

CLASSIFICAÇÃO DE TRANSIENTES DE REATOR IRIS UTILIZANDO MAPAS AUTO-ORGANIZÁVEIS CONSTRUÍDOS EM PLATAFORMA LIVRE

Waldemar Doraskevičius Jr.¹ e Benedito Dias Baptista Filho²

¹ Tecnologia da Informação – São Paulo-Sul
Petróleo Brasileiro S.A. - Petrobras
Avenida Paulista, 901
01311-100 São Paulo, SP
waldj@petrobras.com.br

² Instituto de Pesquisas Energéticas e Nucleares (IPEN / CNEN - SP)
Avenida Professor Lineu Prestes, 2242
05508-000 São Paulo, SP
bdbfilho@ipen.br

RESUMO

Mapas Auto-Organizáveis (*Self-Organizing Map*, SOM) de Kohonen foram testados com dados de vários regimes de operação do reator IRIS (*International Reactor Innovative and Secure*) para se desenvolver uma ferramenta eficaz na classificação e identificação de transientes em reatores nucleares. Os dados foram retirados de 56 simulações da operação do IRIS, de condições de regime permanente a acidentes. O sistema digital construído para os testes foi baseado na plataforma Java pela portabilidade e escalabilidade, e por pertencer às plataformas de desenvolvimento livre. Resultados satisfatórios de classificação de operação foram obtidos com razoável rapidez de processamento em computadores pessoais; de dois a cinco minutos para ordenamento e convergência do aprendizado sobre a base de dados. A metodologia deste trabalho foi estendida para a supervisão logística de gás natural para a rede de gasodutos brasileira, obtendo-se igualmente resultados satisfatórios para a classificação de entregas para vários pontos de medição simultaneamente.

1. INTRODUÇÃO

Este trabalho mostra os resultados do uso de redes neurais artificiais do tipo "mapas auto-organizáveis" (SOM) de Kohonen (Kohonen, 1982) para supervisão de processos em reatores nucleares, como a identificação de transientes, particularmente para o reator IRIS, e sua generalização para sistemas de supervisão logística em gasodutos da Petrobras, contribuindo também com o programa brasileiro de utilização do gás natural. Para a realização dos modelos em sistemas digitais, foi utilizada a linguagem Java, pertencente às plataformas livres e considerada adequada para tratamento de problemas que envolvem informações coletadas por sistemas interligados à Internet ou Intranet, como no caso dos "clusters" de reatores ou das redes de distribuição de gás natural.

O IRIS (*International Reactor Innovative and Safety*) (Carelli *et al.*, 2000) surgiu de um esforço de cooperação internacional para desenvolver um sistema de energia nuclear capaz de

satisfazer a maior parte dos requisitos da IV geração de usinas nucleares. O IRIS tem a vantagem da sua configuração integral para implantar a abordagem segurança por projeto para atingir metas desafiadoras de segurança (Carelli *et al.*, 2001). Com essa filosofia, qualquer possível fonte de vulnerabilidade em segurança deve ser declarada e adequadamente tratada (Packer, 2002). Segurança por projeto e as barreiras de segurança recomendadas pelo princípio da defesa em profundidade podem eliminar acidentes e atenuar muitas conseqüências de falhas mecânicas, elétricas e humanas, mas, para produzir uma planta realmente confiável, são necessárias ferramentas modernas que ofereçam informações relevantes com usabilidade para a equipe de operação.

A ferramenta que será apresentada neste trabalho é promissora na identificação de transientes, classificando esses em normais ou anormais. Numa operação on-line com a instrumentação do reator, fornece suporte ao operador na segurança do IRIS, desde o primeiro estágio de funcionamento, por permitir visualizar ao longo do tempo a migração das unidades neurais ativadas para a fronteira de uma classe de transientes. Esse sistema foi descrito primeiramente por Baptista e Barroso, 2003, e, desde então, foi aperfeiçoado e testado com maiores quantidades de dados, levando em conta um grande conjunto de simulações.

Este artigo é dividido em quatro seções, esta introdução, uma descrição do sistema idealizado para a classificação dos dados, com uma breve descrição das redes neurais e do programa desenvolvido, a análise dos resultados e, finalmente, as conclusões.

2. MATERIAIS E MÉTODOS

O Mapa Auto-Organizável (SOM) de Kohonen tem se mostrado como um dos mais eficientes métodos para mapeamento de dados multidimensionais para um espaço de menor ou igual dimensão. Esse mapeamento resulta na classificação dos padrões de entrada, extraindo as características ocultas dos dados na forma de uma análise de componentes principais não-linear.

O SOM, baseado nos processos de ordenação topológica, encontrados na organização dos sistemas visual, tátil e auditivo do córtex, faz com que entradas com características similares ativem células próximas fisicamente, ou seja, o processo de treinamento produz uma organização topológica da rede neural (Figura 1). Essa organização é resultante do método de treinamento baseado na competição entre as unidades. A unidade neural vencedora, diante de uma entrada, é aquela que possui o vetor peso associado mais próximo do vetor dado de entrada, vetor peso esse que será modificado para a próxima apresentação do dado da seguinte maneira:

$$w_j(n+1) = w_j(n) + \eta(n) h_{j,i(x)}(n) (x - w_j(n)) \quad , \quad (1)$$

onde n é o tempo, ou época, ou ainda iteração. O índice i representa o neurônio vencedor para a entrada x . O índice j é um neurônio da rede e w_j seu vetor peso. O fator η é a taxa de aprendizagem, decrescente ao longo do tempo. A função $h_{j,i}$ é de influência da vizinhança, concentrada cada vez mais no neurônio vencedor ao longo do tempo.

Uma característica do SOM, de apenas uma camada de entrada e uma camada neural, é que suas unidades não possuem limiar para ativação; o valor de saída não é importante, e sim a localização do elemento (unidade neural) ativado, ou ainda o valor do seu peso. O resultado é

a obtenção de características inerentes ao conjunto de dados, características que foram realçadas pelo mapeamento das entradas para uma menor dimensão.

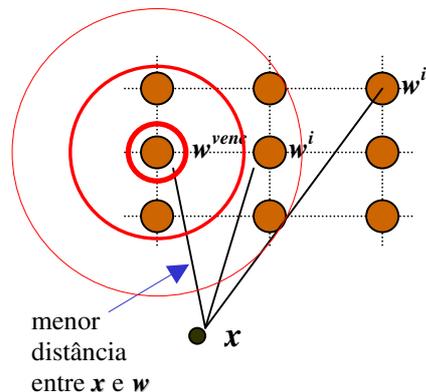


Figura 1. Camada de saída com unidades neurais organizadas em rede bidimensional retangular. Vetor x é entrada e vetor w^j é o peso da unidade j .

O conjunto de dados de treinamento (entradas) para o reator IRIS, além de transientes, contém muitos padrões de condições estacionárias, de 20 a 110% da plena potência. Os diferentes tipos de transientes que foram considerados são:

- degraus potência de 10%, positivos e negativos;
- rampas de potência a 5%/minuto;
- desarme da turbina;
- SCRAM;
- abertura inadvertida da válvula de alívio de pressão;
- degrau positivo de grande potência, 50% da plena potência;
- um grande degrau negativo, 70% da plena potência; e
- um acidente de pequena perda de refrigerante (*Small LOCA*).

É importante observar que a resposta do reator para cada um desses transientes depende do sistema de controle. Quando a arquitetura de controle e os parâmetros não são otimizados, modelos simplificados são suficientes para prover dados básicos a fim de caracterizar o comportamento do IRIS. Em Barroso *et al.*, 2003, há a descrição das ferramentas simplificadas que produziram os dados utilizados neste trabalho. A Figura 2 ilustra a resposta de temperatura durante um SCRAM a partir da plena potência.

2.1. A Customização do SOM para o problema

O sistema para identificação de transientes do IRIS trabalha com a idéia de que algumas variáveis são capazes de caracterizar um tipo de transiente. Essas variáveis são: a potência do reator, a potência do gerador de vapor, a pressão do pressurizador, o nível de água e a temperatura em diferentes pontos como exemplificado na Figura 2. O simulador tem um buffer para coletar dados por alguns segundos de cada uma das principais variáveis, que formarão um espectro que será a entrada para o SOM. Por exemplo, a variação de pressão durante um acidente com pequena perda de refrigerante é traduzida para pacotes de 16

segundos. Cada pacote contém informação de 16 segundos de tempo transiente e a diferença entre pacotes é de 1 segundo.

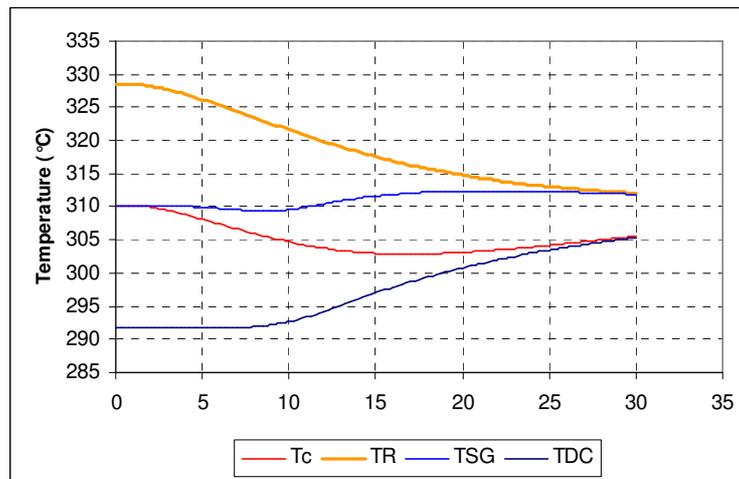


Figura 2. SCRAM: resposta em temperatura. Onde as siglas significam: T – temperatura, C – refrigerante (*coolant*) na subida, R – reator, SG – gerador de vapor (*steam generator*) e DC – canal de descida (*downcomer*).

Em trabalho anterior de Baptista e Barroso, 2003, os dados eram normalizados somente com respeito a cada valor de variável. Na nova versão, a normalização é do conteúdo do buffer. Trabalhou-se principalmente com uma camada de saída em rede hexagonal, no modo não-supervisionado, por 1000 épocas ou iterações para ordenamento e mais 8000 épocas para convergência. O objetivo foi verificar a habilidade da ferramenta em fazer a distinção clara entre quatro tipos de condição de operação: estado estacionário, transientes em rampa, transientes em degrau e eventos anormais ou acidentais. A Tabela 1 lista os pacotes de dados para diversos transientes usados no treinamento da rede.

A fase de convergência é um refinamento do mapa de características providenciando uma quantificação estatística mais acurada do espaço de entrada. Como regra geral o número de iterações para esta fase deve ser pelo menos 500 vezes o número de neurônios na rede (Haykin, 1999), podendo atingir dezenas de milhares de iterações. Nesta fase a taxa de aprendizado $\eta(n)$ é constante e baixa, aproximadamente 0.01. Em qualquer fase, a taxa de aprendizado não pode chegar a zero, senão é possível que a rede neural fique “emperrada” num estado metaestável, um defeito topológico de mínimos locais. A função de vizinhança $h_{j,i(x)}$ nesta fase deve conter somente os neurônios mais próximos, podendo se reduzir para somente o vencedor.

3. RESULTADOS E DISCUSSÕES

3.1. Obtenção das Características de Operação do IRIS

A Figura 3 mostra as classes atribuídas para cada unidade neural para um treinamento com normalização do conteúdo de buffer. A classificação das unidades foi baseada na mínima

distância, ou seja, a classe (representada pela cor) que é atribuída à unidade neural é a classe do vetor de entrada atribuído à unidade e que também é o mais próximo do vetor peso desta unidade. Este método de medida de sensibilidade pode causar resposta não adequada a padrões não presentes no conjunto de treinamento. E a classificação inadequada de transientes pode ser responsável por ações incorretas. Um refinamento através da quantização vetorial poderá melhorar a precisão do sistema, porém esta etapa será abordada em trabalho futuro. Os tipos de condição de operação foram indicados por código numérico e por código de cores no caso da interface gráfica do usuário: 1 e verde para estado estacionário; +2 e laranja-escuro para rampa positiva, -2 e laranja-claro para rampa negativa; +3 e vermelho para degrau positivo, -3 e rosa para degrau negativo e 4 e roxo para eventos anormais.

Tabela 1. Lista de transientes do simulador de operações IRIS.

Transientes Normais			
1	20% Steady state	28	100% Ramp -5%/min
2	25% Steady state	29	90% Ramp -5%/min
3	30% Steady state	30	80% Ramp -5%/min
4	35% Steady state	31	70% Ramp -5%/min
5	40% Steady state	32	60% Ramp -5%/min
6	45% Steady state	33	50% Ramp -5%/min
7	50% Steady state	34	40% Ramp -5%/min
8	55% Steady state	35	30% Ramp -5%/min
9	60% Steady state	36	100% → Step -10%
10	65% Steady state	37	90% → Step -10%
11	70% Steady state	38	80% → Step -10%
12	75% Steady state	39	70% → Step -10%
13	80% Steady state	40	60% → Step -10%
14	85% Steady state	41	50% → Step -10%
15	90% Steady state	42	40% → Step -10%
16	95% Steady state	43	30% → Step -10%
17	100% Steady state	44	20% → Step +10%
18	105% Steady state	45	30% → Step +10%
19	110% Steady state	46	40% → Step +10%
20	25% Ramp +5%/min	47	50% → Step +10%
21	30% Ramp +5%/min	48	60% → Step +10%
22	40% Ramp +5%/min	49	70% → Step +10%
23	50% Ramp +5%/min	50	80% → Step +10%
24	60% Ramp +5%/min	51	90% → Step +10%
25	70% Ramp +5%/min		
26	80% Ramp +5%/min		
27	90% Ramp +5%/min		
Transientes Anormais			
52	100% Turbine trip		
53	100% SCRAM		
54	Inadvertent Safety Valve Opening		
55	100% → Step -70%		
56	100% Small LOCA		

Utilizou-se taxa inicial de aprendizagem η igual a 0,20 e o tempo médio de processamento em CPU de 1 GHz e 256 MB de RAM foi de 3 min., para ordenamento e convergência.

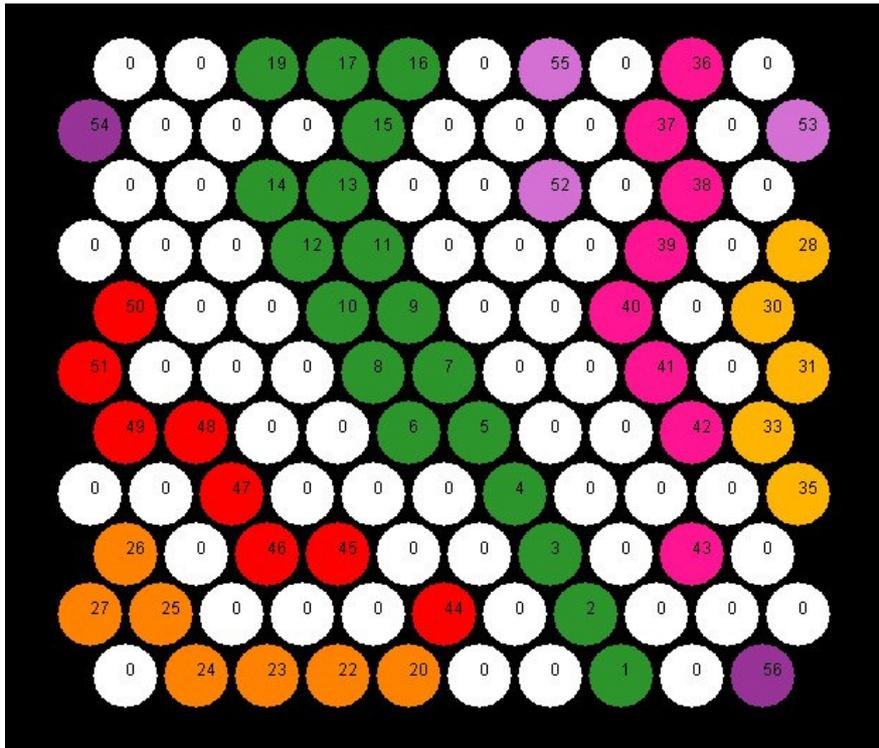


Figura 3. Camada de saída do SOM exibindo o resultado do monitoramento da operação do IRIS sob diversas condições. Nesta visão, os números sobre as unidades neurais correspondem aos dados da Tabela 1.

3.2. Extensão para rede de gasodutos

Buscou-se, com esta ferramenta, também auxiliar no planejamento e na tomada de decisões para entrega de gás natural a partir de gasodutos (logística do gás natural), uma vez que as centrais de supervisão ainda encontram dificuldades neste negócio. Para tanto, utilizaram-se 6 componentes para o vetor de entrada: label do ponto de entrega/interconexão que faz o papel de localização no gasoduto, volume entregue/repassado diário, poder calorífico superior (PCS), pressão, temperatura e densidade relativa ao ar seco.

Como a faixa de variação de PCS é curta porém sensível ao negócio quanto à qualidade, um fator de distensão ζ entre 10 e 100 foi aplicado à faixa de variação do PCS, aumentando a sensibilidade do sistema para tal variável,

$$\left(\frac{x_{c \max}^j - x_c^j}{x_{c \max}^j - x_{c \min}^j} \right) \times \zeta_c, \quad (2)$$

onde c representa um dos componentes do vetor de entrada. Pelo número bem maior de unidades, entradas e iterações, o processamento em Java, para CPU de 1 GHz e 256 MB de RAM, levou em média 12 min.

No resultado apresentado na Figura 4, temos uma visão que imprime, sobre as unidades, o label do ponto de entrega/interconexão, seguido de “|” e depois do PCS em kcal/m³.

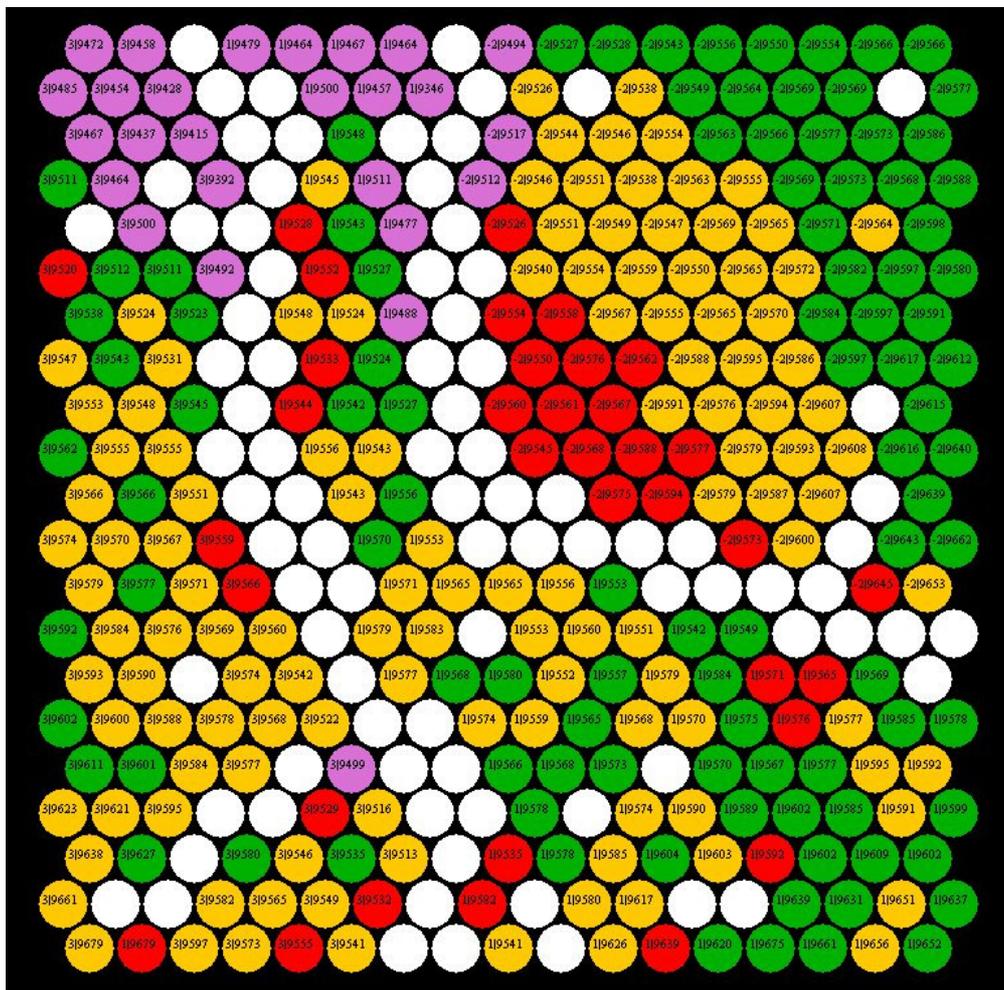


Figura 4. Classificação de 3 pontos de entrega de gás natural. Verde refere-se a volumes acima de 5% da média. Vermelho, abaixo de 20% da média. Laranja, dentro da média. Roxo, PCS abaixo de 0,5% da média. Valores de contrato poderiam ser submetidos ao invés da média.

Utilizando outra massa menor de dados para teste, o acerto na classificação destes após o treinamento da rede neural ficou por volta de 90%.

4. CONCLUSÕES

A utilização do Mapa auto-Organizável para classificação de transientes em reatores e para classificação de entregas de gás natural a partir de gasodutos se mostrou viável e útil no auxílio à tomada de decisões, mesmo sem recorrer à quantização vetorial, à retropropagação e ao Mapa Auto-Organizável hierárquico.

Não há qualquer diferença de eficiência entre utilizar uma camada neural em rede bidimensional retangular ou hexagonal. Porém a rede hexagonal, por ter seus elementos mais compactados, apresenta uma visualização mais agradável para o usuário quando este necessita verificar a separação das classes.

O próximo passo neste projeto será a utilização do SOM para quantização vetorial e a associação do SOM a uma camada de propagação (associação chamada de contrapropagação).

AGRADECIMENTOS

Agradecemos aos docentes do IPEN, pelo atendimento e paciência nas dificuldades, à Petrobras, pelo fornecimento de recursos e instruções em informática e à FAPESP pelo apoio financeiro no projeto para viabilizar o desenvolvimento de um protótipo, Processo n° 04/05150-1.

REFERÊNCIAS

1. Baptista F., B. D., “Redes Neurais Artificiais na Engenharia Nuclear – Parte 2,” *Revista Brasileira de Pesquisa e Desenvolvimento*, **Vol. 4**, No.2, págs.220-225 (2002).
2. Baptista F., B. D., Barroso, A. C. O., “Identification of IRIS Reactor Transients with Self-Organized Maps,” *International Conference on Global Environment and Advanced Nuclear Power Plants (GENES4/ANP2003)*, Kyoto, Japan, (2003).
3. Baptista F., B. D., Barroso, A. C. O., “Self-Organized Maps in the Identification of IRIS Reactor Transients,” *The International Conference on Integrated Modeling & Analysis in Applied Control & Automation (IMAACA 2004)*, Genoa, Italy, October 28-30, Paper IMAACA_Nu-05 (2004).
4. Barroso, A. C. O., Baptista F., B. D., Arone, I. D., Macedo, L. A., Sampaio, P. A. B., Moraes, M., “IRIS Pressurizer Design,” *Proceedings of ICAPP '03*, Córdoba, Spain, May 4-7, Paper 3227 (2003).
5. Carelli, M. D. *et al.*, “IRIS, International New Generation Reactor,” *Proceedings of the 8th International Conference on Nuclear Engineering*, Baltimore, USA, April 1-5 (2000).
6. Carelli, M. D. *et al.*, “Safety by Design: A New Approach to Accident Management in the IRIS Reactor,” *IAEA International Seminar on Status and Prospects for Small and Medium Sized Reactors*, Cairo, Egypt, May 27-31 (2001).
7. Haykin, S., *Neural Networks: A Comprehensive Foundation*, Prentice Hall, New Jersey, USA (1999).
8. Kohonen, T., “Self-Organized Formation of Topologically Correct Feature Maps,” *Biological Cybernetics*, **Vol. 43**, pp. 59-69. Reprinted by Anderson and Rosenfeld in 1988 (1982).
9. Packer, C., “A Framework for the Organizational Assumptions Underlying Safety Culture,” *Annals of the International Safety Conference on Safety Culture in Nuclear Installations (IAEA)*, Rio de Janeiro, Brazil, December 2-6 (2002).
10. “Cálculo de Poder Calorífico, Fator de Compressibilidade, Índice de Wobbe e Densidade Relativa de Combustíveis Gasosos,” Normalização Técnica Petrobras N-2535 (2001).