



## IDENTIFICAÇÃO DE REGIMES DE ESCOAMENTO BIFÁSICO HORIZONTAL COM AUXÍLIO DE REDES NEURAIS

### **Kelen Cristina Oliveira Crivelaro**

Universidade de São Paulo, Escola de Engenharia de São Carlos, Núcleo de Engenharia Térmica & Fluidos, Av. Dr. Carlos Botelho, 1465, CEP: 13560-250, - São Carlos, SP, Brasil  
e-mail: crivelar@sc.usp.br

### **Paulo Selegim Junior**

Universidade de São Paulo, Escola de Engenharia de São Carlos, Núcleo de Engenharia Térmica & Fluidos, Av. Dr. Carlos Botelho, 1465, CEP: 13560-250 São Carlos - SP, Brasil.

### **Eric Hervieu**

Commissariat à l'Energie Atomique, Service de Thermohydraulic, Laboratoire d'Etude Fondamentales, 17 rue des Martyrs, 38054, Grenoble Cedex 9, França.

**Resumo.** *Um fluido multifásico pode escoar segundo diversos regimes de escoamento. A problemática associada aos sistemas multifásicos refere-se basicamente ao comportamento de parâmetros macroscópicos, tais como perdas de pressão, trocas térmicas, etc., e sua forte ligação com o regime de escoamento. Portanto, do ponto de vista das aplicações industriais, a segurança e a longevidade de equipamentos e instalações somente podem ser asseguradas quando estes operam segundo os regimes de escoamento para os quais foram dimensionados. Isto implica na necessidade de se diagnosticar em tempo real os regimes de escoamento. O diagnóstico automático de regimes de escoamento representa hoje um objetivo de extrema importância, principalmente para as indústrias petroquímica e nuclear. Neste trabalho, uma rede neural 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 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:** *Escoamentos bifásicos, Redes neurais, Regimes de escoamento, Diagnóstico*

## 1. INTRODUÇÃO

Um fluido multifásico pode escoar segundo diversas organizações topológicas chamadas regimes ou configurações de escoamento. Por exemplo, as duas fases de uma mistura gás-líquido podem escoar horizontalmente de forma dispersa (regimes a bolhas ou a gotas pulverizadas) ou segregada (regimes anular e estratificado). Em um leito fluidizado o

escoamento gasoso através do sólido particulado pode ser de tal maneira que a fluidização seja homogênea, borbulhante ou caótica, com a formação de grandes vazios sem forma e movimentos coerentes. A problemática associada aos sistemas multifásicos refere-se basicamente ao comportamento de parâmetros macroscópicos, tais como perdas de pressão, trocas térmicas etc., e sua forte ligação com o regime de escoamento, podendo variar de maneira brutal de uma configuração à outra. Do ponto de vista das aplicações industriais, a segurança e a longevidade de equipamentos e instalações somente pode ser assegurada quando estes operam segundo os regimes de escoamento para os quais foram dimensionados. Isto implica não apenas a capacidade de se diagnosticar em tempo real as configurações de escoamento, mas também a possibilidade de uma eventual transição de regime, afim de retroagir no sentido de evita-la ou simplesmente de minimizar seus efeitos.

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 & Dukler (1976), que é construída a partir de um modelo 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 & 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 Seleghim & 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 & 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. GRUBERT (1995) utilizou uma rede neural do tipo *feedforward* com algoritmo de aprendizagem *backpropagation* (repropagação) para estimar as condições de escoamento quando a mistura interfacial em estruturas estratificadas se iniciam. Monji & Matsui (1998) utilizaram uma rede neural *feedforward* na identificação de regimes de escoamento bifásico gás-líquido. Foram utilizados dois tipos diferentes de padrões de treinamento. O primeiro tipo baseou-se em parâmetros estatísticos relativos às flutuações de fração de vazio. O segundo tipo baseou-se em dados de uma série temporal relativa a flutuação de fase do gás. O presente trabalho consiste em desenvolver e implementar uma rede neural, 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 term nucleares entre outras.

## 2. REDES NEURAI

Inteligência Artificial, Redes Neurais e Conexionismo são técnicas que, até bem pouco tempo atrás não haviam ainda demonstrado a potencialidade em resolver problemas complexos de análise. Entretanto, em todo o mundo, o desenvolvimento de linhas de pesquisa nesses campos teve um grande aporte de recursos humanos e econômicos indicando a confiança depositada pela comunidade científica nesse segmento de trabalho. O progresso mais notável deu-se, em particular, na área de redes neurais, cujos princípios fundamentais estão assentados nos trabalhos de modelagem biológica de processos neurofisiológicos, cognitivos e comportamentais. Nos aspectos teóricos, adquiriu corpo formal coerente com abordagens que vão desde a Teoria dos Sistema Dinâmicos até à Mecânica Estatística. Do ponto de vista prático, implementações tão interessantes tem sido desenvolvidas que, hoje, não se concebe pensar em sistemas de controle, identificação e processamento de sinais sem, pelo menos, fazer-se uma menção às redes neurais (Kovács, 1996).




Figura 1: Esquema de uma rede neural

Uma rede neural *feedforward* com o algoritmo de aprendizagem *backpropagation* consiste de camada de entrada, camada de saída e camadas intermediárias de neurônios. A "Fig". 1 mostra uma rede *feedforward* 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. Tipicamente, a saída do neurônio é normalizada e definida num intervalo fechado  $[0,1]$  ou  $[-1,1]$  (Haykin, 1994). 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. Este erro é retropropagado (*backpropagation*) camada por camada através da rede, donde o nome do algoritmo. Na regra de aprendizado do gradiente descendente, o parâmetro taxa de aprendizado especifica como as correções devem ser feitas aos pesos quando existe um erro. Quando a soma de todos os erros da rede atinge um mínimo global, diz-se que a rede está treinada. Treinamento é um processo iterativo, o qual deve convergir para uma solução correta. Desde que o erro de superfície é multidimensional pode existir vários mínimos locais tanto como mínimos globais. Existe um período em que o processo de treinamento ficará instável e não convergirá, ou ele convergirá para uma solução errada por ficar parado em um mínimo local. Este problema, apesar de ocorrência pouco comum, pode ser contornado introduzindo-se perturbações aleatórias nas correções calculadas.

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 transiente 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". 2. A seção de ensaios é construída em acrílico e suas dimensões são de 60 mm de diâmetro interno e 30 m de comprimento.

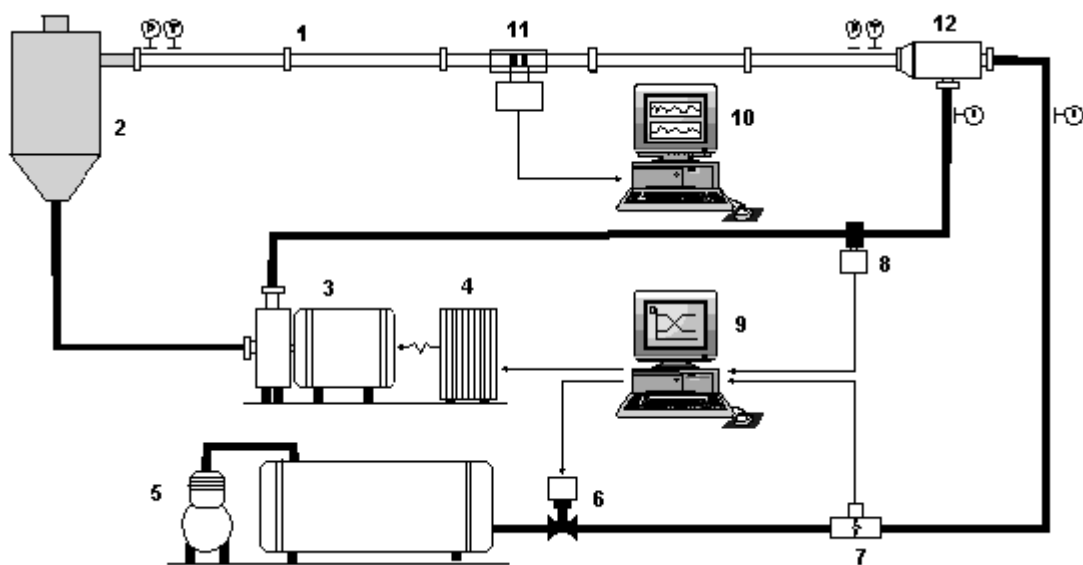


Figura. 2: Circuito experimental, segundo Selegim & Hervieu, (1998) : (1) seção de ensaios, (2) separador, (3) bomba hidráulica, (4) variador de frequência, (5) compressor, (6) servo-válvula, (7) medidor de vazão eletromagnético, (8) medidor de vazão, (9) piloto do circuito, (10) sistema de aquisição 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 Selegim & 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 & Hervieu (1998), consiste de dois anéis de eletrodos de aço inoxidável montados juntos à parede do tubo como ilustrado na "Fig". 3. 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". 3.




Figura 3: Sonda condutiva segundo SELEGHIM & HERVIEU (1998)

## 5. RESULTADOS

Para cada grande família de escoamentos bifásicos horizontais foram realizadas séries de testes 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". 3. Assim, para cada teste, estes sinais foram filtrados (anti-aliasing) e amostrados a taxas de 20 e 30 Hz até o máximo da capacidade das memórias de armazenamento ( $2^{14}$  amostras). A Tabela 1 mostra em detalhes as condições relativas às séries de testes realizados.

A rede neural utilizada neste trabalho foi uma rede *feedforward* com o algoritmo de aprendizagem *backpropagation*. A rede foi implementada no *Neural Networks Toolbox* do Matlab e o computador utilizado foi um Pentium II 300MHz com 148 Mbytes de RAM. No caso, a rede neural possuía uma camada de entrada, uma camada intermediária e uma camada de saída. A arquitetura da rede foi definida de acordo com as necessidades de se obter um bom treinamento. O número de neurônios das camadas intermediárias foi ajustado no sentido de capacitar a rede a aprender tarefas complexas pela extração progressiva de aspectos significantes dos padrões de entrada (Haykin,1994). 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, a camada intermediária foi composta por 200 neurônios e a de saída um neurônio.

A função de ativação utilizada foi a *sigmóide logística* em todas as camadas. O modelo de cada neurônio na rede inclui uma não linearidade da saída. O ponto importante a ser enfatizado é que a não linearidade é diferenciável em toda parte, sendo esta uma característica importante na utilização do algoritmo *backpropagation*. Uma forma comumente usada de não linearidade que satisfaz este requisito é a função sigmóide logística.

Tabela 1 : Codificação dos ensaios (Seleglim, 1996)

Codificação	Ensaio	Qg (m <sup>3</sup> /h)	Ql (m <sup>3</sup> /h)
1	estratificado – intermitente	5	0.5 à 3
2	estratificado – intermitente	10	0.5 à 3
3	estratificado – intermitente	40	0.5 à 3
4	estratif. liso - estratif. Ondulado	10 à 40	0.5
5	estratif. liso - estratif. Ondulado	10 à 40	0.2
6	estratif. ondulado - estratif. Rugoso	30 à 60	0.75
7	estratif. ondulado - estratif. Rugoso	30 à 60	0.5
8	estratif. Ondulado - estratif. Rugoso	30 à 60	0.2
9	intermitente – bolhas	5	5 à 50
10	intermitente – bolhas	7.5	5 à 50
11	intermitente – bolhas	10	5 à 50
12	intermitente – anular	70 à 250	2

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 o número de eletrodos e as linhas o número de 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 6 segundos caracterizariam bem os ensaios 1, 2, 3, 4, 6, 7, 9, 10, 11, 12. Porém, este mesmo intervalo de tempo para os ensaios 5 e 8 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 0,6 segundos.

Depois do treinamento verifica-se a generalização (diagnóstico) da rede neural. Uma rede é dita generalizar bem, quando a relação entrada/saída calculada por ela está correta ou bem próxima de uma resposta correta para os padrões entrada/saída que não foram usados no treinamento da rede. Para a generalização sinais característicos de diferentes regimes foram apresentados à rede neural de forma que seus índices de reconhecimento correto pudessem ser levantados. A partir daí calculou-se a porcentagem de acerto da rede neural de acordo com a generalização dos diferentes regimes apresentados. Veja Tabela 2.

Conforme se pode observar, as taxas de acerto são bastante satisfatórias, tendo chegado a um máximo de 99% e com um índice médio de acerto de 82,8%. Com relação aos ensaios em que o acerto ficou abaixo da média diversos fatores contribuíram para isso.

Para os ensaios 1, 2, 3, 9, 10, e 11 (ver Tabela 2), tem-se que o regime de escoamento estratificado se caracteriza como um regime onde o líquido escoar ao longo do fundo do tubo e gás escoar ao longo do topo do tubo. O regime de escoamento intermitente se caracteriza por uma fase líquida homogênea e por uma interface gás líquida lisa. O regime de escoamento intermitente é usualmente dividido em dois subregimes: bolhas\bolhas alongadas e *slug*. No subregime *slug* a configuração do escoamento é considerada aerada e a interface gás-líquida

tem uma estrutura turbulenta. São conhecidos como bolsões de ar. Os escoamentos intermitentes horizontais podem ser interpretados como uma alternância entre porções de escoamento estratificado e a bolhas.

Quando a rede se deparou com uma dessas alternâncias no escoamento intermitente, obviamente classificou como regime de escoamento estratificado ou à bolhas. Por isso nesses ensaios obteve-se uma porcentagem abaixo da média.

Tabela 2: Porcentagem de acerto da rede neural

Ensaio	Taxa de aprend.	Intervalo de tempo	% Acerto
1	0,02	6s	80%
2	0,02	6s	87%
3	0,02	6s	70%
4	0,01	6s	99%
5	0,01	0,6s	90%
6	0,01	6s	98%
7	0,01	6s	77%
8	0,02	0,6s	80%
9	0,02	6s	70%
10	0,02	6s	72%
11	0,02	6s	72%
12	0,02	6s	99%

Nos ensaios 4, 5, 6, 7 e 8 (ver Tabela 2), tem-se que o regime de escoamento estratificado liso se caracteriza por uma interface desprovida de oscilações significativas. O regime de escoamento estratificado ondulado se caracteriza pela presença de ondulações coerentes ou regulares na interface de segregação entre o líquido e o gás. Partindo de uma configuração estratificada ondulada e aumentando a vazão de ar, a vazão constante de água, é possível observar uma situação em que as ondas superficiais perdem completamente sua coerência, produzindo uma interface de aspecto rugoso.

A diferença entre estratificado liso e estratificado ondulado é bem acentuada e a transição ocorre abruptamente, então esses regimes de escoamentos são bem diferenciados um do outro. Por isso ocorreu um acerto bem maior pela rede. Do escoamento ondulado para o rugoso essa diferença não é tão acentuada e por isso provocou uma porcentagem de acerto menor pela rede neural.

No ensaio 12 (ver Tabela 2), tem-se que os escoamentos anulares ocorrem quando a velocidade do gás é suficientemente forte para romper os bolsões de líquido, obrigando este último a escoar na região parietal do conduto. O filme anular apresenta, em geral, ondulações não regulares. Em faixas específicas de vazão, pode igualmente apresentar ondas anulares periódicas, formadas pela deposição de pequenas gotas que fluem dispersas no escoamento central gasoso de alta velocidade. O escoamento anular tem características bem distintas do escoamento intermitente, por isso obteve-se uma melhor porcentagem de acerto pela rede neural.

## 6. CONCLUSÕES

Neste trabalho, são mostradas redes neurais para identificação de regimes de escoamento bifásico em um tubo horizontal. Para treinar as redes utilizou-se os dados obtidos de uma sonda capaz de produzir imagens qualitativas do escoamento sem necessidade de reconstrução

numérica (tomografia). Para verificar a generalização (diagnóstico) das redes neurais foram utilizados novos dados obtidos da mesma sonda, i.e. dados diferentes daqueles empregados no treinamento. 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 às redes 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. As porcentagens de acerto foram satisfatórias, obtendo-se uma porcentagem mínima de 70%, uma porcentagem média de 82,8% e uma porcentagem máxima de 99%.

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.

### ***Agradecimentos***

Este trabalho contou com o financiamento da CAPES (bolsa MsC de K.C.O.C) e FAPESP (Projeto individual de pesquisa Proc. 96/3663 - 3).

### **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*, n.372, p.41-46, May.
- Giona M., Paglianti A. E Soldati A., 1994, Diffusional analysis of intermittent flow transitions. *Fractals*, vol. 2, pp 256-258.
- Grubert, J. P. , 1995, Application of neural networks in stratified flow stability analysis, *Journal of Hydraulic Engineering*, vol. 121i7, pp. 523-532.
- Haykin, S., 1994, *Neural network a comprehensive foundation*. New York, Macmillan College Publishing Company.
- Kovács, Z. L., 1996, *Redes Neurais Artificiais: Fundamentos e Aplicações*, São Paulo.
- Lin, P. Y.; Hanratty, T. J., 1987, Detection of slug flow from pressure measurements, *Int. J. Multiphase Flow*, vol. 13, n.1, pp.13-21.
- Monji, H.; Matsui, G., 1998, Flow pattern identification of gas-liquido two-phase flow using a neural network. *Third International Conference on Multiphase Flow*, vol. cd-rom, pp. 1-8, Jun.
- Sekoguchi, K.; Inoue, K., Imasaka, T. 1987, Void signal analysis and gas-liquido two-phase flow regime determination by a statistical pattern recognition method, *JMSE International Journal*, vol. 30, n.266, pp.1266-1273.
- Seleghim Jr. P. & Hervieu E., 1998, An objective indicator for two-phase flow pattern transition, *Nuclear Engineering and Design*, vol. 184, pp. 421-435.
- Seleghim, P. Jr., 1996, *Caractérisation des changements de configuration d'un écoulement diphasique horizontal par l'application de méthodes d'analyse temps-fréquence*, docteur. These, Institut National Polytechnique de Grenoble, France, Grenoble, France.
- Taitel, Y.; Dukler, A. E., 1976, A model for predicting flow regime transitions in horizontal and near horizontal gas-liquido flow. *AIChE Journal*, vol. 22, n.1, pp.47-55, Jan.



Wambsganss, M. W.; Jendrzeczyk, 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, Mar.

## **HORIZONTAL TWO PHASE FLOW PATTERN IDENTIFICATION BY NEURAL NETWORKS**

**Abstract.** A multiphase fluid can flow according to several flow regimes. The problem associated with multiphase systems are basically related to the behavior of macroscopic parameters, such as pressure drop, thermal exchanges and so on, and their strong correlation to the flow regime. From the industrial applications point of view, the safety and longevity of equipment and systems can only be assured when they work according to the flow regimes for which they were designed to. This implies in the need to diagnose flow regimes in real time. The automatic diagnosis of flow regimes represents an objective of extreme importance, mainly for applications on nuclear and petrochemical industries. In this work, a neural network is used in association to a probe of direct visualization for the identification of a gas-liquid flow horizontal regimes, developed in an 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 network, Multiphase flow, Flow regimes, Diagnosis,