

## DESENVOLVIMENTO DE REDES NEURAIIS PARA O PROCESSAMENTO DE SINAIS ACÚSTICOS VISANDO A MEDIÇÃO DE PROPRIEDADES TOPOLÓGICAS EM ESCOAMENTOS BIFÁSICOS A BOLHAS

**Érica Regina Filletti**

Escola de Engenharia de São Carlos  
Universidade de São Paulo  
Av. Trabalhador Sãoocarlense, 400  
13560-970 São Carlos - SP  
filletti@sc.usp.br

**Paulo Seleglim Júnior**

Escola de Engenharia de São Carlos  
Universidade de São Paulo  
Av. Trabalhador Sãoocarlense, 400  
13560-970 São Carlos - SP  
seleglim@sc.usp.br

**Resumo.** Um novo método para medir a fração volumétrica e a área interfacial em escoamentos bifásicos é proposto neste trabalho, baseado em redes neurais para processar respostas obtidas de sinais acústicos. A distribuição geométrica das fases no escoamento é mapeada pela velocidade local de propagação acústica, considerada na equação diferencial que governa o problema. Esta equação é resolvida numericamente pelo método de diferenças finitas com condições de contorno reproduzindo a estratégia de excitação/medida. Um número significativo de distribuições das velocidades de propagação foi considerado na solução da equação diferencial para construir uma base de dados, da qual os parâmetros da rede são ajustados. O modelo neural é construído para mapear características extraídas dos sinais obtidos de quatro sensores acústicos, localizados no contorno do domínio de sensoriamento, estimando a fração volumétrica e a área interfacial. Os resultados numéricos mostram que o modelo neural pode ser treinado em um tempo computacional razoável e é capaz de reproduzir precisamente a relação entrada/saída do conjunto de treinamento. O erro em avaliar a fração volumétrica e a área interfacial de novas distribuições de velocidade de propagação é menor que 40% no pior caso. Entretanto, este erro pode ser significativamente reduzido com a otimização da arquitetura da rede neural.

**Palavras chave:** escoamentos bifásicos, monitoração acústica, fração volumétrica, área interfacial, redes neurais artificiais

### 1. Introdução

A monitoração acústica de processos industriais surge como uma técnica extremamente interessante, sobretudo em aplicações envolvendo o transporte e a manipulação de escoamentos multifásicos. Em específico, tanto podem ser mensurados parâmetros físicos (vazões, densidade, viscosidade, fração volumétrica, temperatura e outros), quanto é possível obter informações mais completas sobre a fenomenologia do processo, normalmente expressas através de imagens montadas diretamente ou reconstruídas numericamente a partir dos sinais de resposta acústica (Lynch, 1991). Dentre as principais vantagens da monitoração acústica (robustez, imunidade a ruídos elétricos, baixo custo e outras), a possibilidade de se fazer o sensoriamento de forma não intrusiva e não invasiva é fundamental para algumas aplicações em que não são possíveis intervenções mais diretas, seja para a instalação dos equipamentos de medida ou mesmo das próprias sondas. No caso do sensoriamento acústico, a propriedade que o ultra-som tem de atravessar diferentes materiais permite que o sensoriamento seja feito por simples contato com as paredes da tubulação.

Um dos parâmetros mais importantes para descrever regimes de escoamento bifásico é, sem dúvida, a fração de vazio. A medição desse parâmetro apresenta um crescimento importante em muitos processos industriais, tais como físicos, químicos e petrolíferos. Por esta razão, diversas técnicas de medida da fração volumétrica têm sido desenvolvidas por pesquisadores nos últimos anos. Dong *et al.* (2003) empregam um sistema de tomografia de resistência elétrica para calcular a fração volumétrica de escoamentos bifásicos. Huang, Wang e Li (2003) utilizam a técnica de tomografia por capacitância elétrica para o desenvolvimento de um novo método

de medição de fração volumétrica para escoamentos bifásicos. Prasser, Misawa e Tiseanu (2005) medem a fração volumétrica utilizando um sensor de fio elétrico e também através de tomografia de raio-x.

Neste sentido, um dos objetivos deste trabalho é o desenvolvimento de uma ferramenta numérica para o monitoramento acústico de escoamentos bifásicos. Particularmente, deseja-se determinar e quantificar como os campos de sensoriamento acústico se estabelecem, tendo em vista sua interação com a topologia do escoamento, assim como com a geometria da tubulação. De fato, um problema bastante importante relacionado aos métodos ultra-sônicos é a complexidade dos sinais de resposta. Mais especificamente, a resposta a um pulso acústico é composta de múltiplos sinais gerados nas interfaces do escoamento multifásico (reflexões e dispersão), e também nas paredes da tubulação (ecos múltiplos). Conseqüentemente, os sensores acústicos localizados na superfície externa de um tubo metálico que contém um fluido multifásico capturaram formas de ondas complexas, mesmo em resposta a um único pulso de excitação tipo Dirac (onda acústica com todas as frequências). Recuperar informações sobre a estrutura geométrica do escoamento a partir destes sinais de resposta implica em resolver um problema inverso mal-posto.

Em específico pretende-se investigar a possibilidade de usar uma rede neural para avaliar diretamente a estrutura geométrica do escoamento a partir dos sinais de resposta medidos no contorno do domínio de sensoriamento. Assim, a necessidade de se resolver um problema inverso é evitada e um método de medida muito mais robusto pode ser desenvolvido. Para isto, o problema de monitoração acústica é resolvido no sentido direto para calcular os correspondentes sinais de resposta. A base de dados assim constituída é usada para treinar uma rede neural para produzir as estimativas da área interfacial e da fração volumétrica, tendo como dados de entrada algumas características extraídas dos sinais de resposta. Estas características correspondem ao tempo de chegada da onda acústica e às amplitudes e aos tempos dos três maiores picos.

## 2. Descrição do Problema

A propagação de ondas acústicas no interior de um volume de sensoriamento  $\Omega$  pode ser modelada com auxílio da equação (Kinsler *et al.*, 1999)

$$\frac{\partial^2 P(t, \vec{x})}{\partial t^2} - c^2(\vec{x}) \nabla^2 P(t, \vec{x}) = 0, \quad \text{para } (t, \vec{x}) \in \mathbb{R}_+ \times \Omega \quad (1)$$

onde  $P$  é a pressão acústica,  $c(\vec{x})$  é a velocidade local do som. É importante enfatizar que a velocidade local do som mapeia a distribuição da fase dentro do volume de medida  $\Omega$ . As condições inicial e de contorno que modelam a excitação/estratégia da medida são dadas por

$$P(0, \vec{x}) = \begin{cases} 1, & \text{se } \vec{x} \in L_{exc} \\ 0, & \text{se } \vec{x} \in \Omega - L_{exc} \end{cases} \quad (2)$$

$$\vec{n} \cdot \vec{\nabla} P(t, \vec{x}) = 0, \quad \text{para } (t, \vec{x}) \in \mathbb{R}_+^* \times \partial\Omega \quad (3)$$

$$R_k(t) = \oint_{s \in L_k} P(t, \vec{x}) ds, \quad \text{para } L_k \in \partial\Omega \quad (4)$$

$L_{exc}$  na Eq. (2) denota o elemento responsável pela excitação,  $R_k(t)$  e  $L_k$  na Eq. (4) representam, respectivamente, o sinal de resposta e o  $k$ -ésimo elemento de medição (que pode corresponder a  $L_{exc}$ ).

De um ponto de vista físico, a estrutura geométrica de um escoamento disperso pode ser caracterizada pela área interfacial volumétrica, definida como

$$\Gamma(t) = \frac{A_i(t)}{V} \quad (5)$$

onde  $A_i(t)$  é a área interfacial instantânea de todas as gotas circunscritas em um volume de controle  $V$ . Aceita-se geralmente que  $\Gamma(t)$  governa trocas interfaciais com o seguinte princípio (Ishii, 1987, 1990):

$$\text{Transferência interfacial} = \Gamma(t) \times \text{força motriz} \quad (6)$$

Conseqüentemente,  $\Gamma(t)$  é relacionado fortemente à massa, momento e transferências de energia e, um conhecimento exato desta variável é crucial para uma operação eficiente de um processo industrial de escoamentos multifásicos.

Um outro parâmetro importante na caracterização de escoamento disperso é a fração volumétrica, definida por

$$\alpha(t) = \frac{V_b(t)}{V} \quad (7)$$

onde  $V_b(t)$  representa o volume ocupado pelas gotas no volume  $V$ . A fração volumétrica é fortemente relacionada à distribuição da fase e é um parâmetro requerido para projetos hidrodinâmico e térmico de várias aplicações. Por exemplo, a aglutinação das bolhas tende a aumentar significativamente em um reator de coluna para  $\alpha > 0,3$ , com conseqüente redução na taxa da reação.

Um esboço do sensor proposto é mostrado na Fig. (1). A idéia básica é aplicar um pulso de excitação através de um elemento piezoelétrico e capturar as respostas correspondentes medidas diretamente nos elementos piezoelétricos. Como mencionado antes, apesar do pulso da excitação que é simples na forma, um delta de Dirac por exemplo, as respostas medidas têm geralmente uma forma complexa devido aos ecos múltiplos e às difrações associados com as paredes da tubulação e com a mistura multifásica.

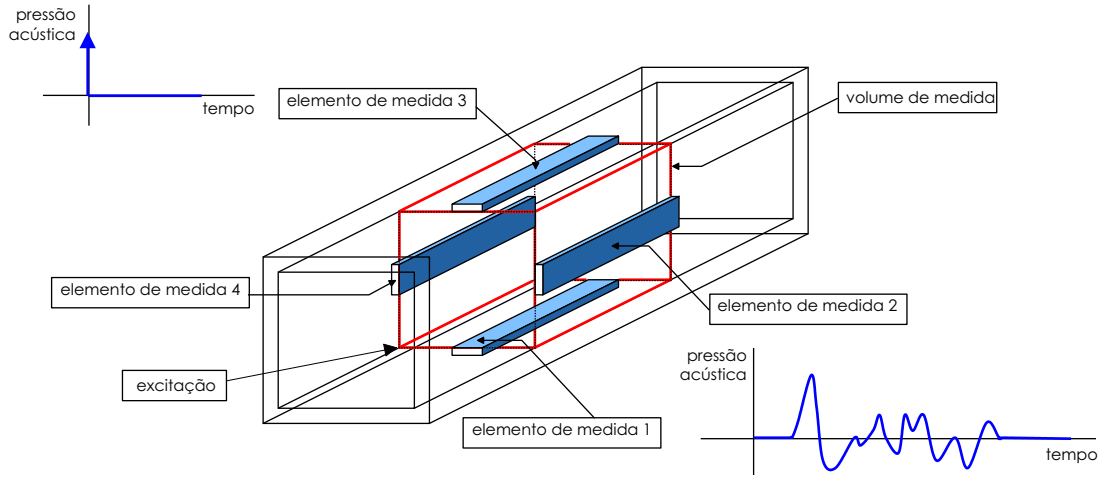


Figura 1: Esboço do sensor proposto - a resposta a um sinal de excitação tipo Dirac tem uma forma complexa devido às reflexões múltiplas e às difrações que ocorrem dentro da mistura multifásica e com as paredes da tubulação.

### 3. Construção do Modelo Numérico

O problema físico-matemático é transformado em um problema numérico e são formuladas rotinas de solução com base no Método de Diferenças Finitas (MDF), que apresenta algumas vantagens como, por exemplo, ser de fácil e rápida implementação.

Considerando a geometria do problema, sobretudo a disposição dos elementos de medida, justifica-se desprezar as variações axiais de forma a obter uma equação bidimensional. A Eq. (1) é adimensionalizada e discretizada utilizando-se a formulação à esquerda no tempo e a formulação central no espaço. A derivada parcial de segunda ordem com relação ao tempo é aproximada por diferenças à esquerda de segunda ordem e as derivadas parciais com relação ao espaço são aproximadas por diferenças centradas, também de segunda ordem, obtendo-se

$$\frac{1}{\Delta t^2} (P_{i,j}^k - 2P_{i,j}^{k-1} + P_{i,j}^{k-2}) - \frac{c_{i,j}^2}{\Delta x^2} (P_{i+1,j}^k - 2P_{i,j}^k + P_{i-1,j}^k) - \frac{\lambda c_{i,j}^2}{\Delta y^2} (P_{i,j+1}^k - 2P_{i,j}^k + P_{i,j-1}^k) = 0. \quad (8)$$

onde  $i$  e  $j$  indicam as coordenadas na malha, nas direções  $x$  e  $y$ , respectivamente,  $\Delta t = 10^{-6}$  e

$$\Delta x = \frac{L_x}{N-1}, \quad (9)$$

$$\Delta y = \frac{L_y}{M-1}, \quad (10)$$

sendo que  $N$  e  $M$  são os números de pontos nos intervalos  $[0, L_x]$  e  $[0, L_y]$ ,  $L_x$  e  $L_y$  são as dimensões da tubulação nas direções  $x$  e  $y$ , respectivamente. A tubulação considerada tem geometria quadrada, de lados  $L_x = L_y = 1$ , e  $N = M = 30$ .

Reorganizando a Eq. (8) de modo a agrupar os termos em  $P$ , obtém-se

$$\begin{aligned} & \left( \frac{1}{\Delta t^2} + \frac{2c_{i,j}^2}{\Delta x^2} + \frac{2\lambda c_{i,j}^2}{\Delta y^2} \right) P_{i,j}^k + \left( -\frac{c_{i,j}^2}{\Delta x^2} \right) P_{i+1,j}^k + \\ & \left( -\frac{c_{i,j}^2}{\Delta x^2} \right) P_{i-1,j}^k + \left( -\frac{\lambda c_{i,j}^2}{\Delta y^2} \right) P_{i,j+1}^k + \left( -\frac{\lambda c_{i,j}^2}{\Delta y^2} \right) P_{i,j-1}^k + \\ & \left( -\frac{2}{\Delta t^2} \right) P_{i,j}^{k-1} + \left( \frac{1}{\Delta t^2} \right) P_{i,j}^{k-2} = 0, \end{aligned} \quad (11)$$

Como a velocidade local do som mapeia a distribuição de fase no escoamento, utiliza-se a velocidade de propagação acústica na água, ou seja,  $c_{\text{água}} = 1,48 \frac{Km}{s}$  e no óleo,  $c_{\text{óleo}} = 1,7 \frac{Km}{s}$  (óleo de motor SAE 30), uma vez que o escoamento simulado neste trabalho é um escoamento óleo-água em que a fase contínua é água e a fase dispersa (gotas) é óleo.

As gotas são geradas aleatoriamente em cada teste numérico de modo que não haja intersecção entre elas. Outra imposição é que a fração volumétrica esteja no intervalo  $[0, 0.3]$ , já que o escoamento de interesse é um escoamento disperso. Alguns casos são ilustrados na Fig. (2).




Figura 2: Geração aleatória de gotas.

Na formulação bidimensional, a área interfacial e a fração volumétrica são calculadas, respectivamente, por

$$\Gamma(t) = \frac{\sum P_i(t)}{A} \quad (12)$$

$$\alpha(t) = \frac{\sum A_i(t)}{A} \quad (13)$$

onde  $P_i$  e  $A_i$  são o perímetro e a área instantâneos de todas as gotas circunscritas na seção transversal da tubulação, respectivamente, e  $A$  é a área total da seção transversal.

#### 4. Sinais Acústicos

Os sinais de pressão acústica adquiridos neste trabalho através das simulações numéricas têm uma estrutura muito complexa, mesmo em resposta a um único pulso de excitação tipo Dirac, aplicado em um dos vértices da seção transversal do quadrado, como mostra a Fig. (1). Essa complexidade deve-se aos ecos múltiplos nas paredes da tubulação e também às reflexões e dispersão da onda acústica. Outro fator que influencia na forma dos sinais de resposta é a configuração do escoamento, neste caso, um escoamento disperso, uma vez que a velocidade de propagação acústica é diferente na fase contínua (água) e na fase dispersa (óleo).

Como pode ser observado na Fig. (1), neste trabalho são obtidos 4 sinais de resposta  $R_k(t)$ ,  $k = 1, \dots, 4$ , dados pela Eq. (4), para cada teste numérico realizado. São extraídas algumas características destes sinais, tais

como a tempo de chegada,  $T$ , da onda acústica em cada um dos elementos de medida, as amplitudes dos três maiores picos dos sinais,  $A_1$ ,  $A_2$  e  $A_3$ , bem como o tempo de chegada desses picos, indicados por  $T_1$ ,  $T_2$  e  $T_3$  na Fig. (3), a fim de particularizar a complexidade do sinal em um nível suficiente para a inferência da área interfacial e da fração volumétrica.




Figura 3: Sinal acústico e as respectivas características extraídas.

### 5. Redes Neurais Artificiais

Uma rede neural pode ser definida como um mapeamento não-linear dos dados de entrada e saída. Isto é realizado através das camadas de neurônios com suas respectivas funções de ativação, em que as coordenadas de entrada são somadas de acordo com pesos e *bias* específicos para produzir uma única saída. Neste trabalho, a rede utilizada é a rede *feed-forward*, onde o fluxo de informação dos neurônios da camada de entrada até os neurônios da camada de saída segue estritamente adiante, isto é, as conexões de um neurônio são sempre para outros neurônios da camada posterior, como é mostrado na Fig. (4).

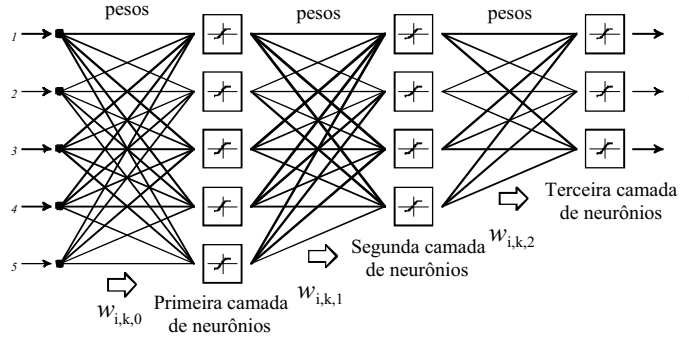


Figura 4: Representação esquemática de uma rede neural feed-forward mapeando um vetor com 5 elementos de entrada em um vetor com 3 elementos de saída.

Formalmente, se a função da ativação do  $i$ -ésimo neurônio da  $j$ -ésima camada é indicada por  $F_{i,j}(\cdot)$ , sua saída  $s_{i,j}$  pode ser calculada a partir da saída da camada anterior  $s_{i,j-1}$  e dos correspondentes *bias*  $b_{i,j}$  e pesos  $w_{i,k,j-1}$  (o segundo índice  $k$  indica o neurônio da  $j-1$ -ésima camada, na qual a conexão está sendo estabelecida) de acordo com a expressão

$$s_{i,j} = F_{i,j} \left( b_{i,j} + \sum_k w_{i,k,j-1} s_{k,j-1} \right) \tag{14}$$

Os valores da entrada e da saída da rede são denotados, respectivamente, por  $\eta_i$  e  $\xi_i$ , a relação que mapeia entrada e saída pode ser obtida aplicando sucessivamente a Eq. (14), que para o exemplo da Fig. (4) resulta

$$\xi_i = F_{i,3} \left( b_{i,3} + \sum_{k=1}^4 w_{i,k,2} F_{k,2} \left( b_{k,2} + \sum_{m=1}^5 w_{k,m,1} F_{m,1} \left( b_{m,3} + \sum_{n=1}^5 w_{m,n,0} \eta_n \right) \right) \right) \tag{15}$$

A Eq. (15) mostra claramente que a relação entre  $\eta_i$  e  $\xi_i$  é definida escolhendo-se as funções de ativação e ajustando-se os pesos e *bias*. Entre muitas, uma característica muito importante das redes neurais é a capacidade de aprendizagem, isto é, a possibilidade de ajustar os pesos e *bias* através de uma regra conveniente de treinamento para reproduzir os pares de entrada e saída. O algoritmo de *back-propagation* é a heurística de treinamento mais utilizada e melhor adaptada para as redes *feed-forward*. É baseada na aplicação iterativa do método da redução do gradiente instantâneo, a partir do cálculo das derivadas primeiras de uma função de erro convenientemente definida, cujos argumentos são os parâmetros da rede (pesos e *bias*). Uma descrição detalhada do algoritmo de *back-propagation* é encontrada em Haykin (1999). Em linhas gerais, as etapas básicas da implementação do algoritmo de *back-propagation* utilizado neste trabalho são as seguintes:

- (i) Inicializar os parâmetros da rede  $b_{i,j}$  e  $w_{i,k,j}$  com valores aleatórios.
- (ii) A partir de um conjunto de treinamento com pares de entrada/saída, tomar o  $p$ -ésimo par  $(\eta_i^p, \delta_i^p)$ , calcular a saída da rede com a mesma entrada e formar o par  $(\eta_i^p, \xi_i^p)$ .
- (iii) Calcular o erro entre a saída desejada  $(\delta_i^p)$  e a saída obtida  $(\xi_i^p)$  de acordo com a norma euclidiana

$$e = \sqrt{\sum_i (\delta_i^p - \xi_i^p)^2} \quad (16)$$

- (iv) Calcular as derivadas do erro  $e$  em relação a  $w_{i,k,j}$  e  $b_{i,j}$ .
- (v) Modificar os pesos e *bias* da rede de acordo com o método da redução do gradiente instantâneo, e de uma determinada taxa de aprendizado  $\gamma$

$$b_{i,j} \leftarrow b_{i,j} - \gamma \frac{\partial e}{\partial b_{i,j}} \quad (17)$$

$$w_{i,k,j} \leftarrow w_{i,k,j} - \gamma \frac{\partial e}{\partial w_{i,k,j}} \quad (18)$$

- (vi) Iterar entre os passos 2 e 5, modificando sucessivamente  $b_{i,j}$  e  $w_{i,k,j}$  até que seja atingido um determinado número de épocas de aprendizado ou que o erro seja inferior a um determinado valor limite.

O desempenho da rede neural é profundamente afetado por sua arquitetura interna (número de camadas ocultas e número de neurônios em cada uma delas) e pelo tipo de interconexões (*feed-forward*, recorrentes). A forma exata da função de ativação limita os efeitos no desempenho geral da rede e é ajustada de acordo com as necessidades da heurística de treinamento (função sigmoideal no exemplo do algoritmo de *back-propagation*).

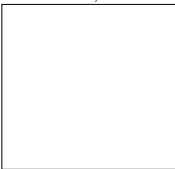
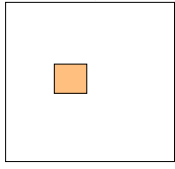
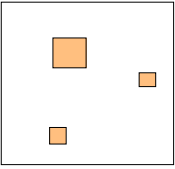
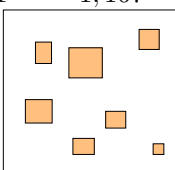
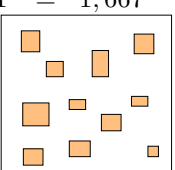
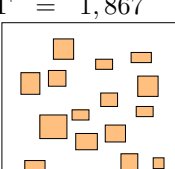
A rede utilizada neste trabalho foi implementada no *Neural Networks Toolbox* do MATLAB 6.0 em um computador AMD Athlon (TM) XP 2600+ com 2,08 GHz e 1,5 GB de RAM. Sua arquitetura consiste de uma camada de entrada com 24 neurônios, duas camadas intermediárias e uma camada de saída com 2 neurônios. 16 neurônios foram utilizados na primeira camada intermediária e 12 na segunda. As funções de ativação utilizadas são a tangente sigmoideal nas camadas intermediárias e a função linear na camada de saída. Cada neurônio da camada de saída é responsável por estimar um dos seguintes parâmetros do escoamento bifásico disperso: área interfacial e fração volumétrica.

O procedimento de treinamento constitui em adquirir sinais de pressão acústica do escoamento de interesse para cada simulação numérica realizada e extrair algumas particularidades que caracterizam a complexidade do sinal em um nível suficiente para a inferência da área interfacial e da fração volumétrica para compor o conjunto de treinamento.

## 6. Resultados e Discussão

São realizados 300 testes numéricos simulando escoamento bifásico disperso. Para tanto, impõe-se que a fração volumétrica varie aleatoriamente de maneira uniforme entre 0 e 0,3 conforme mencionado anteriormente. A área interfacial resultante limita-se entre 0 e 2,5 devido à malha utilizada nas simulações. A Tab. (1) ilustra alguns destes casos, mostrando também as respectivas características dos sinais de medida mapeados pela rede neural.

Tabela 1: Características extraídas dos sinais de resposta para diferentes testes numéricos.

Distribuição de gotas	Elemento de medida 1	Elemento de medida 2	Elemento de medida 3	Elemento de medida 4
$\alpha = 0,000$ $\Gamma = 0,000$ 	$T = 0,155$ $T_1 = 0,368$ $T_2 = 1,748$ $T_3 = 2,802$ $A_1 = 0,594$ $A_2 = 0,376$ $A_3 = 0,249$	$T = 0,525$ $T_1 = 0,794$ $T_2 = 1,283$ $T_3 = 3,181$ $A_1 = 0,585$ $A_2 = 0,351$ $A_3 = 0,247$	$T = 0,536$ $T_1 = 0,803$ $T_2 = 1,261$ $T_3 = 3,179$ $A_1 = 0,563$ $A_2 = 0,340$ $A_3 = 0,238$	$T = 0,173$ $T_1 = 0,392$ $T_2 = 1,745$ $T_3 = 2,792$ $A_1 = 0,585$ $A_2 = 0,368$ $A_3 = 0,257$
$\alpha = 0,027$ $\Gamma = 0,167$ 	$T = 0,144$ $T_1 = 0,343$ $T_2 = 0,455$ $T_3 = 1,743$ $A_1 = 0,576$ $A_2 = 0,376$ $A_3 = 0,332$	$T = 0,512$ $T_1 = 0,776$ $T_2 = 1,274$ $T_3 = 3,163$ $A_1 = 0,544$ $A_2 = 0,387$ $A_3 = 0,269$	$T = 0,533$ $T_1 = 0,800$ $T_2 = 1,248$ $T_3 = 3,155$ $A_1 = 0,628$ $A_2 = 0,319$ $A_3 = 0,209$	$T = 0,173$ $T_1 = 0,394$ $T_2 = 1,730$ $T_3 = 2,778$ $A_1 = 0,703$ $A_2 = 0,391$ $A_3 = 0,284$
$\alpha = 0,093$ $\Gamma = 0,530$ 	$T = 0,155$ $T_1 = 0,370$ $T_2 = 1,720$ $T_3 = 0,489$ $A_1 = 0,625$ $A_2 = 0,370$ $A_3 = 0,326$	$T = 0,524$ $T_1 = 0,791$ $T_2 = 1,255$ $T_3 = 3,794$ $A_1 = 0,654$ $A_2 = 0,279$ $A_3 = 0,209$	$T = 0,530$ $T_1 = 0,791$ $T_2 = 1,254$ $T_3 = 3,140$ $A_1 = 0,627$ $A_2 = 0,406$ $A_3 = 0,266$	$T = 0,162$ $T_1 = 0,372$ $T_2 = 1,274$ $T_3 = 1,434$ $A_1 = 0,477$ $A_2 = 0,383$ $A_3 = 0,305$
$\alpha = 0,187$ $\Gamma = 1,167$ 	$T = 0,154$ $T_1 = 0,359$ $T_2 = 0,474$ $T_3 = 0,561$ $A_1 = 0,885$ $A_2 = 0,606$ $A_3 = 0,440$	$T = 0,501$ $T_1 = 0,766$ $T_2 = 0,479$ $T_3 = 1,227$ $A_1 = 0,654$ $A_2 = 0,313$ $A_3 = 0,288$	$T = 0,519$ $T_1 = 0,777$ $T_2 = 0,478$ $T_3 = 0,366$ $A_1 = 0,779$ $A_2 = 0,322$ $A_3 = 0,292$	$T = 0,168$ $T_1 = 0,378$ $T_2 = 0,489$ $T_3 = 1,667$ $A_1 = 0,742$ $A_2 = 0,517$ $A_3 = 0,382$
$\alpha = 0,271$ $\Gamma = 1,667$ 	$T = 0,150$ $T_1 = 0,352$ $T_2 = 1,648$ $T_3 = 0,470$ $A_1 = 0,627$ $A_2 = 0,312$ $A_3 = 0,275$	$T = 0,492$ $T_1 = 0,746$ $T_2 = 1,213$ $T_3 = 3,630$ $A_1 = 0,454$ $A_2 = 0,220$ $A_3 = 0,213$	$T = 0,506$ $T_1 = 0,759$ $T_2 = 1,803$ $T_3 = 0,478$ $A_1 = 0,423$ $A_2 = 0,184$ $A_3 = 0,175$	$T = 0,150$ $T_1 = 0,433$ $T_2 = 0,343$ $T_3 = 0,497$ $A_1 = 0,333$ $A_2 = 0,296$ $A_3 = 0,294$
$\alpha = 0,227$ $\Gamma = 1,867$ 	$T = 0,144$ $T_1 = 0,361$ $T_2 = 0,462$ $T_3 = 2,700$ $A_1 = 0,574$ $A_2 = 0,355$ $A_3 = 0,317$	$T = 0,505$ $T_1 = 0,763$ $T_2 = 1,250$ $T_3 = 0,475$ $A_1 = 0,628$ $A_2 = 0,324$ $A_3 = 0,254$	$T = 0,515$ $T_1 = 0,775$ $T_2 = 1,215$ $T_3 = 0,472$ $A_1 = 0,548$ $A_2 = 0,273$ $A_3 = 0,266$	$T = 0,162$ $T_1 = 0,389$ $T_2 = 1,691$ $T_3 = 0,505$ $A_1 = 0,588$ $A_2 = 0,414$ $A_3 = 0,360$

A análise dos histogramas destas características mostra que algumas delas são mais ricas em informação do que outras, sendo conveniente para o treinamento da rede excluir aquelas menos relevantes. Em outras palavras, uma característica que sofre pouca ou nenhuma influência da distribuição interna de velocidade de propagação acústica funciona como um *bias* na entrada da rede. Esta informação, não sendo relevante para o cálculo da fração volumétrica e da área interfacial, tem os respectivos pesos diminuídos durante o processo de treinamento. Porém, estes pesos são inicializados aleatoriamente durante o início do treinamento e, conseqüentemente, o número total de épocas deverá aumentar. Portanto, as características a serem consideradas doravante são as seguintes:  $T_1$ ,  $T_2$ ,  $T_3$ ,  $A_1$ ,  $A_2$  e  $A_3$ . A característica  $T$  foi descartada. Abaixo são mostrados alguns destes histogramas a título de ilustração, sendo que na Fig. (5) estão os histogramas da amplitude do maior pico dos sinais de resposta obtidos nos elementos de medida 1 e 2. Já na Fig. (6), encontram-se os histogramas do tempo de chegada da onda acústica nos elementos de medida 1 e 2, característica descartada por não ser muito influenciada pela distribuição local de velocidade de propagação acústica.




Figura 5: Histogramas da maior amplitude dos sinais de pressão acústica obtidos (a) no elemento 1 e (b) no elemento 2.




Figura 6: Histogramas do tempo de chegada da onda acústica dos sinais de pressão obtidos (a) no elemento 1 e (b) no elemento 2.

Os resultados do treinamento da rede mostram que ela é capaz de reproduzir precisamente a relação entrada/saída dos dados do conjunto de treinamento, tanto para a fração volumétrica quanto para a área interfacial. Para a generalização, os dados característicos de testes numéricos com novas distribuições de velocidade local de propagação acústica são apresentados à rede neural, e o erro em estimar a fração volumétrica e a área interfacial é menor que 40% no pior caso. A Fig. (7) mostra a comparação entre os valores estimados pela rede neural e os valores reais para a fração de vazio e área interfacial, respectivamente, onde os pontos azuis são referentes ao treinamento da rede e os pontos vermelhos referem-se à generalização.

## 7. Conclusões

Uma nova metodologia para a medida não intrusiva da fração volumétrica e da área interfacial é proposta neste trabalho, utilizando sensoriamento acústico e resolvendo o problema inverso associado através do desen-






Figura 7: Comparação entre os valores estimados pela rede neural e os valores reais para a fração volumétrica e área interfacial, respectivamente.

volvimento e treinamento de uma rede neural. O modelo matemático é construído a partir das equações de propagação acústica.

A rede neural é treinada com dados oriundos de simulações numéricas. Para a realização de tais simulações, desenvolve-se uma ferramenta numérica capaz de calcular a propagação acústica em meios heterogêneos. Este simulador é utilizado para construir uma base de dados constituída de distribuições de velocidade de propagação acústica geradas aleatoriamente, das quais são extraídas os tempos de chegada das ondas acústicas, a amplitude dos três maiores picos de cada sinal obtido, bem como os tempos de chegada destes picos. Após concluída esta etapa, realiza-se a implementação de uma família de modelos conexionistas. Em seguida, faz-se o treinamento dos melhores modelos com exemplos extraídos da base de dados, buscando determinação de parâmetros como a fração volumétrica e a área interfacial.

Os resultados numéricos mostram que o modelo neural pode ser treinado em um tempo computacional razoável e é capaz de reproduzir precisamente a relação entrada/saída do conjunto de dados do treinamento. O erro em avaliar a fração volumétrica e a área interfacial de novas distribuições de velocidade de propagação acústica é menor que 40% no pior caso. Entretanto, este erro pode ser significativamente reduzido com a otimização da arquitetura da rede neural.

Trabalhos futuros incluem estudos em um domínio tridimensional, além de outras geometrias de tubulação. Também podem ser analisados outros escoamentos, como o escoamento ar-água. Uma outra proposta de trabalho futuro é a implementação de outros tipos de redes neurais. Outra possibilidade, é refinar a malha nas simulações numéricas, afim de obter maiores valores para a área interfacial.

## 8. Agradecimentos

Este trabalho foi realizado com suporte financeiro do PROSET CT-Petro CNPq 01/2002 (processo no 500101/2002-7) e da FAPESP (processo no 03/13819-6).

## 9. Referências

- Dong, F.; Jiang, Z. X.; Qiao, X. T.; Xu, L. A., 2003, "Application of electrical resistance tomography to two-phase pipe flow parameters measurement". *Flow measurement and instrumentation*, Vol. 14, pp. 183-192.
- Haykin, S., 1999, "Neural Networks: a comprehensive foundation". 2nd ed. New Jersey: Prentice Hall, 900p.
- Huang, Z.; Wang, Li, H., 2003. "Application of electrical capacitance tomography to the void fraction measurement of two-phase flow". *IEEE Transactions on Instrumentation and Measurement*, Vol. 52, No. 1, pp. 7-12.
- Ishii M., 1987, "Interfacial area modeling", in G.F. Hewitt, J.M. Delhaye and N. Zuber (eds.), *Multiphase Science and Technology*, Vol. 3, Hemisphere Publishing/Springer-Verlag, pp. 31-61.
- Ishii M., 1990, "Two-fluid model for two-phase flow", in G.F. Hewitt.
- Kinsler L.E., Frey A.R., Coppens A.B. E Sanders J.V., 1999, "Fundamentals of Acoustics", John Wiley & Sons,

245p.

Lynch J., 1991, "Non intrusive multiphase flow measurement techniques (bibliographic review)", Revue de l'Institut Francais du Petrole, Vol. 46, No. 1, pp. 59-88.

Prasser, H. M.; Misawa, M.; Tiseanu, I., 2005. "Comparison between wire-mesh sensor and ultra-fast X-ray tomograph for an air-water flow in a vertical pipe". Flow Measurement and Instrumentation, Vol. 16, pp. 73-83.

## DEVELOPMENT OF NEURAL NETWORKS FOR THE PROCESSING OF ACOUSTIC SIGNALS AIMING AT THE MEASUREMENT OF TOPOLOGICAL PROPERTIES IN BUBBLY TWO-PHASE FLOWS

### Érica Regina Filletti

Escola de Engenharia de São Carlos  
Universidade de São Paulo  
Av. Trabalhador São-carlense, 400  
13560-970 São Carlos - SP  
filletti@sc.usp.br

### Paulo Seleglim Júnior

Escola de Engenharia de São Carlos  
Universidade de São Paulo  
Av. Trabalhador São-carlense, 400  
13560-970 São Carlos - SP  
seleglim@sc.usp.br

**Abstract.** *A new method for measuring the void fraction and interfacial area in two-phase flows is proposed in this work, based on neural network processing the responses obtained from an acoustic interrogation signal. The geometrical distribution of the phases within the flow is mapped by the local acoustic propagation velocity, considered in the governing differential equation. This equation is solved numerically by the finite difference method with boundary conditions reproducing the excitation/measurement strategy. A significant number of propagation velocities distributions were considered in the solution of the differential equation in order to construct a database from which the neural model parameters could be adjusted. The neural model is constructed to map features extracted from the signals delivered by four acoustic sensors, placed on the external boundary of the sensing domain, into the corresponding void fraction and interfacial area. Numerical results shown that the neural model can be trained in a reasonable computational time and is capable of reproducing quite accurately the input/output relation of the training data set. The error in assessing the void fraction and interfacial area from new propagation velocity distributions is less than 40% in the worst case. However, this error can be significantly reduced through optimization of the neural network architecture.*

**Keywords:** *two-phase flow, acoustic monitoring, void fraction, interfacial area, artificial neural network.*