



IDENTIFICAÇÃO E DIAGNÓSTICO AUTÔNOMO DE REGIMES DE ESCOAMENTO BIFÁSICO ATRAVÉS DE MODELOS NEURAI AUTO-ORGANIZATIVOS

Kelen Cristina Oliveira Crivelaro

Núcleo de Engenharia Térmica e Fluidos
Universidade de São Paulo
Av. Trabalhador São-Carlense, 400 – Centro
CEP: 13566-590 – São Carlos – SP
e-mail: crivelar@sc.usp.br

Paulo Seleglim Jr.

Núcleo de Engenharia Térmica e Fluidos
Universidade de São Paulo
Av. Trabalhador São-Carlense, 400 – Centro
CEP: 13566-590 – São Carlos – SP
e-mail: seleglim@sc.usp.br

Eric Hervieu

DRN/DTP/SETEX/LTDF
Commissariat à l’Energie Atomique
38054 Grenoble cedex 9 – França
e-mail: hervieu@ntp.ceaf.fr

***Resumo:** Um dos principais problemas relacionados ao transporte e manipulação de fluidos multifásicos refere-se a existência de regimes de escoamento e sua forte influência sobre importantes parâmetros de operação. Um bom exemplo disto ocorre em reator químico gás-líquido no qual máximos coeficientes de reação podem ser alcançados por manter um escoamento a bolhas disperso maximizando a área interfacial total. Assim, a habilidade de identificar automaticamente regimes de escoamento é de importância crucial, especialmente para operação adequada de sistemas multifásicos. Neste trabalho, uma rede neural não supervisionada, mapas auto-organizativos (self-organizing maps), é utilizada em associação a uma sonda de visualização direta, para a identificação de regimes de escoamento horizontal gás-líquido, produzidos num circuito experimental. Mais especificamente, os sinais produzidos pela sonda são utilizados para compor uma imagem qualitativa do escoamento e, em seguida, enviados à rede neural para o reconhecimento do regime. Resultados são apresentados para diferentes transições entre regimes de escoamento, e demonstram a performance extremamente satisfatória do sistema de diagnóstico.*

***Palavras-chave:** Redes Neurais, Mapas Auto-organizativos, Escoamentos Bifásicos, Regimes de Escoamento, Diagnóstico*

1.INTRODUÇÃO

Um dos principais problemas relacionados ao transporte e manipulação de fluidos multifásicos refere-se a existência de regimes de escoamento e sua forte influência sobre importantes parâmetros de operação. Um bom exemplo disto ocorre em reator químico gás-líquido no qual máximos coeficientes podem ser alcançados por manter um escoamento a bolhas disperso maximizando a área interfacial total. Assim, a habilidade de identificar automaticamente regimes de escoamento é de importância crucial, especialmente para operação adequada de sistemas multifásicos.

O desenvolvimento de técnicas de instrumentação específicas para escoamentos multifásicos teve um grande impulso a partir de meados dos anos 70 quando os Estados Unidos, França e Japão passaram a investir maciçamente na geração termonuclear de energia. Neste período surgiu a carta de Taitel e Dukler (1976), que é construída a partir de um modelo físico-matemático que prevê as relações entre as seguintes variáveis na transição do regime de escoamento: vazões de massa do escoamento de gás e líquido, propriedades dos fluidos e diâmetro.

É bem conhecido que, em escoamento bifásico, uma mudança abrupta na queda de pressão é frequentemente associada a uma mudança de regime de escoamento (Wambsganss et al. 1994). Lin e Hanraty (1987) utilizaram a técnica de medida de pressão para detecção de regime de escoamento intermitente. Sekoguchi et al. (1987) aplicaram um método estatístico e média de fração de vazio para identificação de regimes de escoamento. No que concerne a técnicas não clássicas de análise de sinais Giona et. al., (1994) e Selegim e Hervieu (1998) empregaram, na caracterização das transições de regimes de escoamento bifásico horizontal, respectivamente, técnicas de análise fractal e análise conjunta tempo-frequência. Nesse contexto, o uso de técnicas de redes neurais na análise de sinais originários de escoamentos bifásicos apresenta um grande potencial (Monji e Matsui, 1998). Entretanto, existe ainda apenas um pequeno número de publicações em que esta abordagem é adotada. Segundo Bishop (1994) um fator chave que limita a implementação comum de soluções de redes neurais em muitas áreas tem sido a dificuldade de demonstrar que as saídas generalizadas pela rede são de confiança. Crivelaro et. al. (2002), utilizaram uma rede neural para processar os sinais provenientes de uma sonda de imagem direta para produzir o diagnóstico do regime de escoamento correspondente. Smith et. al. (2001), utilizou rede neural auto-organizativa (self-organizing maps) para comparar os resultados da classificação de regimes de escoamento baseados na análise tradicional. Valores estatísticos do sinal de impedância foram usados como entrada para a rede neural, a qual classificou os resultados dentro de um número de categorias pré-determinada. Mi et. al. (1998) utilizaram uma rede neural supervisionada e outra não supervisionada auto-organizativa (self-organizing maps) para identificar regimes de escoamento, onde o sinal de entrada para a rede neural era uma medida de impedância não intrusiva. Cai et. al. (1994) apresentaram uma técnica para classificação de regimes de escoamento em escoamento bifásico ar-água aplicando uma rede neural auto-organizativa (self-organizing). O princípio da técnica resulta na caracterização e classificação de sinal de pressão turbulenta em relação aos regimes de escoamento.

O presente trabalho consiste em desenvolver e implementar uma rede neural não supervisionada, mapas auto-organizativos (self-organizing maps), que constituirá a lógica básica de um dispositivo de sensoriamento capaz de diagnosticar em tempo real o regime de escoamento no conduto de testes. Em específico, este trabalho se focalizará no desenvolvimento e implementação de modelos neurais especializados no problema de diagnóstico. Deve-se ressaltar que este *savoir faire* é fundamental para a operação eficaz de equipamentos e instalações que envolvam o transporte de fluidos multifásicos e representa hoje um dos grandes desafios das indústrias petroquímicas e termonucleares entre outras.

2. REDES NEURAS ARTIFICIAIS AUTO-ORGANIZATIVAS (SELF-ORGANIZING MAPS)

Uma rede neural artificial pode ser definida como um sistema de processamento de dados de um grande número de neurônios artificiais conectados, veja Fig.(1). Esses elementos de processamento são usualmente organizados dentro de uma sequência de camadas totalmente ou parcialmente conectadas entre si. A camada de entrada é a que apresenta os dados para a rede e a camada de saída é a que recebe a resposta de saída para uma dada entrada. A outra camada é chamada camada intermediária.

A Figura (1) mostra uma rede neural consistindo, de 5 neurônios na camada de entrada, dois neurônios na camada de saída e uma camada intermediária com 3 neurônios. Cada conexão entre os neurônios é denominada peso, o qual é uma medida da importância das conexões na rede. Outro elemento básico da rede neural é a função de ativação que serve para limitar a saída do neurônio. Durante o treinamento esses parâmetros são mudados de maneira a produzir uma determinada saída. A rede é treinada apresentando pares entrada/saída e para cada entrada fornecida à rede, ela calcula uma saída a qual é então comparada com a saída desejada. Especificamente, a diferença entre a saída calculada e a saída desejada é chamada erro. Quando a soma de todos os erros é minimizada, diz-se que a rede está treinada. Treinamento é um processo iterativo, o qual deve convergir para uma solução correta.

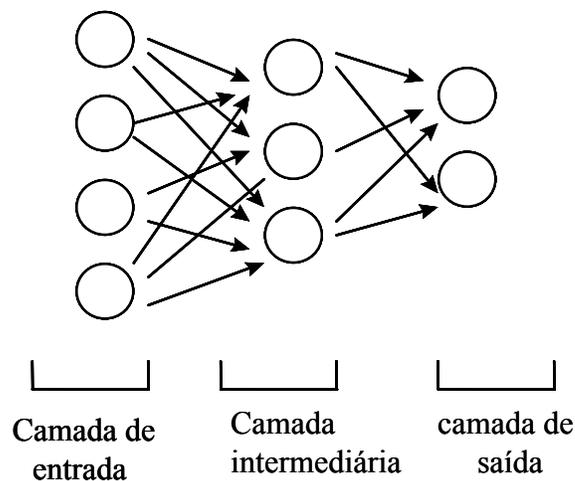


Figura 1: Esquema de uma rede neural

Quando a entrada é apresentada para a rede e ela agrupa as características relacionadas por ela mesma, ela é conhecida como rede neural auto-organizativa (self-organizing maps) (Mi et. al., 1998).

O termo auto-organizativo refere à habilidade da rede aprender sem inicialmente dar a resposta correta para um padrão de entrada. A rede é bem apropriada para reconhecimento de padrões porque ela é capaz de organizar padrões de um espaço arbitrário n-dimensional para um espaço de dimensão menor e preservar as relações topológicas entre os aspectos (Cai et. al., 1994).

Em um mapa auto-organizativo (self-organizing maps), os neurônios estão dispostos em uma grade que é usualmente unidimensional ou bidimensional. Mapas com dimensões maiores também são possíveis, mas não tão comuns (Haykin, 1994). A Figura (2) mostra o diagrama esquemático de uma grade bidimensional de 6 neurônios. Cada neurônio na grade está totalmente conectado a todos os neurônios na camada de entrada. Os neurônios são compostos seletivamente de acordo com os vários padrões de entrada ou classes de padrões de entrada no curso de um processo de aprendizagem competitivo. A localização do neurônio vencedor vem a ser ordenada de acordo com os outros neurônios de uma maneira significativa no sistema de coordenadas criado sobre uma grade, para diferentes aspectos de entrada. Um mapa auto-organizativo é caracterizado pela formação de um mapa topográfico dos padrões de entrada, os quais a localização espacial (i.e., coordenadas) dos neurônios na grade são indicativos de aspectos estatísticos intrínsecos contidos nos padrões de entrada, por isso o nome mapas auto-organizativos.

No processo de aprendizagem competitivo, para cada padrão de entrada, os neurônios na rede calculam seus respectivos valores através de uma função distância. Esta função provém à base para competição entre os neurônios. O neurônio particular com o maior valor da função distância é declarado vencedor da competição.

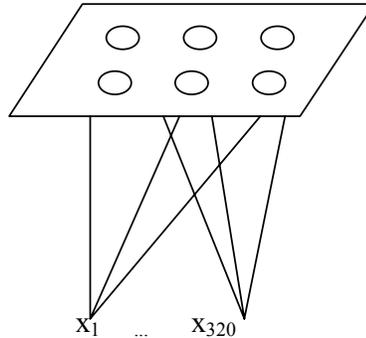


Figura 2: Rede auto-organizativa com uma grade bidimensional de neurônios

Seja m denota a dimensão do vetor de entrada. Seja um vetor de entrada selecionado do espaço de entrada randômico representado por

$$p = [p_1, p_2, \dots, p_m]^T$$

O vetor peso de cada neurônio na rede tem a mesma dimensão do vetor de entrada. Seja o vetor peso do neurônio j denotado por

$$w_j = [w_{j1}, w_{j2}, \dots, w_{jm}]^T, \quad j = 1, 2, \dots, l$$

onde l é o número total de neurônios na rede. Para encontrar a melhor competição do vetor de entrada p com o vetor peso w_j , compare o produto interno $w_j^T p$ para $j = 1, 2, \dots, l$ e selecione o maior. Assuma que o mesmo threshold é aplicado a todos os neurônios; o threshold é o negativo do bias. Assim, por selecionar o neurônio com o maior produto interno $w_j^T p$, terá um efeito que determinou a localização onde a vizinhança topológica de neurônios excitados está centrada.

O melhor critério de competição, baseado na maximização do produto interno de $w_j^T p$, matematicamente equivalente a minimizar a distância Euclidiana entre os vetores p e w_j . O neurônio $i(p)$ identifica o neurônio que melhor compete com o vetor de entrada p , pode-se então determinar $i(p)$ aplicando a condição

$$i(p) = \arg \min_j \|p - w_j\|, \quad j = 1, 2, \dots, l \quad (1)$$

o qual soma a essência do processo de competição entre os neurônios. De acordo com a equação acima, tem-se que dar uma atenção especial a $i(p)$ porque o objetivo é identificar o neurônio i . O neurônio particular i que satisfaz esta condição é chamado de neurônio vencedor para o vetor de entrada p . Pode-se observar isto na Eq.(1) acima.

No treinamento primeiro a rede identifica o neurônio vencedor. Então os pesos do neurônio vencedor e os outros neurônios em sua vizinhança, são movidos junto ao vetor de entrada para cada passo de aprendizagem.

Uma vez treinada, pode-se supor que a rede armazenou o conhecimento a ela fornecido. Entretanto, o conhecimento dentro de uma rede neural não é armazenado em uma localização particular. Conhecimento é armazenado da maneira que os neurônios são conectados, da camada de entrada para a camada de saída e na importância dos pesos na camada de entrada, (Grubert, 1995).

3. INSTALAÇÕES EXPERIMENTAIS

Vários testes experimentais foram feitos neste trabalho. As medidas foram realizadas no circuito BHETA, do Commissariat à l’Energie Atomique em Grenoble – França, para testes transientes em escoamentos bifásicos. Esta instalação é basicamente composta de sistemas de alimentação de água e ar, um misturador, uma seção de ensaios horizontal e um separador, conforme indicado na Fig. (3). A seção de ensaios é construída em acrílico e suas dimensões são de 60 mm de diâmetro interno e 30 m de comprimento.

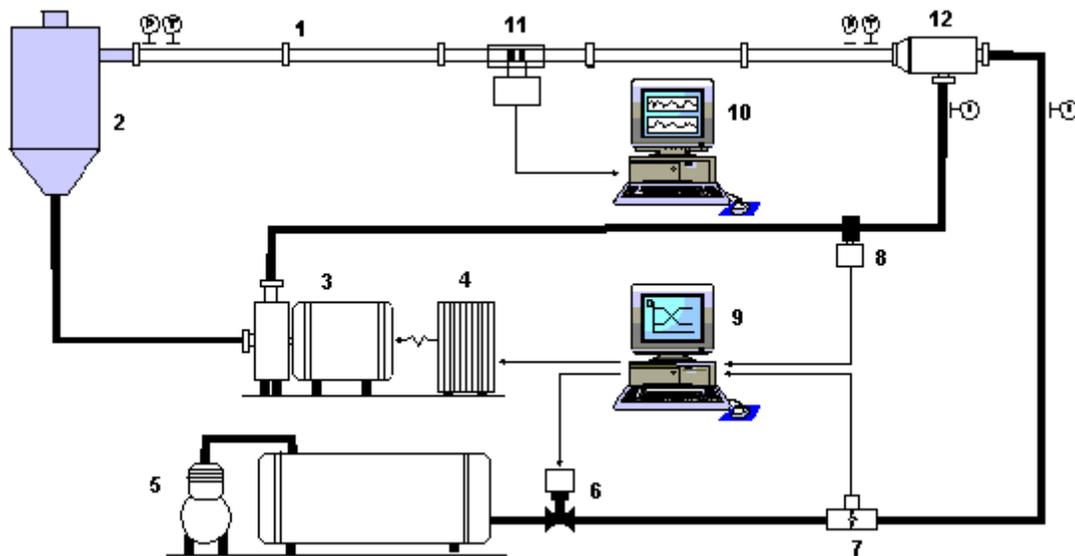


Figura. 3: Circuito experimental, segundo Selegim e Hervieu, (1998) : (1) seção de ensaios, (2) separador, (3) bomba hidráulica, (4) variador de frequência, (5) compressor, (6) servo-válvula, (7) medidor de vazão eletromagnético, (8) medidor de vazão, (9) piloto do circuito, (10) sistema de aquisição de sinais, (11) sonda condutiva, (12) misturador.

A instrumentação de controle do circuito inclui transdutores de pressão e temperatura, bancos de medidores de vazão do tipo turbina e eletromagnético, respectivamente para medidas das vazões de ar e água. Dois sistemas de regulação baseado na lógica PID asseguram a possibilidade de se impor, a priori e de forma independente, as variações temporais de vazão a serem executadas durante o ensaio. É importante dizer que, em sistemas bifásicos não dotados de regulação, as vazões físicas tendem a oscilar de forma acoplada mesmo na ausência de perturbações ou comandos externos nesse sentido (Selegim & Hervieu, 1998).

4. SONDA

Segundo Seleghim e Hervieu (1998), para se obter uma imagem do escoamento diretamente da medida de quantidades físicas, *i.e.* sem reconstrução numérica, é necessário produzir uma divisão na região de sensoriamento em um certo número de sub-regiões independentes. Por exemplo, uma representação do perfil de imagem da fração de vazio pode ser obtida pela partição do volume de sensoriamento por meio de um certo número de detectores de fase. Se estes detectores não perturbarem o escoamento e suas zonas de sensibilidade forem restritas a uma pequena região do sensor, o conjunto de sinais assim obtidos pode ser diretamente plotado respeitando a estrutura da partição. Como cada valor é representativo da fração de vazio local, o resultado estará próximo do perfil de fase real.

A geometria adotada por Seleghim e Hervieu (1998), consiste de dois anéis de eletrodos de aço inoxidável montados juntos à parede do tubo como ilustrado na Fig. (4). A medida principal é baseada nas diferenças ou contrastes entre as propriedades elétricas das fases constitutivas do escoamento bifásico. Devido a este fato, sua distribuição espacial afeta a impedância global.

Uma característica fundamental da geometria dos eletrodos é que a impedância global depende fortemente do padrão de escoamento dentro do volume de sensoriamento. Isto pode ser atribuído às diferenças no fluxo azimutal de corrente para diferentes regimes de escoamento. Consequentemente uma partição do volume de medida pode ser obtida pela segmentação medida que resulta em uma série de eletrodos regularmente dispostos de acordo com o perímetro do tubo, como esquematizado na Fig. (4).

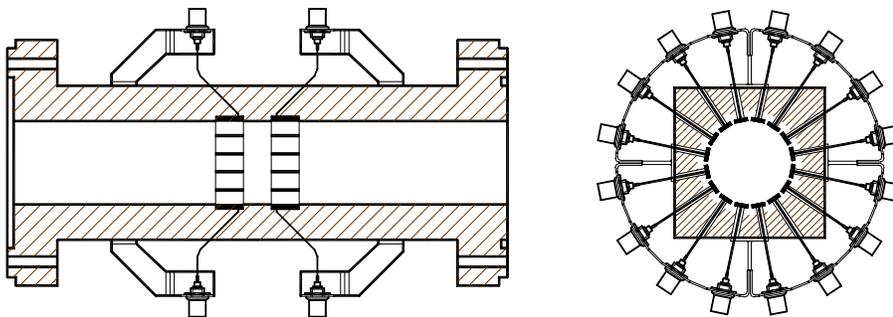


Figura 4: Sonda condutiva segundo SELEGHIM & HERVIEU (1998)

5. RESULTADOS

Para cada grande família de escoamentos bifásicos horizontais foram realizadas séries de testes em regime permanente de longa duração no circuito experimental descrito anteriormente. Os sinais analisados correspondem à medida de condutividade elétrica obtida por meio da sonda de visualização, cujo princípio de funcionamento encontra-se esquematizado na Fig. (4). Assim, para cada teste, estes sinais foram filtrados (anti-aliasing) e amostrados à taxa 100 Hz. A Tabela (1) mostra em detalhes as condições relativas às séries de testes realizados.

A rede neural utilizada neste trabalho foi uma rede auto-organizativa (self-organizing) com o algoritmo de aprendizagem competitivo.

A rede foi implementada no *Neural Networks Toolbox* do Matlab. A arquitetura da rede foi definida de acordo com as necessidades de se obter um bom treinamento. A partir de estudos preliminares, a arquitetura da rede foi definida para que a mesma tivesse um bom desempenho no treinamento. A camada de entrada foi composta por 320 neurônios, e a grade possuía 6 neurônios de saída, pois o objetivo é classificar seis regimes de escoamento. A função distância utilizada foi a Euclidiana.

Tabela 1 : Codificação dos ensaios

Codificação	Ensaio
1	intermitente
2	anular
3	estratificado liso
4	estratificado ondulado
5	estratificado rugoso
6	bolhas

Os dados utilizados no treinamento foram obtidos dos ensaios feitos com a sonda. Para o treinamento da rede foram tomadas matrizes de 20 linhas por 16 colunas (as colunas representam a posição dos eletrodos e as linhas o instante das amostras). Esse número foi determinado pela máxima capacidade do Matlab no qual a rede foi implementada, de forma que o processo de treinamento pudesse ser completado satisfatoriamente e num tempo não excessivamente longo.

Cada regime de escoamento analisado tem suas características próprias. Para o treinamento da rede deseja-se obter dados que caracterizem cada regime de escoamento. Analisando-os individualmente concluiu-se que 2 segundos caracterizariam bem os ensaios 1, 2, 3, 4, 6. Porém, este mesmo intervalo de tempo para o ensaio 5 acarreta perdas de informações associadas a frequências mais altas e, com isso, dificulta-se o treinamento da rede. Portanto neste caso utilizou-se um intervalo de tempo de 1 segundo.

Depois do treinamento, a rede classificou com sucesso os regimes de escoamento.

Tabela 2: Resultados da rede neural

Regimes de escoamento	Classificação da rede Neural	neurônio
anular	pontos: 1, 2, 3, 4, 5, 6, 7, 8, 9, 10	1
bolhas	pontos: 11, 12, 13, 14, 15, 16, 17, 18, 19, 20	2
intermitente	pontos: 21, 22, 23, 24, 25, 26, 27, 28, 29, 30	3
estrat. rugoso	pontos: 31, 32, 33, 34, 35, 36, 37, 38, 39, 40	1
estrat. liso	pontos: 41, 42, 43, 44, 45, 46, 47, 48, 49, 50	4
estrat. ondulado	pontos: 51, 52, 53, 54, 55, 56, 57, 58, 59, 60	5

Os conjuntos para a rede fazer a classificação foram denotados como pontos experimentais de 1-60. Do ponto 1-10 a rede terá que classificar como regime de escoamento anular, do ponto 11-20 ela terá que classificar como regime de escoamento à bolhas, do ponto 21-30 como regime de escoamento intermitente, do ponto 31-40 como regime de escoamento estratificado rugoso, do ponto 41-50 como regime de escoamento estratificado liso e do ponto 51-60 como regime de escoamento estratificado ondulado.

A Tabela 2 representa a classificação feita pela rede neural e o neurônio que classificou os regimes. Como pode-se observar a rede classificou erroneamente o regime de escoamento anular no mesmo neurônio (mesma classe) que ela classificou o regime de escoamento estratificado rugoso. Conforme se pode observar na Tab. (2), as taxas de acerto são bastante satisfatórias

6. Conclusões

Neste trabalho, são mostradas redes neurais para identificação de regimes de escoamento bifásico em um tubo horizontal. Para treinar a rede utilizou-se os dados obtidos de uma sonda capaz de produzir imagens qualitativas do escoamento sem necessidade de reconstrução numérica (tomografia). A arquitetura da rede neural foi definida de acordo com estudos preliminares tendo como meta a obtenção de um bom treinamento.

Para demonstrar a potencialidade da metodologia adotada várias simulações foram feitas: sinais característicos de diferentes regimes de escoamento foram apresentados a rede neurais de forma que seus índices de reconhecimento correto pudesse ser levantado. Resultados confirmam que redes neurais são capazes de diagnosticar os diferentes regimes de escoamento

Além dos objetivos deste trabalho, os resultados satisfatórios encorajam novos desenvolvimentos tendo como base a aplicação de redes neurais a problemas de análise em escoamentos bifásicos. Como proposta para trabalhos futuros pode-se sugerir o estudo das regiões de transição dos diferentes regimes de escoamento, o uso de técnicas neurais na tomografia de escoamentos e, a medição de frações volumétricas.

7. AGRADECIMENTOS

Este trabalho contou com o financiamento do CNPq (bolsa Dr. de K.C.O.C).

8. REFERÊNCIAS

- Bishop, C. M. (1993). "Neural Network Validation: an Illustration from the Monitoring of Multiphase Flow". IEE Conference Publication 3rd International Conference on Artificial Neural Networks, No.372, pp.41-46.
- Cai, S. Q., Toral, H., Qiu, Jianhung and Aecher, J. S., 1994, "Neural Network Based Objective Flow Regime Identification in Air-Water Two-Phase Flow", Canadian Journal of Chemical Engineering, Vol. 72, No. 3, pp. 440-445.
- Crivelaro, K. C. O., Selegim Jr.,P., Hervieu, E., 2002, "Identification of Horizontal Two-Phase Flow Regimes Through a Neural Network Model. Aceito para publicação na Revista Brasileira de Ciências Mecânica.
- Grubert, J. P., 1995. "Application of Neural Networks in Stratified Flow Stability Analysis", Journal of Hydraulic Engineering, Vol. 121i7, pp. 523-532.
- Giona M., Paglianti A. E Soldati A., 1994, "Diffusional analysis of intermitten flow transitions". Fractals, Vol. 2, pp 256-258.

- Haykin, S., 1994, Neural Network a Comprehensive Foundation. New York, Macmillan College Publishing Company, pp.842.
- Lin, P. Y.; Hanraty, T. J., 1987, "Detection of Slug Flow from Pressure Measurements", Int. J. Multiphase Flow, Vol. 13, No.1, pp.13-21.
- Mi, Y., Ishii, M. and Tsoukalas, L. H., 1998, "Vertical Two-Phase Flow Identification Using Advanced Instrumentation and Neural Network", Nuclear Engineering and Design, No. 184, pp. 409-420.
- Monji, H.; Matsui, G., 1998, "Flow Pattern Identification of Gas-Liquid Two-Phase Flow Using a Neural Network". Third International Conference on Multiphase Flow, Vol. cd-rom, pp. 1-8.
- Sekoguchi, K.; Inoue, K., Imasaka, T. 1987, "Void Signal Analysis and Gas-Liquid Two-Phase Flow Regime Determination by a Statistical Pattern Recognition Method", JMSE International Journal, Vol. 30, No.266, pp.1266-1273.
- Seleglim Jr. P. & Hervieu E., 1998, "An Objective Indicator for Two-Phase Flow Pattern Transition", Nuclear Engineering and Design, Vol. 184, pp. 421-435.
- Smith, T., Ishii, M., Mi Y., Aldorwish, Y., 2001, "Flow Regime Identification Using Impedance Meters and Self-Organizing Neural Networks for Vertical Pipe Sizes: 1/2" 2" 4", 6" ID". Fourth International Conference on Multiphase Flow, New Orleans, Vol. CD-Rom.
- Taitel, Y.; Dukler, A. E., 1976, "A model for Predicting Flow Regime Transitions in Horizontal and Near Horizontal Gas-Liquid Flow". AIChE Journal, Vol. 22, No.1, pp.47-55.
- Wambsganss, M. W.; Jendrzejczyk, J. A.; France, D. M., 1994, "Determination and Characteristics of the Transition to Two-Phase Slug Flow in Small Horizontal Channels", Journal of Fluids Engineering, Vol. 116, pp. 140-146.

IDENTIFICATION AND DIAGNOSIS OF TWO- PHASE FLOW REGIMES THROUGH SELF-ORGANIZING NEURAL NETWORK MODEL

Kelen Cristina Oliveira Crivelaro

Núcleo de Engenharia Térmica e Fluidos
 Universidade de São Paulo
 Av. Trabalhador São-Carlense, 400 – Centro
 CEP: 13566-590 – São Carlos – SP
 e-mail: crivelar@sc.usp.br

Paulo Seleglim Jr.

Núcleo de Engenharia Térmica e Fluidos
 Universidade de São Paulo
 Av. Trabalhador São-Carlense, 400 – Centro
 CEP: 13566-590 – São Carlos – SP
 e-mail: seleglim@sc.usp.br

Eric Hervieu

DRN/DTP/SETEX/LTDF
 Commissariat à l’Energie Atomique
 38054 Grenoble cedex 9 – França

Abstract. One of the main problems related to the transport and manipulation of multiphase flow concerns the existence de characteristic flow regimes and its strong influence on important operation parameters. A good example of this occurs in gas-liquid chemical reactors in which maximum efficiencies can be achieved by maintaining a finely dispersed bubbly flow to maximize the total interfacial area. Thus, the ability to automatically identify flow regimes is of crucial importance,

especially for the adequate operation of multiphase system. In this work a unsupervised neural network, self-organizing maps, is used in association by a direct imaging probe for the identification of horizontal two-phase flow regimes, developed in experimental circuit. More specifically, the signals produced by the probe are used to compose a qualitative image of the flow, which is promptly sent to the network for the recognition of the regimes. Results are presented for different transitions among the flow regimes, which demonstrate the extremely satisfactory performance of the diagnosis system.

Keywords: *Neural Networks, Self-organizing Maps, Two-phase Flow, Flow regimes, Diagnosis.*