações das posições das 4 barras de controle (Eq. 5.4). Tem-se as mesmas informações nas TAB. E.3 e E.4, mas com o vetor de entrada formado pelas 4 posições das barras e as DPA^N e DPA^W (Eq. 5.8).

Nas TAB. E.5 e E.6 são apresentadas as matrizes dos pesos e os bias da camada oculta e da camada de saída, respectivamente, obtidos no treinamento do conjunto 7 com a rede MLP, tendo as posições das 4 barras de controle (Eq. 5.4) no vetor de entrada. Esta rede tem uma camada oculta com 5 neurônios e um na camada de saída.

Nas TAB. E.7 a E.17 são apresentados os resultados finais obtidos nos testes para avaliação da robustez das redes neurais.

TABELA E.5 - Pesos e bias para entrada da camada oculta, obtidos no treinamento do conjunto 7 com a rede MLP, tendo 4 barras de controle como entrada

Matriz dos Pesos e Vetor dos Bias					
Neurônios da Camada Oculta	Matriz dos Pesos de Entrada, W_e, para 5 Neurônios				Vetor Bias Entrada, B_e da C. Oculta
	1	2	3	4	
1	0,0464	0,0452	0,0457	0,0462	-13,6893
2	1,7039	-1,4989	-0,4505	0,3302	0,4815
3	0,5392	0,5535	-0,2840	-0,3297	-4,5896
4	0,0233	0,0251	0,1960	0,2019	-27,3922
5	-0,4105	0,2821	0,0708	-0,0325	5,3843

TABELA E.6 - Pesos e bias para entrada da camada de saída, obtidos no treinamento do conjunto 7 com a rede MLP, tendo 4 barras de controle como entrada

Vetor Linha dos Pesos de Saída, W_s, e Bias de Saída, B_s					
Neurônios da Camada Oculta	1	2	3	4	5
Vetor dos Pesos de Saída, W_s	-0,0612	-0,0220	-0,0008	0,0495	-0,0230
Bias de Saída, B_s	2,1520	-----	-----	-----	-----

TABELA E.7 - Incertezas na estimativa do FP para o estado 2

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	59,82	77,10	67,10	67,10	-----	-----	2,251		-0,44
RBF	59,82	77,10	67,10	67,10	-----	-----	2,251	2,261	-0,44
RBF	59,82	77,10	67,10	67,10	16,01	17,37	2,252		-0,40
MLP	0	77,10	67,10	67,10	-----	-----	2,255		-0,27
RBF	0	77,10	67,10	67,10	-----	-----	2,106	2,261	-6,86
RBF	0	77,10	67,10	67,10	16,01	17,37	2,118		-6,33
MLP	59,82	0	67,10	67,10	-----	-----	2,245		-0,71
RBF	59,82	0	67,10	67,10	-----	-----	2,105	2,261	-6,90
RBF	59,82	0	67,10	67,10	16,01	17,37	2,115		-6,46
MLP	59,82	77,10	0	67,10	-----	-----	2,132		-5,71
RBF	59,82	77,10	0	67,10	-----	-----	2,105	2,261	-6,90
RBF	59,82	77,10	0	67,10	16,01	17,37	2,116		-6,41
MLP	59,82	77,10	67,10	0	-----	-----	2,162		-4,38
RBF	59,82	77,10	67,10	0	-----	-----	2,106	2,261	-6,86
RBF	59,82	77,10	67,10	0	16,01	17,37	2,117		-6,37
RBF	59,82	77,10	67,10	67,10	0	17,37	2,223	2,261	-1,68
RBF	59,82	77,10	67,10	67,10	16,01	0	2,220	2,261	-1,81

TABELA E.8 - Incertezas na estimativa do FP para o estado 11

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	67,10	67,10	59,81	77,10	-----	-----	2,251		-0,35
RBF	67,10	67,10	59,81	77,10	-----	-----	2,255	2,259	-0,18
RBF	67,10	67,10	59,81	77,10	17,38	17,02	2,252		-0,31
MLP	0	67,10	59,81	77,10	-----	-----	2,258		-0,04
RBF	0	67,10	59,81	77,10	-----	-----	2,105	2,259	-6,82
RBF	0	67,10	59,81	77,10	17,38	17,02	2,116		-6,33
MLP	67,10	0	59,81	77,10	-----	-----	2,259		0,00
RBF	67,10	0	59,81	77,10	-----	-----	2,106	2,259	-6,77
RBF	67,10	0	59,81	77,10	17,38	17,02	2,116		-6,33
MLP	67,10	67,10	0	77,10	-----	-----	2,164		-4,21
RBF	67,10	67,10	0	77,10	-----	-----	2,106	2,259	-6,77
RBF	67,10	67,10	0	77,10	17,38	17,02	2,118		-6,24
MLP	67,10	67,10	59,81	0	-----	-----	2,167		-4,07
RBF	67,10	67,10	59,81	0	-----	-----	2,104	2,259	-6,86
RBF	67,10	67,10	59,81	0	17,38	17,02	2,115		-6,38
RBF	67,10	67,10	59,81	77,10	0	17,02	2,222	2,259	-1,64
RBF	67,10	67,10	59,81	77,10	17,38	0	2,223	2,259	-1,59

TABELA E.9 - Incertezas na estimativa do FP para o estado 17

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	67,10	61,01	67,10	77,10	-----	-----	2,252	2,247	0,22
RBF	67,10	61,01	67,10	77,10	-----	-----	2,249		0,09
RBF	67,10	61,01	67,10	77,10	18,30	16,88	2,248		0,05
MLP	0	61,01	67,10	77,10	-----	-----	2,262	2,247	0,67
RBF	0	61,01	67,10	77,10	-----	-----	2,105		-6,32
RBF	0	61,01	67,10	77,10	18,30	16,88	2,115		-5,87
MLP	67,10	0	67,10	77,10	-----	-----	2,264	2,247	0,76
RBF	67,10	0	67,10	77,10	-----	-----	2,106		-6,28
RBF	67,10	0	67,10	77,10	18,30	16,88	2,116		-5,83
MLP	67,10	61,01	0	77,10	-----	-----	2,164	2,247	-3,69
RBF	67,10	61,01	0	77,10	-----	-----	2,106		-6,28
RBF	67,10	61,01	0	77,10	18,30	16,88	2,118		-5,74
MLP	67,10	61,01	67,10	0	-----	-----	2,189	2,247	-2,58
RBF	67,10	61,01	67,10	0	-----	-----	2,105		-6,32
RBF	67,10	61,01	67,10	0	18,30	16,88	2,116		-5,83
RBF	67,10	61,01	67,10	77,10	0	16,88	2,220	2,247	-1,20
RBF	67,10	61,01	67,10	77,10	18,30	0	2,220	2,247	-1,20

TABELA E.10 - Incertezas na estimativa do FP para o estado 24

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	87,10	67,10	67,10	55,01	-----	-----	2,225	2,228	-0,14
RBF	87,10	67,10	67,10	55,01	-----	-----	2,226		-0,09
RBF	87,10	67,10	67,10	55,01	15,27	16,06	2,225		-0,14
MLP	0	67,10	67,10	55,01	-----	-----	2,169	2,228	-2,65
RBF	0	67,10	67,10	55,01	-----	-----	2,105		-5,52
RBF	0	67,10	67,10	55,01	15,27	16,06	2,116		-5,03
MLP	87,10	0	67,10	55,01	-----	-----	2,174	2,228	-2,42
RBF	87,10	0	67,10	55,01	-----	-----	2,106		-5,48
RBF	87,10	0	67,10	55,01	15,27	16,06	2,119		-4,89
MLP	87,10	67,10	0	55,01	-----	-----	2,164	2,228	-2,87
RBF	87,10	67,10	0	55,01	-----	-----	2,105		-5,52
RBF	87,10	67,10	0	55,01	15,27	16,06	2,113		-5,16
MLP	87,10	67,10	67,10	0	-----	-----	2,164	2,228	-2,87
RBF	87,10	67,10	67,10	0	-----	-----	2,105		-5,52
RBF	87,10	67,10	67,10	0	15,27	16,06	2,115		-5,07
RBF	87,10	67,10	67,10	55,01	0	16,06	2,205	2,228	-1,03
RBF	87,10	67,10	67,10	55,01	15,27	0	2,201	2,228	-1,21

TABELA E.11 - Incertezas na estimativa do FP para o estado 26

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	77,10	67,10	58,96	67,10	-----	-----	2,246	2,243	0,13
RBF	77,10	67,10	58,96	67,10	-----	-----	2,242		-0,05
RBF	77,10	67,10	58,96	67,10	16,86	16,37	2,241		-0,09
MLP	0	67,10	58,96	67,10	-----	-----	2,186	2,243	-2,54
RBF	0	67,10	58,96	67,10	-----	-----	2,105		-6,15
RBF	0	67,10	58,96	67,10	16,86	16,37	2,116		-5,66
MLP	77,10	0	58,96	67,10	-----	-----	2,192	2,243	-2,27
RBF	77,10	0	58,96	67,10	-----	-----	2,106		-6,11
RBF	77,10	0	58,96	67,10	16,86	16,37	2,118		-5,57
MLP	77,10	67,10	0	67,10	-----	-----	2,164	2,243	-3,52
RBF	77,10	67,10	0	67,10	-----	-----	2,106		-6,11
RBF	77,10	67,10	0	67,10	16,86	16,37	2,116		-5,66
MLP	77,10	67,10	58,96	0	-----	-----	2,164	2,243	-3,52
RBF	77,10	67,10	58,96	0	-----	-----	2,104		-6,20
RBF	77,10	67,10	58,96	0	16,86	16,37	2,115		-5,71
RBF	77,10	67,10	58,96	67,10	0	16,37	2,215	2,243	-1,25
RBF	77,10	67,10	58,96	67,10	16,86	0	2,214	2,243	-1,29

TABELA E.12 - Incertezas na estimativa do FP para o estado 29

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	61,02	67,10	77,10	67,10	-----	-----	2,251	2,247	0,18
RBF	61,02	67,10	77,10	67,10	-----	-----	2,248		0,05
RBF	61,02	67,10	77,10	67,10	16,87	17,51	2,248		0,05
MLP	0	67,10	77,10	67,10	-----	-----	2,262	2,247	0,67
RBF	0	67,10	77,10	67,10	-----	-----	2,106		-6,28
RBF	0	67,10	77,10	67,10	16,87	17,51	2,117		-5,79
MLP	61,02	0	77,10	67,10	-----	-----	2,264	2,247	0,76
RBF	61,02	0	77,10	67,10	-----	-----	2,104		-6,36
RBF	61,02	0	77,10	67,10	16,87	17,51	2,115		-5,87
MLP	61,02	67,10	0	67,10	-----	-----	2,164	2,247	-3,69
RBF	61,02	67,10	0	67,10	-----	-----	2,105		-6,32
RBF	61,02	67,10	0	67,10	16,87	17,51	2,116		-5,83
MLP	61,02	67,10	77,10	0	-----	-----	2,162	2,247	-3,78
RBF	61,02	67,10	77,10	0	-----	-----	2,106		-6,28
RBF	61,02	67,10	77,10	0	16,87	17,51	2,118		-5,74
RBF	61,02	67,10	77,10	67,10	0	17,51	2,223	2,247	-1,07
RBF	61,02	67,10	77,10	67,10	16,87	0	2,218	2,247	-1,29

TABELA E.13 - Incertezas na estimativa do FP para o estado 37

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	67,10	100,00	52,68	67,10	-----	-----	2,206	2,202	0,18
RBF	67,10	100,00	52,68	67,10	-----	-----	2,197		-0,23
RBF	67,10	100,00	52,68	67,10	17,52	16,63	2,198		-0,18
MLP	0	100,00	52,68	67,10	-----	-----	2,173	2,202	-1,32
RBF	0	100,00	52,68	67,10	-----	-----	2,106		-4,36
RBF	0	100,00	52,68	67,10	17,52	16,63	2,119		-3,77
MLP	67,10	0	52,68	67,10	-----	-----	2,167	2,202	-1,59
RBF	67,10	0	52,68	67,10	-----	-----	2,105		-4,41
RBF	67,10	0	52,68	67,10	17,52	16,63	2,116		-3,91
MLP	67,10	100,00	0	67,10	-----	-----	2,162	2,202	-1,82
RBF	67,10	100,00	0	67,10	-----	-----	2,104		-4,45
RBF	67,10	100,00	0	67,10	17,52	16,63	2,114		-4,00
MLP	67,10	100,00	52,68	0	-----	-----	2,162	2,202	-1,82
RBF	67,10	100,00	52,68	0	-----	-----	2,106		-4,36
RBF	67,10	100,00	52,68	0	17,52	16,63	2,113		-4,04
RBF	67,10	100,00	52,68	67,10	0	16,63	2,179	2,202	-1,05
RBF	67,10	100,00	52,68	67,10	17,52	0	2,177	2,202	-1,14

TABELA E.14 - Incertezas na estimativa do FP para o estado 40

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	100,00	53,30	100,00	53,30	-----	-----	2,179	2,178	0,05
RBF	100,00	53,30	100,00	53,30	-----	-----	2,179		0,05
RBF	100,00	53,30	100,00	53,30	11,90	14,38	2,176		-0,09
MLP	0	53,30	100,00	53,30	-----	-----	2,262	2,178	3,86
RBF	0	53,30	100,00	53,30	-----	-----	2,105		-3,35
RBF	0	53,30	100,00	53,30	11,90	14,38	2,114		-2,94
MLP	100,00	0	100,00	53,30	-----	-----	2,261	2,178	3,81
RBF	100,00	0	100,00	53,30	-----	-----	2,105		-3,35
RBF	100,00	0	100,00	53,30	11,90	14,38	2,115		-2,89
MLP	100,00	53,30	0	53,30	-----	-----	2,164	2,178	-0,64
RBF	100,00	53,30	0	53,30	-----	-----	2,106		-3,31
RBF	100,00	53,30	0	53,30	11,90	14,38	2,114		-2,94
MLP	100,00	53,30	100,00	0	-----	-----	2,162	2,178	-0,74
RBF	100,00	53,30	100,00	0	-----	-----	2,105		-3,35
RBF	100,00	53,30	100,00	0	11,90	14,38	2,115		-2,89
RBF	100,00	53,30	100,00	53,30	0	14,38	2,166	2,178	-0,55
RBF	100,00	53,30	100,00	53,30	11,90	0	2,176	2,178	-0,09

TABELA E.15 - Incertezas na estimativa do FP para o estado 43

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	53,05	100,00	53,05	100,00	-----	-----	2,180	2,178	0,09
RBF	53,05	100,00	53,05	100,00	-----	-----	2,179		0,05
RBF	53,05	100,00	53,05	100,00	17,48	14,78	2,178		0,00
MLP	0	100,00	53,05	100,00	-----	-----	2,259	2,178	3,72
RBF	0	100,00	53,05	100,00	-----	-----	2,105		-3,35
RBF	0	100,00	53,05	100,00	17,48	14,78	2,115		-2,89
MLP	53,05	0	53,05	100,00	-----	-----	2,264	2,178	3,95
RBF	53,05	0	53,05	100,00	-----	-----	2,105		-3,35
RBF	53,05	0	53,05	100,00	17,48	14,78	2,114		-2,94
MLP	53,05	100,00	0	100,00	-----	-----	2,160	2,178	-0,83
RBF	53,05	100,00	0	100,00	-----	-----	2,105		-3,35
RBF	53,05	100,00	0	100,00	17,48	14,78	2,115		-2,89
MLP	53,05	100,00	53,05	0	-----	-----	2,162	2,178	-0,74
RBF	53,05	100,00	53,05	0	-----	-----	2,106		-3,31
RBF	53,05	100,00	53,05	0	17,48	14,78	2,114		-2,94
RBF	53,05	100,00	53,05	100,00	0	14,78	2,162	2,178	-0,74
RBF	53,05	100,00	53,05	100,00	17,48	0	2,164	2,178	-0,64

TABELA E.16 - Incertezas na estimativa do FP para o estado 46

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	53,23	100,00	100,00	53,23	-----	-----	2,180	2,179	0,05
RBF	53,23	100,00	100,00	53,23	-----	-----	2,181		0,09
RBF	53,23	100,00	100,00	53,23	14,10	17,78	2,176		-0,14
MLP	0	100,00	100,00	53,23	-----	-----	2,259	2,179	3,67
RBF	0	100,00	100,00	53,23	-----	-----	2,105		-3,40
RBF	0	100,00	100,00	53,23	14,10	17,78	2,115		-2,94
MLP	53,23	0	100,00	53,23	-----	-----	2,264	2,179	3,90
RBF	53,23	0	100,00	53,23	-----	-----	2,104		-3,44
RBF	53,23	0	100,00	53,23	14,10	17,78	2,114		-2,98
MLP	53,23	100,00	0	53,23	-----	-----	2,162	2,179	-0,78
RBF	53,23	100,00	0	53,23	-----	-----	2,104		-3,44
RBF	53,23	100,00	0	53,23	14,10	17,78	2,114		-2,98
MLP	53,23	100,00	100,00	0	-----	-----	2,160	2,179	-0,87
RBF	53,23	100,00	100,00	0	-----	-----	2,105		-3,40
RBF	53,23	100,00	100,00	0	14,10	17,78	2,115		-2,94
RBF	53,23	100,00	100,00	53,23	0	17,78	2,164	2,179	-0,69
RBF	53,23	100,00	100,00	53,23	14,10	0	2,160	2,179	-0,87

TABELA E.17 - Incertezas na estimativa do FP para o estado 54

Rede	BS1	BS2	BC1	BC2	DPA ^N	DPA ^W	FP ^{RN}	FP	(FP ^{RN} -FP)/FP (%)
MLP	87,10	87,10	55,50	55,50	-----	-----	2,146	2,151	-0,23
RBF	87,10	87,10	55,50	55,50	-----	-----	2,152		0,05
RBF	87,10	87,10	55,50	55,50	15,70	15,77	2,152		0,05
MLP	0	87,10	55,50	55,50	-----	-----	2,162	2,151	0,51
RBF	0	87,10	55,50	55,50	-----	-----	2,105		-2,14
RBF	0	87,10	55,50	55,50	15,70	15,77	2,118		-1,53
MLP	87,10	0	55,50	55,50	-----	-----	2,164	2,151	0,60
RBF	87,10	0	55,50	55,50	-----	-----	2,105		-2,14
RBF	87,10	0	55,50	55,50	15,70	15,77	2,118		-1,53
MLP	87,10	87,10	0	55,50	-----	-----	2,164	2,151	0,60
RBF	87,10	87,10	0	55,50	-----	-----	2,102		-2,28
RBF	87,10	87,10	0	55,50	15,70	15,77	2,110		-1,91
MLP	87,10	87,10	55,50	0	-----	-----	2,207	2,151	2,60
RBF	87,10	87,10	55,50	0	-----	-----	2,103		-2,23
RBF	87,10	87,10	55,50	0	15,70	15,77	2,111		-1,86
RBF	87,10	87,10	55,50	55,50	0	15,77	2,144	2,151	-0,33
RBF	87,10	87,10	55,50	55,50	15,70	0	2,142	2,151	-0,42

APÊNDICE F – Implementação em Sistema de Proteção de Reatores de Potência

A seguir tem-se as operações matriciais necessárias para estimar os fatores de pico de potência, utilizando os parâmetros das redes RBF e MLP treinadas.

F.1 Determinação do FP com a Rede Neural RBF

Tomando os parâmetros da rede neural RBF obtidos no treinamento, como por exemplo os dados apresentados nas TAB. E.1 e E.2, tem-se que o fator de pico de potência, FP, é obtido a partir das seguintes operações:

$$\mathbf{S} = \|\| \mathbf{C} - \mathbf{X} \|\| \mathbf{R} \quad (\text{F.1})$$

onde S é um vetor coluna resultante da operação acima, C é a matriz dos centros, R é o vetor coluna dos raios e X é o vetor coluna de entrada, contendo por exemplo, as posições das 4 barras de controle:

$$\mathbf{X} = \begin{bmatrix} \text{BS1} \\ \text{BS2} \\ \text{BC1} \\ \text{BC2} \end{bmatrix}$$

O vetor coluna Y é a saída dos neurônios da camada oculta e é dado por:

$$\mathbf{Y} = \exp(-\mathbf{S})^2. \quad (\text{F.2})$$

Finalmente, FP é obtido da multiplicação do vetor linha contendo os pesos, \mathbf{W}_s , pelas saídas dos neurônios da camada oculta Y, somado ao bias, \mathbf{B}_s , aplicado à saída dos sinais dos neurônios da camada oculta:

$$\text{FP} = \mathbf{W}_s \mathbf{Y} + \mathbf{B}_s. \quad (\text{F.3})$$

F.2 Determinação do FP com a Rede Neural MLP

Tomando os parâmetros da rede neural tipo MLP treinada, dados, por exemplo, nas TAB. E.5 e E.6, o fator de pico de potência, FP, é obtido a partir das seguintes operações matriciais:

$$\mathbf{S} = \mathbf{W}_e \mathbf{X} + \mathbf{B}_e \quad (\text{F.4})$$

$$\mathbf{Y} = \tanh(\mathbf{S}) \quad (\text{F.5})$$

$$\text{FP} = \mathbf{W}_s \mathbf{Y} + \mathbf{B}_s \quad (\text{F.6})$$

onde \mathbf{X} é o vetor coluna de entrada contendo, por exemplo, as posições das 4 barras de controle; \mathbf{W}_e é a matriz de pesos e \mathbf{B}_e é o vetor coluna de bias de entrada; e \mathbf{S} é o vetor coluna dos sinais dos neurônios da camada oculta. O FP é determinado multiplicando-se o vetor coluna de saídas dos neurônios da camada oculta, \mathbf{Y} , pelo vetor linha contendo os pesos, \mathbf{W}_s , somado ao bias \mathbf{B}_s , aplicado à saída dos sinais dos neurônios da camada oculta.

REFERÊNCIAS BIBLIOGRÁFICAS

ACCORSI, R.; MARSEGUERRA, M.; PADOVANI, E.; ZIO, E. Neural estimation of first-order sensitivity coefficients: application to the control of a simulated pressurized water reactor. *Nucl. Sci. Eng.*, v. 132, n. 3, p. 326-336, 1999.

ANSI/ANS-10.4. *Guidelines for the verification and validation of scientific and engineering computer programs for the nuclear industry*. 1987, Rev. 1998.

ARAGONÉS, J.M.; AHNERT, C.; CABELLOS, O. Methods and performance of the three-dimensional pressurized water reactor core dynamics SIMTRAN on-line code. *Nucl. Sci. Eng.*, v. 124, p. 111-124, 1996.

BARHEN, J. et al. **The HAMMER code system**. Technion, EPRI-NP-565, 1978.

BATISTA FILHO, B.D. Redes neurais artificiais na engenharia nuclear (partes 1 e 2). In: ENCONTRO NACIONAL DE FÍSICA DE REATORES E TERMO-HIDRÁULICA, 13, 2002, Rio de Janeiro. *Anais ...* Rio de Janeiro: ABEN, 2002. 1 CD-ROM.

BELL, G.I.; GLASSTONE, S. *Nuclear reactor theory*. New York, N.Y.: Van Nostrand Reinhold, 1970.

BOMAN, L.H.; CHELEMER, H.; DZENIS, E.A. Thermal-hydraulic methods for PWR DNB criterion evaluations. *Trans. Am. Nucl. Soc.*, v. 38, p. 738-739, 1981.

BORGES, J.B. Determinação da resposta dos detectores externos da faixa de potência de ANGRA 1 em função da assimetria axial de fluxo neutrônico. In: CONGRESSO GERAL DE ENERGIA NUCLEAR, 2, 1988, Rio de Janeiro. *Anais ...* Rio de Janeiro: ABEN, 1988. p. 265-272.

BOROUSHAKI, M.; GHOFrani, M.B.; LUCAS, C.; YAZDANPANAH, M.J.; SADATI, N. Identification and control of a nuclear reactor core (VVER) using recurrent neural networks and fuzzy systems. *IEEE Trans. Nucl. Sci.*, v. 50, n. 1, p. 159-174, 2003.

BOROUSHAKI, M.; GHOFrani, M.B.; LUCAS, C.; YAZDANPANAH, M.J.; SADATI, N. Axial offset control of PWR nuclear reactor core using intelligent techniques. *Nucl. Eng. Design*, v. 227, p. 285-300, 2004.

BRAGA, A.P.; LUDERMIR, T.B.; CARVALHO, A.C.P.L.F. *Redes Neurais Artificiais: Teoria e Aplicações*. Rio de Janeiro, LTC, 2000.

CHIU, C. An advanced methodology for on-line protection against DNB. *Trans. Am. Nucl. Soc.*, v. 39, p. 1028-1029, 1981.

CRACIUNESCU, T. A neural network model for the tomographic analysis of irradiated nuclear fuel rods. *Nucl. Technol.*, v. 146, n. 1, p. 65-71, 2004.

CRUMP, M.W.; LEE, J.C. Calculation of spatial weighting functions for excore neutron detectors. *Nucl. Technol.*, v. 41, n. 1, p. 87-96, 1978.

DERMUTH, H.; BEALE, M. *Neural Network toolbox user's guide – for use with MATLAB*. Massachusetts: The MathWorks Inc., 2001.

DIO, W.-H.; GRUEN, A. Incore instrumentation systems for PWR core control and protection. Proceedings of a Specialists Meeting on: In: CORE INSTRUMENTATION AND REACTOR ASSESSMENT, June 7-10, 1988, Cadarache. *Proceedings...* France: 1988.

DUDERSTADT, J.J.; HAMILTON, L.J. *Nuclear reactor analysis*. New York, N.Y.: J. Wiley & Sons, 1976.

ERDOGAN, A.; GEÇKINLI, M. A PWR reload optimisation code (Xcore) using artificial neural networks and genetic algorithms. *Ann. Nucl. Energy*, v. 30, n. 1, p. 35-53, 2003.

FARIA, E.F.; PEREIRA, C. Nuclear fuel loading pattern optimization using a neural network. *Ann. Nucl. Energy*, v. 30, n. 5, p. 603-613, 2003.

FOWLER, T.B.; VONDY, D.R.; CUNNINGHAM, G.W. **Nuclear reactor core analysis code: CITATION**. Rev. 2. Oak Ridge, TN: Oak Ridge National Laboratory, 1971. (ORNL-2496).

GARIS, N.S.; PÁZSIT, I.; SANDBERG, U.; ANDERSSON, T. Determination of PWR control rod position by core physics and neural network methods. *Nucl. Technol.*, v. 123, p. 278-295, 1998.

GUANGHUI, S.; FUKUDA, K.; MORITA, K.; PIDDUCK, M.; JIA, D.; MATSUMOTO, T.; AKASAKA, R. Applications of artificial neural network for the prediction of flow boiling curves. *J. Nucl. Sci. Technol.*, v. 39, n. 11, p. 1190-1198, 2002.

GUANGHUI, S.; MORITA, K.; FUKUDA, K.; PIDDUCK, M.; DOUNAN, J.; MIETTINEN, J. Analysis of the critical heat flux in round vertical tubes under low pressure and flow oscillation conditions. Applications of artificial neural network. *Nucl. Eng. Design*, v. 220, n. 1, p. 17-35, 2003.

HAYKIN, S. *Neural networks – a comprehensive foundation*. Upper Saddle River: Prentice-Hall, 1999.

HOLLOWACH, M.J.; HOCHREITER, L.E.; CHEUNG, F.-B. Critical heat flux during reflood transients in small-hydraulic-diameter geometries. *Nucl. Technol.*, v.140, n.1, p. 18-27, 2002.

IKONOMOPOULOS, A., VAN DER HAGEN, T. H. J. J. A novel signal validation method applied to a stochastic process. *Ann. Nucl. Energy*, v. 24, n. 13, p. 1057-1067, 1997.

IPEN. INSTITUTO DE PESQUISAS ENERGÉTICAS E NUCLEARES. *Especificação técnica para o projeto nuclear da unidade crítica*. Rel. n. R10-IP3-213PR-4EN-001/3-RTF. São Paulo, 17 agosto, 1988.

- KIM, H.-C.; CHANG, S.H. Development of a back propagation network for one-step transient DNBR calculations. *Ann. Nucl. Energy*, v. 24, n. 17, p. 1437-1446, 1997.
- KIM, H.G.; CHANG, S.H.; LEE, B.H. Pressurized water reactor core parameter prediction using an artificial neural network. *Nucl. Sci. Eng.*, v. 113, p. 70-76, 1993.
- KIM, H.-K.; LEE, S.-H. Neural network model for estimating departure from nucleate boiling performance of a pressurized water reactor core. *Nucl. Technol.*, v. 101, p. 111-122, 1993.
- KIM, U.-S.; SEONG, P.-H. Optimization of the worth shape of axially variable strength control rods with simulation optimization methodology for the power maneuvering of pressurized water reactors. *Nucl. Eng. Design*, v. 225, p. 27-35, 2003 a.
- KIM, U.-S.; SEONG, P.-H. Development and application of axially variable strength control rods for the power maneuvering of pressurized water reactors. *Nucl. Technol.*, v. 141, p. 157-166, 2003 b.
- KNOLL, G.F. *Radiation detection and measurement*. New York, N.Y.: J. Wiley & Sons, 1979.
- KOSTIC, L. Monitoring of the temperature reactivity coefficient at the PWR nuclear power plant. *Ann. Nucl. Energy*, v. 24, n. 1, p. 55-64, 1997.
- KUEHNEL, K.; RICHTER, K.-D.; DRESCHER, G. High local power densities permissible at SIEMENS pressurized water reactors. *Nucl. Technol.*, v. 137, n. 2, p. 73-83, 2002.
- LEE, G.; CHANG, S. H. Radial basis function networks applied to DNBR calculation in digital core protection systems. *Ann. Nucl. Energy*, v. 30, p. 1561-1572, 2003.
- LEGER, R.P.; GARLAND, Wm.J.; POEHLMAN, W.F.S. Fault detection and diagnosis using statistical control charts and artificial neural networks. In: 19 CANADIAN NUCLEAR SOCIETY SIMULATION SYMPOSIUM, October 16-17, 1995, Hamilton. *Proceedings...* Canada: 1995.
- LIN, C.; SHEN, C-M. Neurocontrol of pressurized water reactors in load-follow operations. *Nucl. Technol.*, v. 132, n. 3, p. 389-402, 2000.
- LINDÉN, P.; PÁZSIT, I. Study of the possibility of determining mass flow of water from neutron activation measurements with flow simulations and neural networks. *Kernteknik*, v. 63, n. 4, p. 188-198, 1998.
- LOMBARDI, C.; MAZZOLA, A. Prediction of two-phase mixture density using artificial neural networks. *Ann. Nucl. Energy*, v. 24, n. 17, p. 1373-1387, 1997.
- MAIORINO, J.R. et al. Projeto nuclear da unidade crítica IPEN/MB-01. In: ENCONTRO NACIONAL DE FÍSICA DE REATORES E TERMO-HIDRÁULICA, 7, 1989, Recife. *Anais...* Pernambuco: Editora Universitária UFPE, 1989. v. 1. p. 311-323.
- MARSEGUERRA, M.; RICOTTI, M.E.; ZIO, E. Neural network-based fault detections in a pressurized water reactor pressurizer. *Nucl. Sci. Eng.*, v. 124, p. 339-348, 1996.

MATSUMOTO, J.; SEKI, K.; KOMANO, Y. Analytical evaluation of the uncertainty of on-line axial Power distribution measurement with the four-section ex-core detector. In: IN-CORE INSTRUMENTATION AND REACTOR CORE ASSESSMENT, October 16-17, 1996, Japan. *Proceedings...* Paris, France: OECD, 1997. p. 47-56.

McFARLANE, A.F. Physics of operating pressurized water reactors. *Nucl. Appl. Techno.*, v. 9, p. 634-639, 1970.

MEYER, C.E.; BENNETT, C.L.; HILL, D.J.; DZIKOWSKI, K.J. Improved load follow strategy for return-to-power capability. *Nucl. Technol.*, v. 41, n. 27, p. 27-35, 1978.

MIRANDA, A.F.; MOREIRA, J.M.L. Mapeamento do fluxo de nêutrons no reator IPEN/MB-01 com câmara de fissão miniatura, In: ENCONTRO NACIONAL DE FÍSICA DE REATORES E TERMO-HIDRÁULICA, 11, 1997, Poços de Caldas, MG. *Anais ...* Minas Gerais: ABEN, 1997. 1 CD-ROM.

MOREIRA, J.M.L.; SOUZA, R.M.G.P. Determinação da densidade de potência local utilizando sinais da instrumentação nuclear. Relatório Técnico Interno, CTMSP, ver. 01, maio de 2001.

MOREIRA, J.M.L.; SOUZA, R.M.G.P. Improving the peak power density estimation for the DNBR trip signal utilizing out-of-core detectors. In: INTERNATIONAL SYMPOSIUM ON NUCLEAR POWER PLANT LIFE MANAGEMENT, Nov., 4-8, 2002, Budapest, Hungary. *Proceedings...* Vienna: IAEA, 2002. 21/CD-ROM.

NA, M.G.; SHIN, S.H.; LEE, S.M.; JUNG, D.W.; LEE, K.; LEE, Y.J. Estimation of axial DNBR distribution at the hot pin position of a reactor core using fuzzy neural networks. *J. of Nucl. Sci. and Technol.*, v. 41, n. 8, p. 817-826, 2004.

NA, M.G.; UPADHYAYA, B.R. A neuro-fuzzy controller for axial power distribution in nuclear reactors. *IEEE Trans. Nucl. Sci.*, v. 45, n. 1, p. 59-67, 1998.

NA, M.G.; YANG, W.S.; CHOI, H. Pin power reconstruction for CANDU reactors using a neuro-fuzzy inference system. *IEEE Trans. Nucl. Sci.*, v. 48, n. 2, p. 194-201, 2001.

NABESHIMA, K.; SUZUDO, T.; SUZUKI, K.; TÜRKAN, E. Real-time nuclear power plant monitoring with neural network. *J. Nucl. Sci. Technol.*, v. 35, n. 2, p. 93-100, 1998.

ORTIZ, J.J.; REQUENA, I. Using neural networks to predict core parameters in a boiling water reactor. *Nucl. Sci. Eng.*, v. 143, n. 3, p. 254-267, 2003.

ORTIZ, J.J.; REQUENA, I. Using a multi-state recurrent neural network to optimize loading patterns in BWRs. *Ann. Nucl. Energy*, v. 31, n. 7, p. 789-803, 2004.

PÁZSIT, I.; GARIS, N.S. On the neutron noise diagnostics of pressurized water reactor control rod vibrations - IV: application of neural networks. *Nucl. Sci. Eng.*, v. 124, p. 167-177, 1996.

PÁZSIT, I.; KITAMURA, M. The role of neural networks in reactor diagnostics and control. *Adv Nucl. Sci. Technol.*, v. 24, p. 95-130, 1996.

REIFMAN, J. Survey of artificial intelligence methods for detection and identification of component faults in nuclear power plants. *Nucl. Technol.*, v. 119, n. 1, p. 76-97, 1997.

SADIGHI, M.; SETAYESHI, S.; SALEHI, A.A. Neutron flux flattening in PWRs using neural networks in fuel management. *IEEE Trans. Nucl. Sci.*, v. 49, n. 3, p. 1574-1578, 2002.

SAKAMOTO, Y.; ARAKI, T.; YAMAMOTO, F. Evaluation of reactivity and Xe behavior during daily load following operation. *J. Nucl. Sci. Technol.*, v. 29, n. 2, p. 161-174, 1992.

SENGLER, G.; MOURLEVAT, J.L. Average incore axial power distribution measurement by a multi excore detector. In: IAEA – NPPCI SPECIALISTS’ MEETING ON NEW INSTRUMENTATION OF WATER COOLED REACTORS, April 23-25, 1985, Dresden, German Democratic Republic. *Proceedings...* Vienna: IAEA, 1985. p. 33-54.

SEON, Y.; CHA, C.K.H.; PARK, M.G.; LEE, C.S. Predictive mathematical modeling for excore neutron detectors using a neural network. In: PHYSOR 2002, October 7-10, 2002, Seoul, Korea. *Proceedings...* Seoul: 2002.

SEONG, S.-H.; PARK, H.-Y.; KIM, D.-H.; SUH, Y.-S.; HUR, S.; KOO, I.-S. Development of fast-running simulation methodology using neural networks for load follow operation. *Nucl. Sci. Eng.*, v. 141, n.1, p. 66-77, 2002.

SIPUSH, P.J.; KERR, R.A.; GINSBERG, A.P.; MORITA, T.; SCHERPEREEL, L.R. Load – follow demonstrations employing constant axial offset power – distribution control procedures. *Nucl. Technol.*, v. 31, n. 12, p. 12-31, 1976.

SOUZA, R.M.G.P.; MOREIRA, J.M.L. Determinação do fator de pico utilizando sinais de detectores *out-of-core* em reator de pequeno porte. In: ENCONTRO NACIONAL DE FÍSICA DE REATORES E TERMO-HIDRÁULICA, 13/INTERNATIONAL NUCLEAR ATLANTIC CONFERENCE, 2002, Rio de Janeiro. *Anais ...* Rio de Janeiro: ABEN, 2002 a. 1 CD-ROM.

SOUZA, R.M.G.P.; MOREIRA, J.M.L. Determinação do fator de pico utilizando sinais de detectores *out-of-core* em reator de pequeno porte. *Revista Brasileira de Pesquisa e Desenvolvimento* - Research and Development Brazilian Journal, v. 4, n. 2, p. 106-111, setembro 2002 b.

SOUZA, R.M.G.P.; MOREIRA, J.M.L. Determinação do fator de pico utilizando sinais de detectores *out-of-core* em reatores navais. *Pesquisa Naval*. - Suplemento Especial da Revista Marítima Brasileira, n. 16, p. 257-268, 2003.

SOUZA, R.M.G.P.; MOREIRA, J.M.L. Power peak factor for protection systems – experimental data for developing a correlation. *Ann. Nucl. Energy*. Artigo em fase de publicação, 2005 a.

SOUZA, R.M.G.P.; MOREIRA, J.M.L. Neural network correlation for power peak factor estimation. *Ann. Nucl. Energy*. Artigo em fase de publicação, 2005 b.

- STACEY, W. M. *Nuclear reactor physics*. New York, N.Y.: John Wiley & Sons, 2001. p. 295.
- SU, G.; FUKUDA, K.; JIA, D.; MORITA, K. Application of an artificial neural network in reactor thermohydraulic. Problem: prediction of critical heat flux. *Journal Nucl. Sci. Technol.*, v. 39, n. 5, p. 564-571, 2002.
- TAMBOURATZIS, T.; ANTONOPOULOS-DOMIS, M. On-line stability monitoring of BWR's using artificial neural networks. *Ann. Nucl. Energy*, v. 26, p. 1287-1302, 1999.
- TSOUKALAS, L.H.; UHRIG, R.E. *Fuzzy and neural approaches in engineering*. New York, N.Y.: J. Wiley & Sons, 1997.
- TSUKUDA, Y.; KONO, N.; AKIYAMA, Y.; HORI, K.; SUEMURA, T. Post DNB heat transfer experiments for PWR fuel assemblies. *J. Nucl. Sci. Technol.*, v. 40, n. 10, p. 886-894, 2003.
- ULUYOL, Ö.; RAGHEB, M.; TSOUKALAS, L. Neural network with local memory for nuclear reactor power level control. *Nucl. Technol.*, v. 133, n. 2, p. 213-228, 2001.
- USNRC. US Nuclear Regulatory Commission. *Standard technical specification, Westinghouse Plants, bases*. Section 3.2 – power distribution limits. Rev. 1. v. 2, 1995 (NUREG-1431).
- USNRC. US Nuclear Regulatory Commission. Regulatory guide 1.105 - *Setpoints for the safety related instrumentation*. Rev. 3., 1999.
- WANG, Y.; LI, F.; LUO, Z.; HAN, S. On-line monitoring the incore power distribution by using excore ion-chambers. *Nucl. Eng. Design*, v. 225, p. 315-326, 2003.
- WASSERMAN, P.D. *Advanced Methods in Neural Computing*. Reinhold, Van Nostrand, 1993.
- YAMAMOTO, A. Application of neural network for loading pattern screening of in-core optimization calculations. *Nucl. Technol.*, v. 144, n. 1, p. 63-75, 2003.
- ZIVER, A.K.; PAIN, C.C.; CARTER, J.N.; OLIVEIRA, C.R.E.; GODDARD, A.J.H.; OVERTON, R.S. Genetic algorithms and artificial neural networks for loading pattern optimisation of advanced gas-cooled reactors. *Ann. Nucl. Energy*, v. 31, n. 4, p. 431-457, 2004.