UNIVERSIDADE DE SÃO PAULO
ESCOLA DE ENGENHARIA DE SÃO CARLOS
DEPARTAMENTO DE ENGENHARIA MECÂNICA

UTILIZAÇÃO DE REDES NEURAIS AUTO-ORGANIZATIVAS PARA IDENTIFICAÇÃO DE REGIMES DE ESCOAMENTO BIFÁSICO HORIZONTAL AR-ÁGUA

Kelen Cristina Oliveira Crivelaro

Orientador: **Prof. Assoc. Paulo Seleghim Jr.**

DEDALUS - Acervo - EESC
31100050093

Tese apresentada à Escola de Engenharia de São Carlos, da Universidade de São Paulo, como parte dos requisitos para obtenção do título de Doutor em Engenharia Mecânica.

EESC - USP
Biblioteca
CAMPUS DE S. CARLOS

São Carlos
2004

Serviço de Pós-Graduação EESC/USP

EXEMPLAR REVISADO

Data de entrada no Serviço 22/12/04

Ass.:

Class. TESE-EESC
Cutt. 2572
Tombo T312/04
Sysno 1415146

Ficha catalográfica preparada pela Seção de Tratamento
da Informação do Serviço de Biblioteca – EESC/USP

C936u

Crivelaro, Kelen Cristina Oliveira
Utilização de redes neurais auto-organizativas para identificação de regimes de escoamento bifásico horizontal ar-água / Kelen Cristina Oliveira Crivelaro. -- São Carlos, 2004.

Tese (Doutorado) -- Escola de Engenharia de São Carlos-Universidade de São Paulo, 2004.
Área: Engenharia Mecânica.
Orientador: Prof. Assoc. Paulo Seleghim Jr.

1. Redes neurais. 2. Mapas auto-organizativos. 3. Escoamentos bifásicos. 4. Regimes d escoamento. 5. Diagnóstico I. Título.

FOLHA DE JULGAMENTO

Candidata: Licenciada **KELEN CRISTINA OLIVEIRA CRIVELARO**

Tese defendida e julgada em 31-08-2004 perante a Comissão Julgadora:

APROVADA

Prof. Associado. **PAULO SELEGHIM JÚNIOR (Orientador)**
(Escola de Engenharia de São Carlos/USP)

APROVADA

Prof. Dr. **CARLOS DIAS MACIEL**
(Escola de Engenharia de São Carlos/USP)

APROVADA

Prof. Dr. **FLAVIO DONIZETI MARQUES**
(Escola de Engenharia de São Carlos/USP)

APROVADA

Prof. Dr. **ANDRÉ CARLOS PONCE DE LEON FERREIRA DE CARVALHO**
(Instituto de Ciências Matemáticas e de Computação/USP)

Aprovado

Dr. **EMERSON DOS REIS**
(Universidade Estadual de Campinas/UNICAMP)

Prof. Associado **JONAS DE CARVALHO**
Coordenador do Programa de Pós-Graduação
em Engenharia Mecânica

Profa. Titular **MARIA DO CARMO CALIJURI**
Presidente da Comissão de Pós-Graduação

Para a memória exemplar de minha mãe, Isabel Crivelaro,

pelo seu amor, confiança, entusiasmo e firmeza que tornou a conclusão desta tese de doutorado possível e deixou muitas saudades.

Para meu pai Osvaldo Crivelaro,

meu reconhecimento pelo esforço para vencer dificuldades e pela boa formação e incentivo ao longo de toda minha carreira, sinto-me orgulhosa disto.

AGRADECIMENTOS

Agradeço a Deus por suas bênçãos e por me manter perseverante em meus objetivos.

Ao Prof. Dr. Paulo Seleghim Jr. pela orientação e otimismo na realização deste trabalho. Mesmo com dificuldades e imprevistos, conseguimos finalizá-lo.

Ao Prof. Dr. Flávio D. Marques pelo auxílio no desenvolvimento dos resultados numéricos e pelas valiosas contribuições ao manuscrito, tanto no estilo como no contexto.

Ao meu namorado Geraldo pela paciência, compreensão e amor.

À Gi, minha grande amiga e companheira de todos os momentos, quero expressar a minha eterna gratidão.

À Luciane pelas discussões teóricas sobre redes neurais e sugestões relevantes para a conclusão deste trabalho. Mas, principalmente pela amizade de todos esses anos.

À Luciana pelo companheirismo durante todos esses anos de república e pela sua sinceridade e amizade.

A Paulo Roberto pela disposição, paciência e amizade. Suas idéias foram fundamentais para a concretização deste trabalho.

Aos meus amigos Alessandro, Cláudio, Érica, Fabiana, Graziela, Helder, Juliana, Rodrigo, Teodora e Vanessa.

Ao Sr. Romualdo e D. Nilza pelo acolhimento, conselhos e lições de vida. Vocês também são responsáveis pelo meu sucesso.

Aos técnicos do laboratório, Donizeti, Hélio, Jorge, Luchesi, Roberto Lourenço e Roberto Prataviera. Este projeto de pesquisa de doutorado não estaria completo sem as suas participações.

À Beth, grande amiga, pelos conselhos, bom humor e alegria.

À minha vó Carmem, minha tia Edna e meu irmão Marcelo pelo exemplo de vida e incentivo nesta caminhada.

À todos da minha família que sempre estiveram ao meu lado me apoiando com todo amor.

Sumário

LISTA DE FIGURAS....iii

LISTA DE TABELAS....vi

RESUMO....vii

ABSTRACT....viii

1 - INTRODUÇÃO....1

2 – OBJETIVOS....4

3 – REVISÃO BIBLIOGRÁFICA....5

3.1 - Regimes de escoamento....5

3.1.1 - Regimes de escoamento gás-líquido horizontal....5

3.2 - Técnicas de medidas em escoamento multifásico 7

3.2.1 – Fração de vazio local....8

3.2.2 – Perda de pressão....9

3.2.3 – Análise fractal....11

3.2.4 – Método estatístico....11

3.2.5 - Análise de sinais....12

3.2.6 – Transdutor de Impedância....13

3.2.7 - Tomografia....15

3.2.8 – Redes neurais....16

4 - METODOLOGIA....23

4.1 - Redes neurais....23

4.1.1 - Modelo do neurônio e arquitetura de redes....23

4.2 – Redes neurais auto-organizativas....26

4.2.1 – Grade de neurônios....27

4.2.2 – Funções topológicas e funções distância....28

4.2.3 – Arquitetura de uma rede neural competitiva....30

4.2.4 – Formação do mapa auto-organizativo....31

4.2.4.1 – Processo competitivo....32

4.2.4.2 – Processo Cooperativo....33

4.2.4.3 – Processo adaptativo....36

4.2.4.3.1 – Fase 1: Fase de ordenação....38

4.2.4.3.2 – Fase 2: Fase de regulagem....38

4.2.5 – Inicialização dos pesos....39

4.2.6 – Regra de aprendizagem e *bias*....39

4.2.7 – Generalização....40

4.3. – Exemplo de aplicação de uma rede neural auto-organizativa....41

4.4 – Instalações experimentais....45

5 - RESULTADOS....48

6 - CONCLUSÕES E SUGESTÕES....62

REFERÊNCIAS BIBLIOGRÁFICAS....64

LISTA DE FIGURAS

Figura 3.1 – Regimes de escoamento em dutos horizontais..... 7

Figura 3.2 -- a) Transdutor genérico para fração local; b) sinal característico (MOREIRA, 1989)..... 9

Figura 3.3 – Esquema básico de um transdutor de impedância..... 14

Figura 4.1 – Neurônio de entrada simples (HAGAN et. al., 1996)..... 24

Figura 4.2 – Esquema de uma rede neural *feedforward* com três camadas..... 25

Figura 4.3 – Grade bidimensional de neurônios 28

Figura 4.4 – Grade retangular de neurônios 29

Figura 4.5 – Grade hexagonal de neurônios 29

Figura 4.6 – Grade aleatória de neurônios 30

Figura 4.7 – Arquitetura de uma rede neural competitiva 31

Figura 4.8 – Função Gaussiana..... 34

Figura 4.9 – Conceito de vizinhança..... 36

Figura 4.10 – Exemplo de ajuste de uma rede neural auto–organizativa sobre pontos do $\Re^3$ concentrados sobre os centróides (1,1,1), (2,2,2), (3,3,3) 43

Figura 4.11 – Exemplo de ajuste de uma rede neural auto–organizativa sobre pontos do $\Re^3$ concentrados sobre os centróides (1,1,1), (2,2,2), (3,3,3) – valores finais após treinamento 45

Figura 4.12 – Representação esquemática do oleoduto piloto do

Núcleo de Engenharia Térmica & Fluidos (NET&F) 46

Figura 4.13 – Foto do oleoduto piloto do Núcleo de Engenharia Térmica & Fluidos (NET&F) 47

Figura 5.1 – Mapa de Taitel e Dukler (1976) construído para um escoamento ar-água em tubulação horizontal de 30 mm de diâmetro interno..... 49

Figura 5.2 – Dados de entrada do regime de escoamento anular para à rede neural..... 50

Figura 5.3 – Dados de entrada do regime de escoamento bolhas para à rede neural..... 51

Figura 5.4 – Dados de entrada do regime de escoamento intermitente para à rede neural 51

Figura 5.5 – Dados de entrada do regime de escoamento estratificado liso para à rede neural 52

Figura 5.6 – Dados de entrada do regime de escoamento estratificado ondulado para à rede neural..... 52

Figura 5.7 – Dados de entrada do regime de escoamento anular para à rede neural..... 53

Figura 5.8 – Exemplos de entrada de cada regime de escoamento e os respectivos pesos dos neurônios..... 54

Figura 5.9 – Regime de escoamento anular e pesos do neurônio 1..... 55

Figura 5.10 – Regime de escoamento estratificado rugoso e pesos do neurônio 2..... 55

Figura 5.11 – Regime de escoamento a bolhas e pesos do neurônio

10..... 56

Figura 5.12 – Regime de escoamento intermitente e pesos do neurônio 4..... 56

Figura 5.13 – Regime de escoamento estratificado liso e pesos do neurônio 7..... 57

Figura 5.14 – Regime de escoamento estratificado ondulado e pesos do neurônio 8..... 57

Figura 5.15 – Gráfico da identificação da rede neural..... 58

Figura 5.16 – Gráfico da identificação da rede neural..... 59

Figura 5.17 – Gráfico da identificação da rede neural..... 61

LISTA DE TABELAS

TABELA 5.1 – Codificação dos ensaios..... 48

TABELA 5.2 – Neurônio de Identificação dos regimes de escoamento pela rede neural depois de treinada..... 53

Tabela 5.3 – Dados da simulação..... 60

Resumo

Crivelaro, K. C. O. (2004). Redes neurais auto-organizativas utilizadas na identificação de regimes de escoamento bifásico horizontal ar/água. São Carlos, 2004. 70p. Tese (Doutorado) Escola de Engenharia de São Carlos, Universidade de São Paulo.

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 reatores químicos gás-líquido no qual máximos coeficientes de reação podem ser alcançados mantendo-se 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. Este trabalho se constituirá no desenvolvimento e implementação de uma rede neural auto-organizativa especializada ao problema de identificação de regimes de escoamento bifásico ar-água em tubo horizontal. Os regimes reconhecidos em tubo horizontal são seis: estratificado liso, estratificado ondulado, estratificado rugoso, intermitente, bolhas e anular. Para tanto, pretende-se tomar como ponto de partida as medidas capacitivas, variação de pressão da tubulação e medida de pressão "flutuante" como padrões associativos a serem armazenados na rede neural. Posteriormente, a fase de treinamento da rede neural consistirá em identificar os coeficientes sinápticos apropriados, a partir de um conjunto representativo de ensaios. Nesse trabalho optou-se por uma arquitetura com 10 neurônios na camada de entrada, portanto uma quantidade maior do que o número de regimes que se deseja identificar. O objetivo é ver se a rede neural consegue encontrar de forma autônoma os seis regimes já conhecidos, mesmo tendo 10 neurônios na grade. Isso demonstra a habilidade da rede neural auto-organizativa em identificar regimes de escoamento mesmo em situações onde não há conhecimento prévio dos mesmos. Serão feitas simulações para verificar o desempenho da rede neural a partir de dados experimentais coletados no oleoduto piloto do Núcleo de Engenharia Térmica e Fluidos da Escola de Engenharia de São Carlos.

Palavras-chave: Redes Neurais, Mapas auto-organizativos, Escoamentos bifásicos, Regimes de scoamento, Diagnóstico.

Crivelaro, K. C. O. (2004).Self-organizing neural networks for the identification of ar-water horizontal two-phase flow regimes. São Carlos, 2004. 70p. Tese (Doutorado) Escola de Engenharia de São Carlos, Universidade de São Paulo.

One of the main problems related to the transport and manipulation of multiphase flow is the existence of flow regimes and its strong influence on important parameters of operation. As an example of it occurs in gas-liquid chemical reactor in which maximum coefficients of reaction can be reached by keeping a maximal flow bubbly dispersed into a total interfacial area. Thus, the ability to identify flow regimes automatically is very important, specially in order to obtain a properly operation of multiphase systems. This work consists in the development and implementation of a self-organizing neural networks specially for the problem of identification of regimes of two-phase flow air-water in horizontal pipe. The regimes recognized in horizontal pipe are six: estratified smooth, estratified wavy, estratified rugged, intermittent, bubbly and annular. The capacitive measures, variation of pressure of the piping and measure of flutuante pressure were considered as a starting point to be stored as associative standards in the neural networks. After, the phase of training of the neural networks consisted of an appropriate identification for the sinaptic coefficients from a representative set of tests. An architectural input-layer of 10 neurons was opted. Therefore a bigger amount of regimes than the ones usually required. The objective is to see if the neural network is able to find independently the six regimes already known, even having 10 neurons in the grid. This demonstrates the ability of the self-organizing maps neural network in identifying flow regimes in situations where one does not have previous knowledge of them. Simulations will be made to verify the performance of the neural network from experimental data collected in the pilot pipe-line of the Nucleus of Thermal Engineering and Fluids of the School of Engineering of São Carlos.

Keywords: neural networks, self-organizing maps, two phase flow, flow regimes, diagnosis.

Capítulo 1 - Introdução

A existência de padrões dinâmicos característicos ou regimes é, sem sombra de dúvida, uma das características mais importantes relacionada à engenharia dos escoamentos multifásicos. Isso justifica o número bastante expressivo de trabalhos técnicos e científicos produzidos na área, sejam eles focalizados sobre aspectos tecnológicos específicos como modelos de perda de carga para situações e regimes determinados sejam, igualmente, voltados a aspectos mais abrangentes como é o caso da construção de critérios objetivos e universais para a identificação de regimes de escoamento multifásico.

Mas o que são regimes de escoamento ? Na ausência de um entendimento maior sobre a questão diferentes pesquisadores trabalham com diferentes definições e o resultado é uma profusão de termos derivados de conceitos muitas vezes conflitantes. Exemplo: um regime (ou padrão ?) de escoamento é "reconhecido", "diagnosticado", "identificado" ou "detectado" ?

Sobre a primeira questão levantada, i.e. o que é um regime de escoamento, pode-se evocar conceitos da teoria dos sistemas dinâmicos para chegar a uma definição, mesmo que formal. Assim, admitindo que exista um conjunto de equações diferenciais que descreva o comportamento de um escoamento bifásico, um regime de escoamento pode ser interpretado como uma trajetória característica no espaço de fase definido pelas variáveis de descrição do sistema de equações.

A diferença entre reconhecer, diagnosticar, identificar ou detectar um regime de escoamento não é unicamente um problema de semântica, mas sim uma questão de se definir, de forma objetiva em que condições e situação experimental o regime deve ser analisado. Do ponto de vista das aplicações que desenvolvemos, a análise pode ocorrer segundo duas situações típicas: 1) quando se tem conhecimento a priori sobre a existência ou não de regimes de escoamento e quais são eles, como são os casos de escoamentos horizontal e vertical em duto circular, e 2) quando não se sabe da existência de regimes característicos de escoamento e muito menos quais seriam eles, como é o caso de um tanque com formato atípico com várias entradas e saídas, por exemplo.

Nestas circunstâncias, as diferentes formas de analisar um regime de escoamento têm significados diferentes:

• "Reconhecer" um regime de escoamento pressupõe confrontar o que se observa com aquilo que se conhece e, portanto, requer conhecimento, a priori, sobre suas características. Exemplos típicos desse tipo de análise são aquelas baseadas na confrontação das chamadas "assinaturas" do regime.

• "Diagnosticar" implica em reconhecer a partir de um conjunto de "sintomas" e não por comparação direta, requerendo igualmente conhecimento a priori. Nesse tipo de abordagem se enquadram trabalhos fundamentados na definição de um espaço de caracterização ("feature space") com eixos correspondendo a quantificadores estatísticos. Desta forma, uma realização do escoamento é virtualmente representada por um ponto no espaço de caracterização e, por sua vez, um regime de escoamento é caracterizado por um aglomerado ("cluster") característico de pontos.

• "Identificar" um regime sugere um trabalho investigativo, de levantamento de indícios que confirmem a tese de que um determinado grupo de escoamentos é constituído por variantes de uma mesma trajetória característica no espaço de fase associado às equações que descrevem o fenômeno e, portanto, constituem um regime de escoamento autêntico. Trabalhos que se enquadram nesse contexto normalmente fazem uso de metodologias de decisão, dentre as

quais se destacam a teoria bayesiana, quantização vetorial e os mapas ou redes auto-organizativas.

• "Detectar" um regime de escoamento se associa ao seu monitoramento em linha, num processo industrial por exemplo. Dependendo da relação entre atraso e precisão, pode ser implementado com base na assinatura do regime (detecção da assinatura) ou com base em seu espaço de caracterização.

Tendo em vista estas idéias, os objetivos estabelecidos para esse trabalho se enquadram no que se entende por identificação de regimes de escoamento. Será desenvolvida e implementada uma rede neural auto-organizativa, que constituirá a lógica básica de um dispositivo de sensoreamento capaz de diagnosticar em tempo real o regime de escoamento no conduto de testes. Mais precisamente, será estudado o problema de identificação de regimes de escoamento bifásico ar/água em tubo horizontal. Deve-se ressaltar que é um assunto de importância 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.

A contribuição deste trabalho de pesquisa é que os dados de entrada na rede neural não terão nenhum pré-processamento, facilitando assim uma implementação em tempo real. Ao que se sabe, na literatura não se encontra aplicação de redes neurais auto-organizativas na identificação de regimes de escoamento bifásico com esse tipo de dado de entrada.

Capítulo 2 - Objetivos

Conforme dito anteriormente, este trabalho se constituirá no desenvolvimento e implementação de uma rede neural auto-organizativa especializada ao problema de identificação de regimes de escoamento bifásico ar-água em tubo horizontal. Os regimes reconhecidos em tubo horizontal são seis: estratificado liso, estratificado ondulado, estratificado rugoso, intermitente, bolhas e anular. Para tanto, pretende-se tomar, como ponto de partida, as medidas capacitivas, variação de pressão da tubulação e medida de pressão "flutuante" como padrões associativos a serem armazenados na rede neural. Posteriormente, a fase de treinamento da rede neural consistirá em identificar os coeficientes sinápticos apropriados, a partir de um conjunto representativo de ensaios. Nesse trabalho optou-se por uma arquitetura com 10 neurônios na camada de entrada, portanto uma quantidade maior do que o número de regimes ou classes que deseja identificar. O objetivo é ver se a rede consegue encontrar, de forma autônoma, os seis, regimes já conhecidos mesmo tendo 10 neurônios na grade. Isso demonstrará a habilidade da rede neural auto-organizativa em identificar regimes de escoamento mesmo em situações onde não há conhecimento prévio dos mesmos. Serão feitas simulações para verificar o desempenho da rede neural a partir de dados coletados no oleoduto piloto do Núcleo de Engenharia Térmica e Fluidos da Escola de Engenharia de São Carlos.

CAPÍTULO 3 - REVISÃO BIBLIOGRÁFICA

3.1 - Regimes de Escoamento

Quando um líquido é vaporizado em um tubo aquecido, o líquido e o vapor gerado distribuem-se segundo configurações espaciais características, conhecidas como regimes de escoamento. Os regimes de escoamento dependem das vazões das fases, da pressão, da temperatura, do fluxo de calor e geometria do tubo. Do ponto de vista do projeto de dispositivos para transporte e manipulação de misturas multifásicas, a grande importância atribuída aos regimes de escoamento se deve à possibilidade de associá-los à modelos simplificados para o cálculo de parâmetros macroscópicos como perda de carga, taxas de transferência de calor, etc. Na literatura especializada, é comum caracterizar os regimes de escoamento de acordo com a orientação do conduto, seja ele vertical ou horizontal. Neste trabalho de pesquisa, os regimes de escoamento estudados serão em tubo horizontal, por isso será dada uma atenção especial a este tipo de escoamento.

3.1.1 - Regimes de escoamento gás-líquido horizontal

Os regimes de escoamentos bifásicos observados em tubos e condutos horizontais tornam-se complexos pela assimetria das fases, resultando da influência da força gravitacional (COLLIER,1981). Os regimes de escoamento geralmente mais aceitos são discutidos e mostrados abaixo.

Escoamento a bolhas: No escoamento a bolhas, o gás ou vapor é distribuído na forma de bolhas discretas imersas em uma fase líquida contínua. As bolhas podem ser pequenas e esféricas ou podem ser grandes com uma capa esférica

e uma capa plana. Neste último estado, apesar do tamanho das bolhas não se aproximar do diâmetro do tubo, pode existir alguma confusão com o escoamento intermitente. As bolhas de vapor tendem a percorrer na parte superior do tubo (COLLIER,1981). Veja Figura 3.1.a

Escoamento estratificado: Este regime ocorre somente para velocidades muito baixas do líquido e vapor (COLLIER,1981). Segundo Drahos & Cermak (1989), escoamento estratificado é definido como um regime no qual o líquido segue ao longo do fundo do tubo e o gás ao longo do topo do tubo. Três sub-regimes podem ser distinguidos: estratificado liso, estratificado ondulado e estratificado rugoso.

Escoamento estratificado liso: caracterizado por uma interface desprovida de oscilações significativas. Veja Figura 3.1.b

Escoamento estratificado ondulado: Aumentando a velocidade do vapor a interface é perturbada e formam-se ondas que seguem na direção do escoamento. Veja Figura 3.1.c

Escoamento estratificado rugoso: 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 (SELEGHIM & HERVIEU, 1998a). Veja Figura 3.1.d

Escoamento intermitente: A característica deste regime de escoamento é uma distribuição axial não uniforme da fase líquida no tubo. O regime de escoamento intermitente é usualmente dividido em dois sub-regimes: bolhas/bolhas alongadas e pistão de líquido. A forma é caracterizada por uma fase líquida homogênea e por uma interface gás-líquido lisa; a estrutura do escoamento é irregular, bolhas alongadas e pequenas seguem ao longo do topo do tubo. No último sub-regime, os pistões são principalmente aerados e a interface gás-líquido tem uma estrutura turbulenta (DRAHOS & CERMAK,1989). Veja Figura 3.1.e.

Figura 3.1 – Regimes de escoamento em dutos horizontais

Escoamento Anular: Uma alta velocidade da fase gasosa resultará na formação de uma região contínua de gás no centro com um filme líquido ao redor da periferia do tubo. A região central usualmente contém gotículas líquidas quando a velocidade do gás for suficientemente alta para arrancá-las do filme anular. Para baixas velocidades do gás existe uma estrutura ondulada no fundo onde a camada líquida é mais espessa. Grandes ondas aparecem somente no tubo momentaneamente. Este regime é usualmente denominado de regime de escoamento anular ondulado. Veja Figura 3.1.f

3.2 – Técnicas de medidas em escoamento multifásico

A tecnologia de escoamento multifásico teve grande impulso com a indústria do petróleo por volta de 1950. A maioria dos pesquisadores usavam dados obtidos de testes feitos em laboratório. Esses dados incluíam vazão volumétrica de gás, vazão de escoamento líquido, propriedades físicas de cada fase, diâmetro do tubo, ângulo de inclinação e pressão na entrada e na saída do tubo. Em alguns casos, regimes de escoamento foram observados e o líquido era medido com uma válvula.

Segundo França et al. (1991), a primeira proposta de mapas de regime de escoamento foi baseada na identificação visual da distribuição de fase.

Enquanto a identificação visual de regimes de escoamento pode ser adequada para muitos casos, em certas situações esse método é ineficaz ou muito subjetivo.

Os fluidos eram tratados como misturas homogêneas. As fases de gás e líquido escoavam, supostamente, com velocidades diferentes e com efeitos inicialmente estimados por meio de correlações de líquido empírico. Mapas de regimes de escoamento empíricos, freqüentemente baseados em grupos dimensionais, foram usados. Equações de gradiente de pressão foram desenvolvidas com base nos princípios de conservação da massa e do momento, aplicados a misturas homogêneas. Perdas de pressão por atrito foram colocadas na equação de escoamento de fase simples. Alguns pesquisadores também usaram um fator multiplicativo empírico para representar o aumento de atrito resultante de uma segunda fase.

Em 1970, a indústria do petróleo começou a identificar alguns mecanismos físicos básicos, para identificar regimes de escoamento e velocidade de bolhas de gás em colunas de líquido. Nesse período, surgiu a carta de Taitel e Dukler (1976), que foiconstruída a partir de um modelo físico que prediz as relações entre as seguintes variáveis nas transições de regime de escoamento: velocidade superficial de gás e líquido, propriedades físicas dos fluidos e geometria da tubulação. Os mecanismos da transição são baseados em conceitos físicos adaptados às observações do escoamento bifásico feitos em laboratório (BRILL, 1992).

A seguir serão apresentados os instrumentos mais conhecidos para medição de escoamentos mutlifásicos.

3.2.1 - Fração de vazio local

Dentre as diversas variáveis que podem ser usadas no diagnóstico de regimes de escoamento, a fração de vazio é, sem dúvida, uma das mais importantes.

Diversas técnicas de medição de fração de vazio têm sido utilizadas pelos pesquisadores nos últimos 40 anos. Os mais variados princípios são utilizados no sentido de se quantificar, ou apenas acusar, a presença de uma

das fases na mistura bifásica. Há técnicas de medição que requerem instrumentação sofisticada, como os aparelhos de absorção de raio X, a técnicas mais acessíveis, como os sensores resistivos (MOREIRA, 1989).

Os instrumentos utilizados para medição de fração de vazio local são caracterizados por informar a presença (ou ausência) de uma das fases numa pequena região localizada no interior do escoamento bifásico. Quanto menor for o tamanho da extremidade sensora, tanto mais os sinais do sensor se aproximarão da função densidade de fase, X_k.

Por exemplo, um pequeno sensor, Figura 3.2.a, é imerso na mistura. Conforme gás ou líquido atinge a extremidade sensora, sinais elétricos característicos são gerados. Dessa forma, o resultado final é um gráfico do tipo daquele esboçado na Figura 3.2.b.

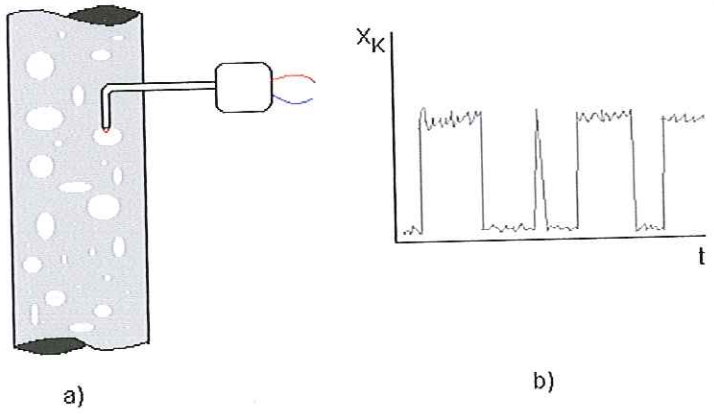

Figura 3.2 – a) Transdutor genérico para fração local; b) sinal característico (MOREIRA, 1989)

3.2.2 - Perda de pressão

É bem conhecido que, em escoamento bifásico, uma mudança de regime de escoamento é freqüentemente associada com uma mudança abrupta em perda de pressão (WAMBSGANSS et al. 1994).

Existem numerosas melhorias nas correlações e métodos para prever a perda de pressão em escoamento gás-líquido. Poucas delas levam em consideração a estrutura altamente complexa de um escoamento bifásico. Deve-se manter em mente que a estrutura do escoamento varia com o tempo e

posição do tubo. Como resultado, a diferença de pressão entre dois pontos também varia com o tempo e seu cálculo direto não é praticável. Além disso, pesquisadores têm desenvolvido técnicas para prever as diferenças de pressão baseadas nas condições do escoamento (DANIELS, 1995).

Lin & Hanraty (1987) utilizaram a técnica de medida de pressão para detecção de regime de escoamento intermitente. O regime de escoamento intermitente foi obtido para escoamento de ar-água em um tubo transparente horizontal. Para baixas velocidades de gás, uma transição para escoamento intermitente foi facilmente detectada visualmente. Para altas velocidades, este não foi o caso. Utilizou-se um par de transdutores de pressão independentemente da direção do escoamento como um artifício para detecção. A análise da queda de pressão é apropriada para escoamento permanente e, particularmente, é vantajosa para regime de escoamento intermitente. Segundo Drahos e Cermak (1989), a principal vantagem do método de flutuações de pressão é sua simplicidade experimental, a qual qualifica este método para aplicação industrial. O problema pode ser a característica do sinal de pressão ou uma possível influência da configuração experimental sob as características do sinal.

Spedding & Spence (1993) obtiveram dados experimentais de regimes de escoamento horizontal ar-água. Os regimes de escoamento foram identificados por uma combinação de observação direta e por vídeo, características de flutuações de pressão e um exame detalhado de perda de pressão. Os resultados, junto com trabalhos prévios foram usados para teste em mapas de regimes de escoamentos. Vários dos mapas não predizeram corretamente os regimes. Modelos teóricos e empíricos foram desenvolvidos para a predição de transição de regimes de escoamentos.

Wambsganss et al. (1994) mediram, em tubo horizontal, a queda de pressão e flutuações de pressão. Os regimes de escoamento foram identificados e o objetivo do método foi determinar as transições dos regimes de escoamento de bolhas para *plug* e de *plug* para *slug*. Em particular, é mostrado que a transição é acompanhada por um claro e abrupto aumento na medida de pressão estática.

3.2.3 - Análise fractal

FRANÇA et al. (1991) propuseram uma técnica fractal para identificação de regimes de escoamento. Foram discutidas algumas medidas de pressão em um escoamento bifásico horizontal ar-àgua. A função densidade de probabilidade e a densidade espectral de potência dos sinais foram calculadas e a técnica fractal foi também usada na tentativa de classificar os vários regimes de escoamento.

3.2.4 - Método estatístico

WANG et al. (1991) através de resultados experimentais, demonstraram que aspectos estatísticos de sinais de pressão diferencial podem ser usados como um indicador de regimes de escoamento em escoamento bifásico horizontal. Os autores introduziram um método estatístico para classificação de regimes de escoamentos próximos da região de transição.

SEKOGUCHI & INOUE (1987) aplicaram um método estatístico e média de fração de vazio para identificação de escoamentos. O reconhecimento dos escoamentos foi baseado num sistema computacional para analisar ondas do cérebro humano. Uma aplicação deste sistema para ondas do cérebro pode automaticamente ser processado com 75% de confiança nos dados obtidos. A aplicação da mesma técnica de reconhecimento, usada para diagnosticar ondas do cérebro humano, pode ser usada para a determinação de regime de escoamento bifásico. NYDAL et al. (1992) desenvolveram uma instrumentação especial com análise e aquisição de dados simultâneos. Isto foi usado para determinar as características de escoamento intermitente. Considerando os aspectos estocásticos de escoamento intermitente, uma investigação experimental deste regime de escoamento deve ser baseada sob extensiva e exata medida de seus principais parâmetros, como duração, velocidade e média de fração de vazio. Foi feita uma investigação experimental sobre propriedades estatísticas de escoamento intermitente. Distribuição estatística dos parâmetros do escoamento intermitente são obtidas para diferentes tamanhos de tubo e condições de entrada, e a relação de funções são

calculadas como indicação das relações estatísticas entre os parâmetros de escoamento intermitente. Um instrumento especial foi projetado para medir diretamente os parâmetros do escoamento intermitente. Sinais de três sondas condutivas são processados *on line* em um computador equipado com uma placa de aquisição trabalhando com altas taxas de amostragem. Somente parâmetros principais são calculados e armazenados para cada unidade de pistão de ar: a velocidade frontal do pistão de ar, velocidade do pistão de ar, o comprimento e o volume do pistão de ar. O conceito de análise e aquisição de dados simultâneos permite a combinação de altas taxas de amostras com longos períodos de aquisição. Isto também possibilita caracterizar o regime de escoamento intermitente em vazões onde a frequência do pistão de ar é baixa.

3.2.5 - Análise de sinais

No que concerne à técnica de análise de sinais, SELEGHIM & HERVIEU (1998b) caracterizaram em tempo e frequência os diferentes regimes de escoamento bifásico ar-água horizontal. Neste trabalho, uma série de ensaios foram realizados num circuito experimental capaz de reproduzir os principais regimes horizontais: estratificados liso, ondulado e rugoso; intermitente, a bolhas e anular. Os sinais obtidos de uma sonda de condutividade foram transcritos no plano tempo-frequência através da transformada de Gabor. Os resultados mostram a habilidade da transformada de Gabor em revelar não somente aspectos genéricos como a configuração de escoamento, mas também detalhes relativamente finos, como estruturas características da interface de segregação em escoamento estratificado, ou sub-intermitências ligadas a acoplamentos entre dois modos dinâmicos em escoamento intermitente.

SOLDATI et al. (1996) propuseram uma análise difusional e a compararam com outros métodos analíticos, e então à aplicaram para a série temporal experimental de escoamento horizontal ar-óleo. Diferentes variáveis do escoamento foram registradas durante o experimento e os autores apresentaram uma discussão da escolha da série temporal apropriada.

DELPRAT et al. (1999) demonstraram como explorar informações espectral e espacial para se obter uma identificação de regimes de escoamentos. Foi feita uma investigação concentrada em quatro regimes de escoamento: escoamento estratificado ondulado, escoamento estratificado rugoso, escoamento intermitente e escoamento a bolhas. A representação espaço-frequência pode ser caracterizada por um conjunto de três parâmetros escalares, quantificando respectivamente a localização no espaço, a localização em frequência e a forma do conteúdo espectral. Plotando a posição de cada experimento em um espaço tridimensional definido por este conjunto de parâmetros, observaram que os pontos estavam agrupados em quatro aglomerados, correspondendo a quatro regimes de escoamentos investigados. Além disso, as regiões limite desses aglomerados não se sobrepõem. Isto demonstra que esses parâmetros são capazes de classificar corretamente os padrões de escoamentos bifásicos.

3.2.6 - Transdutor de impedância

O princípio de operação de sensores elétricos fundamenta-se na diferença de ordem de grandeza entre as propriedades elétricas das fases. Transdutores de condutividade (ou resistividade) são aqueles cujo princípio de funcionamento está relacionado à condutividade média das fases. Capacitivo é a designação para os transdutores que medem a capacitância média de uma mistura não condutiva. Finalmente, transdutores de impedância são aqueles que operam nas faixas capacitiva e resistiva simultaneamente.

Os transdutores de impedância apresentam diversas formas construtivas. Uma das geometrias mais elementares, porém não menos eficiente, pode ser vista no esquema da Figura 3.3. Trata-se de um par de eletrodos imersos no meio bifásico, cuja geometria acompanha a curvatura da tubulação. Nesta configuração, o material das paredes do tubo deve ser isolante.

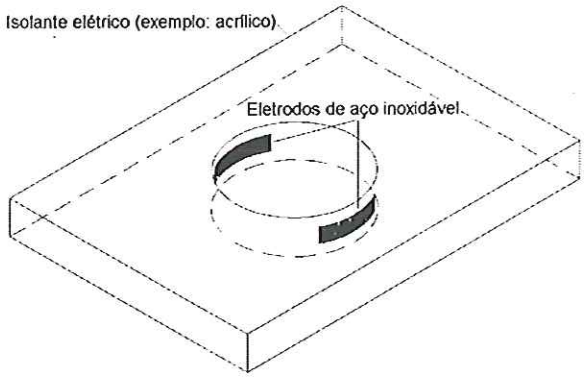

Figura 3.3 – Esquema básico de um transdutor de impedância

O estudo de escoamento multifásico tem levado ao desenvolvimento de várias sondas de impedância elétrica. Em muitos escoamentos multifásicos onde as fases têm diferenças significativas de impedância, a medida de volume médio e local dessas quantidades pode revelar informações sobre a distribuição espacial e temporal das fases dentro do escoamento. Resistência, capacitância, indutância ou qualquer combinação dessas quantidades podem ser medidas pelos vários tipos de sonda. A escala em que a informação é gerada pode variar também: a impedância do meio pode ser medida em uma pequena região com uma sonda local, ou medida sobre um grande volume com um sensor superficial, por exemplo. Com uma seleção criteriosa da geometria da sonda e uma calibração apropriada, sondas de impedância têm sido usadas para medir uma variedade de propriedades de escoamentos multifásicos, tais como média e flutuação da fração de vazio em escoamentos a bolhas, dinâmica de escoamentos intermitentes, etc. Sondas de impedância oferecem uma alta resposta em frequência, baixos custos e construção relativamente fácil (CECCIO & GEORGE, 1996).

SELEGHIM JUNIOR & HERVIEU (1998a) apresentaram uma sonda de imagem direta para escoamento bifásico. A configuração do eletrodo é adaptada no sentido de que uma representação da imagem da distribuição de fase dentro do volume sensoriado pode ser obtida simplesmente plotando o sinal correspondente para medidas condutivas periféricas, sem reconstrução numérica dos dados experimentais. Vários testes transientes foram feitos em um circuito bifásico com o objetivo de demonstrar a capacidade da sonda em exibir não somente grandes estruturas como pistões de ar e de água, mas

também alguns detalhes refinados como ondulação e rugosidade interfaciais em escoamento estratificado, e o escoamento de filme líquido na transição entre regime de escoamento intermitente e anular.

ANDREUSSI et. al. (1988) mostraram que uma sonda não intrusiva feita de dois anéis de eletrodos montados na parede do tubo pode ser muito eficaz na medida da quantidade média de líquido sobre diferentes condições de escoamentos. Somente a quantidade relativa de uma fase líquida contínua pode ser determinada pela sonda quando a impedância é dada por um termo puramente resistivo.

3.2.7 – Tomografia

Uma nova tendência no desenvolvimento de técnicas de medida por tomografia, para produção e pesquisa, é o uso de técnicas elétricas. Essas técnicas são baseadas no contraste entre propriedades elétricas ou eletromagnéticas dos componentes no volume de medida. Das técnicas elétricas de tomografia, a tomografia capacitiva está no estado mais avançada de desenvolvimento e assim já aplicável na indústria e pesquisa (REINECKE & MEWES, 1996).

SUN et al. (1999) apresentaram um algoritmo de reconstrução de imagem para um sistema de tomografia capacitiva elétrica. Para melhorar a qualidade da imagem, redes neurais foram utilizadas para a reconstrução da imagem dos dados da tomografia capacitiva elétrica. Primeiro foi determinada uma arquitetura para a rede neural e então a sensibilidade de um *pixel* (unidade de imagem) na malha computacional de um tubo analisado. Com a rede neural treinada, dados experimentais foram usados para verificar o método.

Existe uma forte relação entre os regimes de escoamento bifásico e o comportamento térmico hidráulico de um circuito natural. De qualquer modo, as descrições das variações de regimes de escoamentos são exclusivamente qualitativas. HSIEH et. al. (1997) estudaram as variações de regimes de escoamento por meio de técnicas de visualização dinâmica. As transições de regimes de escoamento foram registradas e processadas usando técnicas de

análise de imagens. Como resultado, a vazão do escoamento no circuito, pressão, temperatura do fluido e regimes de escoamento podem ser comparados ao mesmo tempo e os detalhes das interações entre regimes de escoamento e outras propriedades termodinâmicas podem ser exploradas.

3.2.8 - Redes neurais

A história de redes neurais tem progredido por meio de inovações de conceitos e desenvolvimento de implementações. Alguns dos trabalhos práticos no campo de redes neurais ocorreram no fim do século XIX e início do século XX. Do ponto de vista mais recente, os estudos sobre redes neurais iniciaram em 1940 com o trabalho de Warren McCulloch e Walter Pitts[1] apud HAGAN et. al. (1996). Estes pesquisadores mostraram que redes de neurônios artificiais podem, em princípio, calcular qualquer função aritmética ou lógica. Este trabalho é reconhecido como o início de redes neurais como campo de trabalho.

McCulloch e Pitts foram seguidos por Donald Hebb[2] apud HAGAN et. al. (1996), os quais propuseram um mecanismo de aprendizado em neurônios biológicos.

A primeira aplicação prática de redes neurais artificiais deu-se em 1950, com a invenção da rede *perceptron* associada à regra de aprendizado de Frank Rosenblatt. Rosenblatt construiu uma rede *perceptron* e demonstrou sua habilidade de reconhecimento de padrões. Os primeiros sucessos estimularam um grande número de pesquisadores interessados em trabalhar com redes neurais. Posteriormente foi mostrado que a base da rede *perceptron* resolve somente uma classe limitada de problemas. Ao mesmo tempo, Bernard Widrow e Tedd Hoff[3] apud HAGAN et. al. (1996) introduziram um novo algoritmo de aprendizado e o usaram para treinar rede neural linear adaptativa, o qual era

---

[1] MCCULLOCH, W.; PITTS, W. (1943) apud HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. (1996). *Neural network design.*

[2] HEBB, D. O. (1949) apud HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. (1996). *Neural network design.*

[3] WIDROW, B.; HOFF, T. (1960) apud HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. (1996). *Neural network design.*

similar na estrutura e capacidade ao *perceptron* de Rosenblatt. A regra de aprendizado de Widrow-Hoff é utilizada até hoje.

As redes de Rosenblatt e Widrow sofrem as mesmas limitações e, cientes dessas limitações, propuseram uma nova rede que poderia superar essas limitações. De qualquer modo, eles não foram capazes de modificar com sucesso o algoritmo de aprendizado para treinar redes mais complexas.

Muitas pessoas, influenciadas por Minsky e Papert, acreditavam que não existiria mais pesquisas sobre redes neurais. Isto combinou com o fato de que não existiam computadores para executarem os programas de redes neurais, fazendo com que muitos pesquisadores deixassem de fazer pesquisas nesta área. As pesquisas em redes neurais foram praticamente suspensas durante décadas.

Alguns trabalhos importantes, continuaram durante os anos 70. Em 1972 Teuvo Kohonem e James Anderson desenvolverem independentemente, novas redes neurais que poderiam atuar como a memória.

Durante os anos 80 esses impedimentos foram superados e a pesquisa em redes neurais aumentou substancialmente. Novos computadores que aumentaram rapidamente sua capacidade, tornaram-se amplamente úteis. Além disso novas concepções importantes foram introduzidas.

Duas novas concepções foram responsáveis pelo renascimento de redes neurais. A primeira foi o uso da mecânica estatística para explicar a operação de uma certa classe de redes recorrentes, as quais podem ser usadas como uma memória associativa.

O segundo desenvolvimento chave dos anos 80 foi o algoritmo *backpropogation* (repropagação) para treinar redes *perceptron* com várias camadas, o qual foi descoberto independentemente por vários pesquisadores. A publicação de maior influência do algoritmo *backpropagation* (repropagação) foi por David Rumelhart e James McClelland (HAGAN et. al., 1996). Este algoritmo foi a resposta para as críticas feitas por Minsky e Papert nos anos 60 (HAGAN et al., 1996).

Esses novos desenvolvimentos revigoraram o campo de redes neurais. Nos últimos 10 anos, centenas de artigos foram escritos e redes neurais têm encontrado muitas aplicações (HAGAN et al., 1996).

Uma rede neural pode expressar uma relação de não linearidade entre entradas e saídas e aprender a relação automaticamente. Por isso é conveniente o uso de redes neurais para relacionar o padrão de escoamento com os parâmetros estatísticos de flutuações de fase a gás. Além disso, a rede neural tem uma possibilidade para expressar o grau de transição do padrão de escoamento (MONJI & MATSUI, 1998).

Segundo Bishop (1994), um fator chave que limita a implementação comum de soluções de redes neurais em muitas áreas tem sido a dificuldade em demonstrar que as saídas generalizadas pela rede tenham confiabilidade. Uma fonte de erro importante está nos novos dados de entrada, isto é, dados de entrada os quais diferem significantemente dos dados usados para treinar a rede. O autor investiga o grau de confiança entre os novos dados de entrada e a correspondente saída da rede. É descrito um procedimento quantitativo para avaliar as novidades e demonstrar seu desempenho em uma aplicação que envolve monitoramento de escoamento multifásico de óleo em dutos. 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. Isto foi realizado pelo treinamento da rede com dados experimentais obtidos em laboratório coletados por muitos anos por vários pesquisadores. Antes do treinamento ser feito , muitas decisões foram tomadas quanto ao tamanho da rede e definição de seus parâmetros de treinamento. Essas decisões foram tomadas com base no sucesso do treinamento de uma condição de escoamento estratificado similar, onde a solução teórica é conhecida. Finalmente, esses resultados foram comparados com uma aproximação da equação de estabilidade utilizando resultados da teoria de escoamento invíscido , teoria de escoamento turbulento e experimentos de laboratório sobre atrito interfacial. Esta predição foi verificada com os dados disponíveis, de acordo com os resultados da rede neural e os resultados teóricos.

YAMASHITA (1997) investigou um procedimento de classificação de regimes de escoamento em um transportador pneumático vertical através de uma rede neural com atraso no tempo, a qual é uma rede *feedforward* multicamadas, desenvolvida para reconhecimento de fenômenos. Do ponto de

vista de analises de sinais, análise de fenômenos é uma análise de série temporal de uma variável simples capaz de aplicar em processos químicos. Nesse estudo, um sensor de mudança eletrostática é combinado com uma rede neural com atraso no tempo para compor um sistema de sensor inteligente.

O desempenho da rede neural após o treinamento foi excelente, exceto para as regiões de transição. Uma rede neural multicamadas foi também utilizada, apresentando um desempenho próximo ao da rede neural com atraso no tempo. Entretanto, a rede neural com atraso no tempo mostrou uma habilidade de generalização superior à rede neural multicamadas.

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 à flutuação de fase do gás. A rede neural treinada utilizando o algoritmo *backpropagation* aprendeu a identificar regimes de escoamento observados experimentalmente. Após o treinamento, a porcentagem máxima de classificação correta de dados, não usados no treinamento foi de 91% para a rede baseada em parâmetros estatísticos e 74% para a rede baseada em uma série temporal. Os regimes de escoamento não foram corretamente identificados nas regiões de transição de um regime para outro.

MOON & CHANG (1994) propuseram um método para estimar o fluxo de calor crítico baseado na teoria de conjuntos difusos e redes neurais artificiais. Este tipo de previsão é muito importante no projeto de reatores nucleares e em diversas aplicações industriais. Os conjuntos difusos foram usados para classificar os dados experimentais do fluxo de calor crítico, por meio de poucos conjuntos de dados, de acordo com suas características. Após a classificação dos dados experimentais, as características dos conjuntos resultantes são discutidas, dando-se ênfase tanto na distribuição das condições experimentais como no mecanismo físico relacionado ao fluxo de calor. Os dados de fluxo de calor são usados no treinamento de uma rede neural artificial para estimar o fluxo de calor no reator nuclear.

MI et. al. (1997) utilizaram um medidor de fração de vazio com múltiplos eletrodos e redes neurais para identificação de regimes de escoamento. Resultados experimentais mostraram que flutuações na fração de vazio média e as assinaturas do regime de escoamento podem estar relacionadas ao sinal de saída da medida de impedância. Desta maneira a fase simples de líquido e a fase simples de gás, tem sido claramente exibidas pelas propriedades estatísticas do sinal de impedância. Por isso, o sinal de impedância tem sido empregado na entrada da rede neural para classificação dos regimes de escoamento. Foram desenvolvidas duas redes neurais para identificação de regimes de escoamento, uma rede neural supervisionada e uma rede neural auto-organizativa. Redes neurais têm-se mostrado apropriadas na identificação de regimes de escoamento. Além disso, a rede neural auto-organizativa descobre informações sobre transição de regimes de escoamento.

A exploração das informações espectral e espacial leva-nos a uma identificação não ambígua dos regimes de escoamento. HERVIEU (2002) analisou simultaneamente a densidade espectral de potência do sinal obtido por um sensor de impedância com vários eletrodos, obtendo uma representação espaço-freqüência a qual mostra aspectos particulares dos diferentes regimes de escoamento. Esses aspectos foram caracterizados por um conjunto de 3 parâmetros escalares, quantificando respectivamente a localização em espaço, em freqüência e a forma do conteúdo espectral. A demonstração final dessa caracterização tempo-freqüência é provada pelo uso de uma rede neural com várias camadas, treinada com os parâmetros escalares. A rede exibiu com sucesso a identificação dos regimes de escoamento.

A identificação de regimes de escoamento é feita visualmente ou por instrumentos de indicação. MI et. al. (2001) evitaram qualquer erro de instrumentação e qualquer julgamento subjetivo envolvido na identificação de regime de escoamento bifásico vertical. A identificação de regime de escoamento vertical foi baseada na simulação teórica de escoamento bifásico com um sistema de redes neurais supervisionadas e outro com redes auto-organizativas (self-organizing). Estatísticas do sinal de impedância do escoamento bifásico foram usadas como entradas para as redes neurais. As redes neurais foram verificadas com medidas do sinal de impedância por uma

medida de fração de vazio. Os resultados demonstraram que as redes neurais são apropriadas para classificar regimes de escoamento vertical.

CRIVELARO (1999) utilizaram uma rede neural com várias camadas com aprendizado supervisionado, em associação a uma sonda de visualização direta, para a identificação de regimes de escoamento horizontal gás-líquido, produzidos em um 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 padrão. As porcentagens de acerto da rede neural foram satisfatórias, obtendo-se uma porcentagem mínima de acerto de 70%, uma porcentagem média de acerto de 82,8% e uma porcentagem máxima de acerto de 90%.

Os trabalhos mais recentes encontrados na literatura são de redes neurais associadas a tomografia para identificação de regimes de escoamento.

YAN et. al. (2004) propuseram a identificação de regimes de escoamento bifásico baseado em redes neurais supervisionadas e um sensor de tomografia de capacitância. Dez parâmetros de aspectos são extraídos das medidas de capacitância e colocados na rede neural supervisionada para identificar os regimes de escoamento. Resultados da simulação mostram que o novo método tem uma boa precisão e alta velocidade.

DONG et. al. (2003) desenvolveram um sistema de tomografia de resistência elétrica para medida de parâmetros de escoamento bifásico. O método de analisar as medidas dos dados do sistema de tomografia de resistência elétrica é aplicado para identificar regimes de escoamento e estimar a fração de vazio. Para vários tipos de regime de escoamento, os métodos de análise de componente principal e redes neurais com função de base radial são apresentados, e é provado por testes experimentais ter alto reconhecimento.

YANG et. al. (2003) implementaram três redes neurais com algoritmo de *backpropagation,* treinadas com resultados de um modelo teórico, para demonstrar sua utilidade na determinação em tempo real de propriedades de escoamento com alta pressão (contendo fração local de vazio, velocidade do líquido, e velocidade das bolhas de gás). As medidas foram feitas em um escoamento bifásico turbulento vertical a bolhas.

Ficou demonstrado que o diagnóstico é possível caso se disponha de um conjunto de dados de treinamento com os respectivos regimes de

escoamento previamente relacionados. A limitação dessa técnica se torna aparente quando se analisa um dispositivo experimental do qual se desconhece sob quais regimes de escoamento se pode operar, ou sua própria existência.

O presente doutorado se baseia na capacidade que as rede neurais têm de organizar autonomamente os dados que lhe são apresentados em grupos ou padrões característicos.

Isso posto, é preciso ressaltar o caráter inovativo da proposta no contexto em que se insere. De fato, segundo nosso conhecimento, não há informações de uma abordagem semelhante na literatura científica.

Capítulo 4 – Metodologia

Neste capítulo serão apresentados os aspectos teóricos de redes neurais auto-organizativas. Os tópicos apresentados foram direcionados de duas formas. Inicialmente, será apresentado um resumo explicando o que é uma rede neural. Em seguida, será apresentada a rede neural auto-organizativa. Alguns tópicos foram escolhidos por sua importância em explicar como redes neurais operam. Houve um empenho para apresentar um material didático de maneira clara e concisa que possa ser facilmente utilizado.

Será empregada uma notação padrão, onde escalares serão representados por letra minúscula em itálico, vetores serão representados por letra minúscula em negrito, matrizes serão representadas por letra maiúscula em negrito.

4.1 – Redes neurais

4.1.1 – Modelo do neurônio e arquitetura de redes

Uma rede neural artificial pode ser definida como um sistema de processamento de dados com um grande número de neurônios artificiais conectados.

A Figura 4.1 mostra um elemento de processamento simples, também conhecido como neurônio.

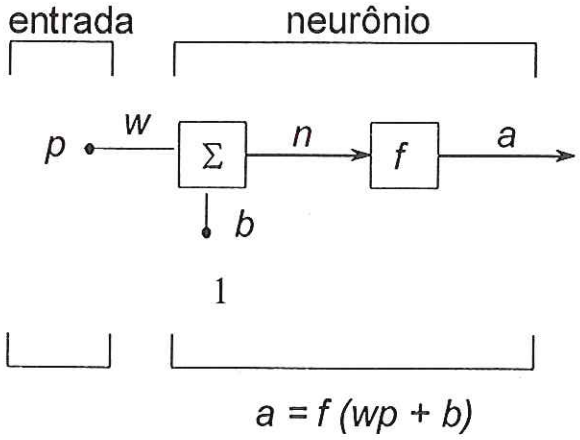

Figura 4.1 - Neurônio de entrada simples (HAGAN et al.,1996).

A saída *a* do neurônio é calculada como

$$a = f(wp+b). \tag{4.1}$$

onde *f* é uma função de transferência ou função de ativação do neurônio, *p* é a entrada da rede, *w* é o valor do peso que pondera a entrada *p* e *b* é o *bias*, ou seja, o peso relativo à entrada fixa unitária.

Uma vez escolhida a função de ativação, os valores de *w* e *b* podem ser ajustados de forma a obter uma relação satisfatória entrada/saída. A esse procedimento de ajuste nos pesos *w* e *b*, atribui-se à denominação genérica de treinamento com base em algumas regras de conhecimento, que reúnem relações específicas entre os neurônios de entrada e saída (HAGAN et al., 1996).

Esses elementos de processamento são usualmente organizados dentro de uma seqüência de camadas totalmente ou parcialmente conectadas entre si.

Cada camada tem sua própria matriz peso **W**, seu próprio vetor *bias* **b**, um vetor de entrada **n** na função de ativação *f* e um vetor de saída **a**. Para distinguir entre cada camada usar-se-á índices sobrescritos. Assim, a matriz peso para a primeira camada é escrita como $\mathbf{W}^1$ e a matriz peso para a segunda camada é escrita como $\mathbf{W}^2$. Esta notação é usada até a terceira camada da rede mostrada na Figura 4.2.

Na rede neural da Figura 4.2, as saídas da primeira e segunda camada são respectivamente as entradas da segunda e terceira camadas, ou seja, o sinal de entrada se propaga da camada de entrada para a camada de saída mas não vice-versa. Em outras palavras, esta rede neural é estritamente do tipo *feedforward*. Assim, a segunda camada pode ser vista como uma rede com uma camada com $R = S^1$ entradas, $S = S^2$ neurônios e uma $S^1 \times S^2$ matriz peso $\mathbf{W}^2$. A entrada para a segunda camada é $\mathbf{a}^1$ e a saída é $\mathbf{a}^2$.

Os neurônios que recebem diretamente as entradas da rede constituem a chamada camada de entrada. Os neurônios que recebem como entradas as saídas daqueles da camada de entrada constituem a segunda camada e assim, sucessivamente até a última camada, chamada de camada de saída. As camadas internas, entre as camadas de entrada e de saída, são geralmente referidas como camadas intermediárias ou escondidas. Desta forma, a rede mostrada na Figura 4.2 possui uma camada de saída (terceira camada) e duas camadas intermediárias (primeira e segunda) (HAGAN et.al., 1996).

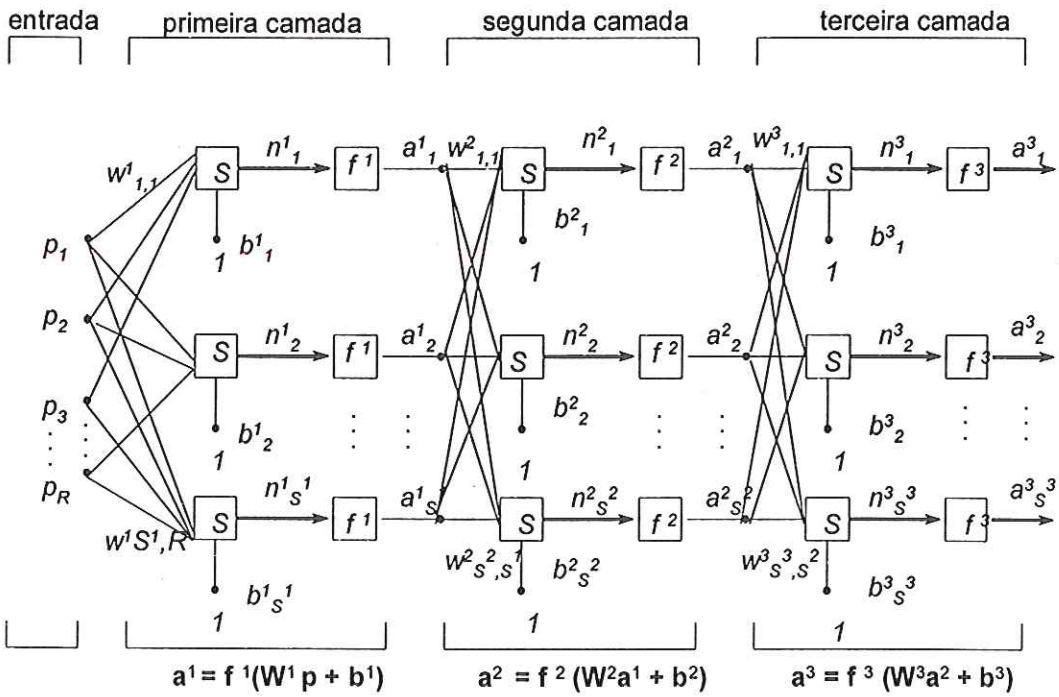

$$a^3 = f^3(W^3 f^2(W^2 f^1(W^1 p + b^1) + b^2) + b^3)$$

Figura 4.2: Esquema de uma rede neural *feedforward* com três camadas.

4.2 – Redes neurais auto-organizativas

O sistema auto-organizativo é considerado uma classe especial de redes neurais artificiais conhecidas como mapas. Ele pode ser descrito como um mapeamento, ordenado, não linear, monotônico, de dados de entrada n-dimensionais nos elementos de um espaço vetorial de dimensão pequena. Do ponto de vista da informação e de como ela é visualizada, o caráter auto-organizativo implica que há conversão de relações estatísticas e métricas não lineares de dados de entrada n-dimensionais em relações geométricas simples em uma malha bidimensional de pontos nodais (KOHONEN, 2001). Em outras palavras, na medida em que um mapa auto-organizativo projeta sobre a malha bidimensional, a informação contida nos dados primários, sem alterar significativamente suas relações topológicas, pode ser entendido como uma ferramenta de abstração. Esses dois aspectos, i.e., visualização e abstração, são extremamente importantes em aplicações complexas envolvendo análise informacional, como é o caso da identificação de regimes de escoamento multifásico e outros problemas relacionados à inteligência artificial (SELEGHIM, 2002).

Essas redes são baseadas no aprendizado competitivo, os neurônios de saída da rede neural competem entre si para ser ativado, somente um neurônio de saída ou um neurônio por grupo é ativado. O único neurônio de saída que ganha a competição é chamado de neurônio vencedor.

A idéia fundamental destes mapas, usualmente chamados mapas auto-organizativos, foi originalmente introduzida e caracterizada computacionalmente por von der Malsburg[1] e Grossberg[2] apud HAGAN et al. (1996) para explicar a formação de mapas topológicos neurais. Usando um modelo de rede neural simplificado de processamento de neurônio, von der Malsburg demonstrou como mapas topográficos podem ser obtidos através do aprendizado. As duas suposições básicas do modelo de von der Malsburg, são que: (1) uma unidade ativada deve ativar suas unidades vizinhas; e (2) pesos

---

[1] von der MALSBURG, C. (1973) apud HAGAN, M. T.;DEMUTH, H. B.; BEALE, M. (1996). *Neural network design.*

[2] GROSSBERG, S. (1967) apud HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. (1996). Neural network design.

das conexões devem ser modificados como um resultado da regra de aprendizagem.

4.2.1 – Grade de neurônios

Em um mapa auto-organizativo, os neurônios estão dispostos em uma grade que pode ser unidimensional ou bidimensional. Mapas com dimensões maiores também são possíveis, mas não tão comuns. A Figura 4.3 mostra o diagrama esquemático de uma grade bidimensional de neurônios comumente usados com os mapas discretos. Cada neurônio na grade está totalmente conectado a todos os neurônios na camada de entrada.

Uma grade unidimensional é um caso especial da configuração representada na Figura 4.3. Neste caso especial, a camada computacional consiste simplesmente de uma coluna simples ou linha de neurônios. Os neurônios são compostos seletivamente de acordo com os vários padrões de entrada (estímulo) 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 características dos padrões de entrada.

Um mapa auto-organizativo é caracterizado pela formação de um mapa topográfico dos padrões de entrada, os quais as localizações espaciais (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 (HAYKIN,1996).

Cada padrão de entrada apresentado para a rede tipicamente consiste de uma região do espaço de entrada. A localização e natureza da região usualmente varia de um padrão de entrada para outro. Todos os neurônios na rede devem, por isso, ser expostos a um número suficiente de diferentes padrões para assegurar que o processo auto-organizativo tenha uma chance de desenvolver corretamente.

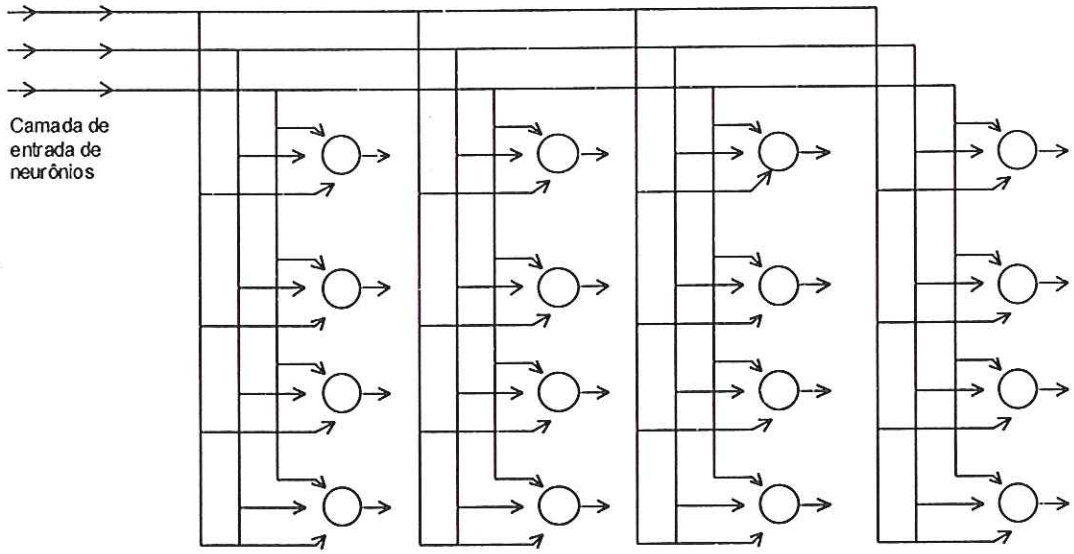

Figura 4.3: Grade bidimensional de neurônios

4.2.2 – Funções topológicas e funções distância

Os neurônios na camada de um mapa auto-organizativo são arranjados originalmente em posições físicas de acordo com a função topológica. Os neurônios podem ser arranjados em uma grade retangular, hexagonal ou *N* dimensional aleatória. Nas Figuras 4.4, 4.5 e 4.6 serão ilustradas essas funções. As distâncias entre neurônios são calculadas de sua posição com uma função distância. A função distância utilizada neste trabalho calcula a distância Euclidiana de um neurônio a outro.

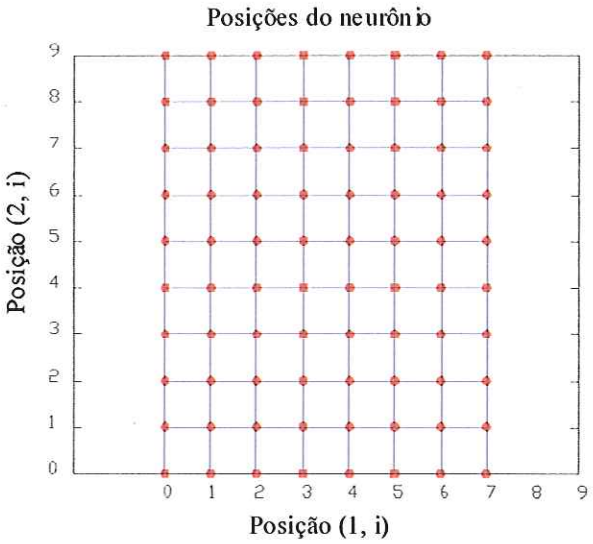

Figura 4.4: Grade retangular de neurônios

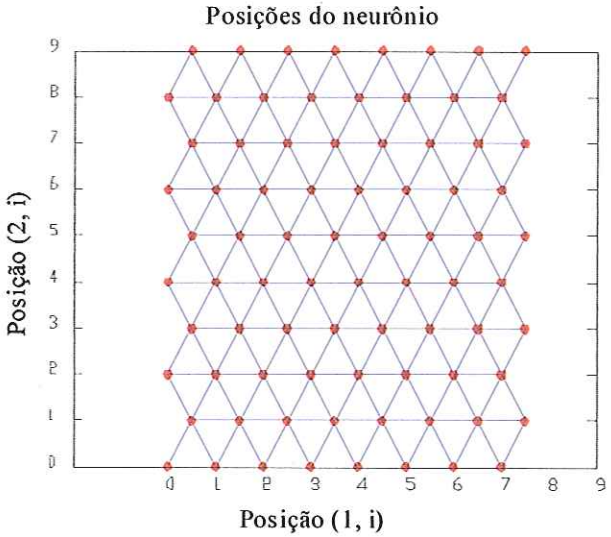

Figura 4.5: Grade hexagonal de neurônios

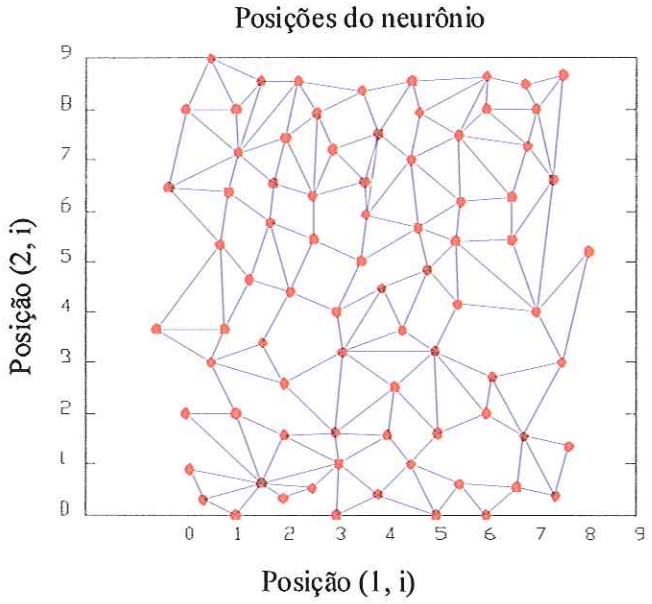

Figura 4.6: Grade aleatória de neurônios

4.2.3 - Arquitetura de uma rede neural competitiva

A arquitetura para uma rede competitiva é mostrada na Figura 4.7.

A caixa ‖ndist‖ na Figura 4.7 recebe o vetor de entrada **p** e a matriz peso de entrada $\mathbf{W}_{1,1}$, e produz um vetor com $\mathbf{S}^1$ elementos. Os elementos de $\mathbf{S}^1$ são o negativo da distância entre o vetor de entrada e vetores $\mathbf{W}_{1,1}$ formado pelas linhas da matriz peso de entrada.

A entrada *n* de uma camada competitiva calcula o negativo da distância Euclidiana encontrando a distância negativa entre o vetor de entrada **p** e o vetor peso **W** e adicionando o *bias* **b**. Se todos os *bias* são zero, a máxima entrada da rede que um neurônio pode ter é zero. Isto ocorre quando o vetor de entrada **p** é igual ao vetor peso.

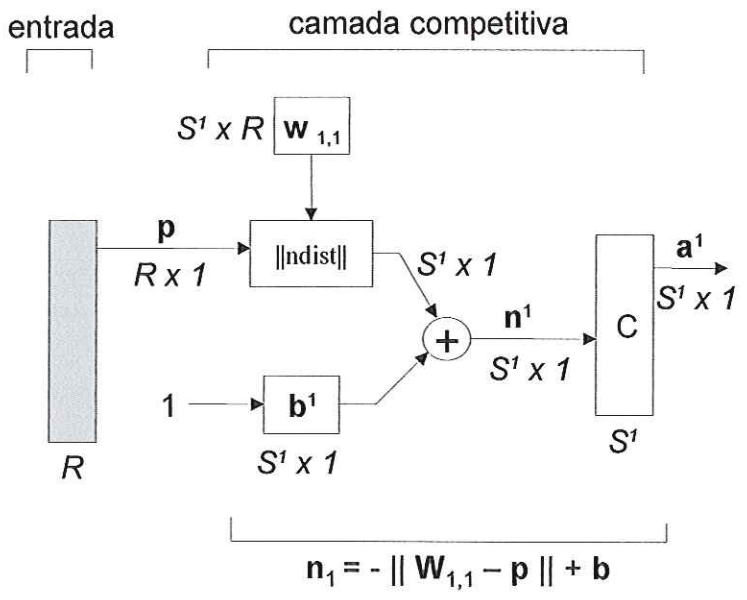

Figura 4.7: Arquitetura de uma rede neural competitiva

A função de ativação de uma camada competitiva recebe um vetor de entrada na rede para uma camada e retorna um neurônio de saída 0 para todos os neurônios, exceto para o vencedor, o neurônio associado com o elemento positivo de entrada da rede *n*. A saída do neurônio vencedor é 1. Se todos os *bias* são zero, então o neurônio o qual o vetor peso para o vetor de entrada tem uma entrada negativa mínima na rede e por isso vence a competição com saída 1 (HAGAN et al., 1996).

4.2.4 – Formação do mapa auto-organizativo

O algoritmo responsável para a formação do mapa auto-organizativo, primeiro inicializa os pesos sinápticos na rede. Isto pode ser feito pela determinação de pequenos valores de um gerador de números randômicos, nenhuma ordem à priori é imposta sobre o mapa auto-organizativo. Uma vez que a rede tenha sido inicializada, existem três processos essenciais envolvidos na formação do mapa auto-organizativo, resumidos a seguir:

1. **Competição**. Para cada padrão de entrada, os neurônios na rede calculam seus respectivos valores de uma função discriminante. Esta função provém

a base para competição entre os neurônios. O neurônio particular com o maior valor da função discriminante é declarado vencedor da competição.

2. **Cooperação**. O neurônio vencedor determina a localização espacial de uma vizinhança topológica de neurônios excitados, por isso provém a base para competição entre neurônios vizinhos.

3. **Adaptação sináptica**. Este mecanismo habilita os neurônios excitados a aumentar seus valores individuais da função discriminante em relação aos padrões de entrada através de ajustes apropriados aplicados aos seus pesos sinápticos. Os ajustes feitos são a resposta do neurônio vencedor para aplicações subseqüentes de um padrão de entrada similar.

A presença de redundância nos dados de entrada é necessária para o aprendizado (HAYKIN, 1996). Agora será apresentada uma descrição dos processos competitivo, cooperativo e adaptação sináptica.

4.2.4.1 - Processo competitivo

Seja *m* a dimensão do vetor de entrada. Seja um vetor de entrada qualquer selecionado do espaço de entrada, representado por:

$$\mathbf{p} = [p_1, p_2, \ldots, p_m]^T \tag{4.2}$$

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

$$\mathbf{W}_j = [w_{j1}, w_{j2}, \ldots, w_{jm}]^T, \quad j = 1,2,\ldots,l \tag{4.3}$$

onde *l* é o número total de neurônios na rede. Para encontrar a melhor competição do vetor de entrada **p** com o vetor peso $\mathbf{w}_j$, comparamos o produto interno $\mathbf{w}^T_j\mathbf{p}$ para $j = 1,2,\ldots,l$ e seleciona-se aquele de maior valor. Assim, por

selecionar o neurônio com o maior produto interno $\mathbf{w}^T_j\mathbf{p}$, determinará a localização onde a vizinhança topológica de neurônios excitados está centrada.

O melhor critério de competição, baseado na maximização do produto interno de $\mathbf{w}^T_j\mathbf{p}$, é matematicamente equivalente a minimizar a distância Euclidiana entre os vetores $\mathbf{p}$ e $\mathbf{w}_j$.

O neurônio *i(p)* identifica o neurônio que melhor aproxima do vetor de entrada $\mathbf{p}$, pode-se então determinar *i(p)* aplicando a condição

$$i(p) = \arg\min_j \left\| \mathbf{p} - \mathbf{w}_j \right\|, \quad j = 1,2,\ldots,l, \tag{4.4}$$

o qual corresponde a essência do processo de competição entre os neurônios. O neurônio particular *i* que satisfaz esta condição é chamado de neurônio vencedor para o vetor de entrada $\mathbf{p}$. Podemos observar isto na equação (4.4).

Um espaço de entrada contínuo de padrões de ativação é mapeado sobre um espaço de saída discreto de neurônios por um processo de competição entre os neurônios na rede neural.

Dependendo do interesse da aplicação, a resposta da rede pode ser o índice do neurônio vencedor (isto é, sua posição na grade), ou o vetor peso que está próximo ao vetor de entrada ou ambos.

3.2.4.2 - Processo Cooperativo

O neurônio vencedor localiza o centro de uma vizinhança topológica de cooperação de neurônios. Em particular, um neurônio que está excitado tende a excitar os neurônios em sua vizinhança imediata mais do que aqueles que estão longe dele. Esta observação leva-se a fazer a vizinhança topológica ao redor do neurônio vencedor *i* decair lentamente com a distância lateral. Seja $h_{j,i}$ a vizinhança topológica centrada no neurônio vencedor *i*, cercada por um conjunto de neurônios excitados, denotado por *j*. Então, podemos assumir que a vizinhança topológica $h_{i,j}$ é uma função unimodal da distância lateral $d_{i,j}$, de maneira que ela satisfaz duas exigências:

- A vizinhança topológica $h_{j,i}$ é simétrica sobre o ponto máximo definido por $d_{i,j} = 0$; em outras palavras , ela obtém seu valor máximo para o neurônio vencedor i para o qual a distância $d_{i,j}$ é zero.

- A amplitude da vizinhança topológica $h_{j,i}$ diminui monotonicamente com o aumento da distância lateral $d_{j,i}$, decaindo para zero quando $d_{j,i} \rightarrow \infty$; esta é uma condição necessária para convergência.

Uma escolha típica de $h_{j,i}$ que satisfaz essas exigências é a função Gaussiana

$$h_{j,i(x)} = \exp\left(-\frac{d_{j,i}^{2}}{2\sigma^{2}}\right) \tag{4.5}$$

a qual é independente da localização do neurônio vencedor. O parâmetro σ é o efeito da amplitude da vizinhança topológica, como ilustrada na Figura 4.8 ; ela mede o grau no qual o neurônio excitado na vizinhança do neurônio vencedor participa no processo de aprendizagem. Em um sentido qualitativo, a vizinhança topológica Gaussiana da equação 4.5 é mais apropriada do que uma retangular.

Seu uso também faz o algoritmo do mapa auto-organizativo convergir mais rapidamente do que seria com uma vizinhança topológica retangular.

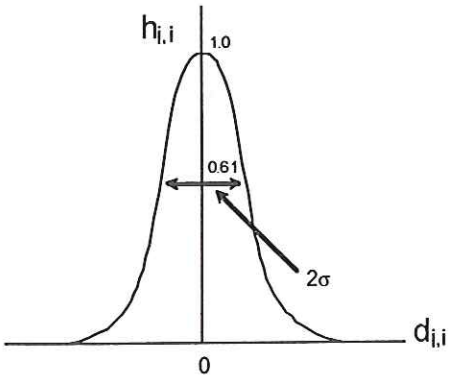

Figura 4.8: Função Gaussiana

Para manter a cooperação entre neurônios vizinhos, é necessário que a vizinhança topológica $h_{j,i}$ seja dependente da distância lateral $d_{j,i}$ entre o

neurônio vencedor i e o neurônio excitado j no espaço de entrada em vez de alguma medida de distância no espaço de entrada original. Isto é precisamente o que temos na equação (4.5). No caso de uma grade bidimensional, $d_{j,i}$ é um inteiro igual a $|j-i|$ e é definida por

$$d_{j,i}^{2} = \|r_j - r_i\|^2 \tag{4.6}$$

onde o vetor discreto r_j define a posição do neurônio excitado j e r_i define a posição discreta do neurônio vencedor i, ambos são medidos no espaço de saída discreto.

Outro aspecto único do algoritmo do mapa outo-organizativo é que o tamanho da vizinhança topológica diminui com o treinamento. Esta exigência é satisfeita fazendo a amplitude de ϑ da função de vizinhança topológica $h_{j,i}$ diminuir com o tempo. Uma escolha popular para a dependência de σ no tempo discreto n é o decaimento da exponencial descrito por

$$\sigma(n) = \sigma_0 \exp\left(-\frac{n}{\tau_1}\right), \qquad n = 0,1,2,..., \tag{4.7}$$

onde σ_0 é o valor de σ para a inicialização do algoritmo do mapa auto-organizativo, e τ_1 é uma constante de tempo. Correspondentemente, a vizinhança topológica assume sua própria forma de variação no tempo, dada por:

$$h_{j,i(x)}(n) = \exp\left(-\frac{d_{j,i}^2}{2\sigma^2(n)}\right), \qquad n = 0,1,2,..., \tag{4.8}$$

onde $\sigma(n)$ é definido pela equação (4.7). Assim, quando o tempo n (i.e., o número de iterações) aumenta, a amplitude $\sigma(n)$ diminui numa razão exponencial, e a vizinhança topológica diminui em uma maneira correspondente. Doravante referimos para $h_{j,i(x)}(n)$ como a função vizinhança.

Para ilustrar o conceito de vizinhança, considere a Figura 4.8. O diagrama a esquerda mostra uma vizinhança bidimensional de raio d = 1 ao redor do neurônio 13. O diagrama a direita mostra uma vizinhança de raio d = 2.

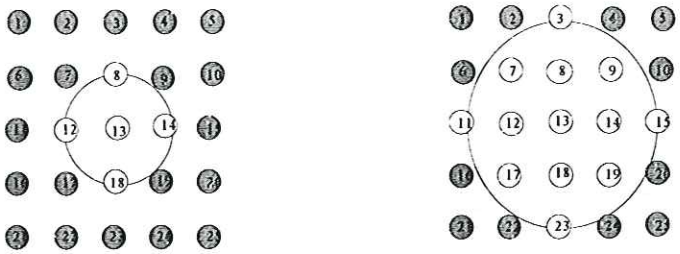

Figura 4.9: Conceito de vizinhança

Esses neurônios podem ser escritos da seguinte maneira:

$N_{13}(1) = \{8,12,13,14,18\}$ e

$N_{13}(2) = \{3,7,8,9,11,12,13,14,15,17,18,19,23\}$

Podemos também definir distância de diferentes maneiras. A performance da rede não é sensível à forma exata da vizinhança (DEMUTH & BEALE, 1994).

4.2.4.3 - Processo adaptativo

O processo adaptativo sináptico é o último processo na formação do mapa auto-organizativo. Para a rede ser auto-organizada, o vetor peso $\mathbf{w}_j$ do neurônio *j* na rede tem que mudar em relação ao vetor de entrada **x**. Incluindo um termo $g(y_j)\mathbf{w}_j$, onde $\mathbf{w}_j$ é o vetor peso do neurônio j e $g(y_j)$ é uma função escalar constante da resposta y_j. A condição para a função $g(y_j)$ é que o termo constante da expansão em série de Taylor seja zero,

$$g(y_j) = 0 \quad \text{para} \quad y_j = 0 \tag{4.9}$$

Dada uma função, podemos então expressar a mudança do vetor peso do neurônio *j* na grade como segue:

EESC - USP Biblioteca CAMPUS DE S. CARLOS

$$\Delta \mathbf{w}_j = \eta y_j \mathbf{x} - g(y_j)\mathbf{w}_j \tag{4.10}$$

onde η é o parâmetro taxa de aprendizagem do algoritmo. Para satisfazer a condição da equação (4.9), escolhemos uma função linear para $g(y_j)$, como a equação (4.11)

$$g(y_j) = \eta y_j \tag{4.11}$$

podemos simplificar a equação (4.10) colocando:

$$y_j = h_{j,i(x)} \tag{4.12}$$

Usando as equações 4.11 e 4.12 em 4.10, obtemos:

$$\Delta \mathbf{w}_j = \eta h_{j,i(x)}(\mathbf{x} - \mathbf{w}_j) \tag{4.13}$$

Finalmente, usando formalismo de tempo discreto, dado o vetor peso sináptico $\mathbf{w}_j(n)$ no tempo n+1 é definido por:

$$\mathbf{w}_j(n+1) = \mathbf{w}_j(n) + \eta(n) h_{j,i(x)}(n)(\mathbf{x} - \mathbf{w}_j(n)) \tag{4.14}$$

o qual é aplicado a todos os neurônios na grade dentro da vizinhança topológica do neurônio vencedor *i*. A equação 4.14 tem o efeito de mover o vetor peso sináptico $\mathbf{w}_i$ do neurônio vencedor *i* junto ao vetor de entrada **x**. Sob repetidas apresentações dos dados de treinamento, o vetor peso sináptico tende a seguir a distribuição dos vetores de entrada devido a atualização da vizinhança. Por isso o algoritmo leva-nos à ordenação da topologia do mapa de aspecto no espaço de entrada no sentido que neurônios que são adjacentes na grade tenderão a ter vetor peso sináptico similar. (HAYKIN, 1996)

O processo adaptativo é dividido em duas fases: uma fase de ordenação ou auto-organização seguida por uma fase de convergência. Essas duas fases do processo adaptativo serão descritas a seguir:

4.2.4.3.1 - Fase 1: Fase de ordenação

Esta fase ocorre durante um certo número de épocas. Inicia quando a distância entre dois neurônios é máxima, e vai diminuindo a distância entre neurônio vizinhos. Nessa fase a taxa de aprendizagem é próxima de 1, e diminui até que ela alcança a fase de regulagem da taxa de aprendizagem, nessa fase a taxa de aprendizagem é próxima de zero. Quando a distância da vizinhança e a taxa de aprendizagem diminuem, os neurônios da rede ordenam o espaço de entrada com a mesma topologia a qual eles são ordenados fisicamente.

4.2.4.3.2 - Fase 2: Fase de regulagem

A distância entre neurônios vizinhos continua diminuindo (a qual deve incluir somente vizinhos próximos i.e., tipicamente que tenham distância 1.0 entre si). A taxa de aprendizagem continua a diminuir, mas muito lentamente.

O número de épocas na fase de regulagem do treinamento deve ser muito maior do que o número de épocas na fase de ordenação, porque essa fase é mais longa.

O vetor peso do neurônio inicialmente toma grandes passos na área do espaço de entrada onde está o vetor de entrada. Então, quando o tamanho da vizinhança diminui para 1, o mapa tende a ordenar topologicamente os vetores de entrada apresentados. Uma vez que o tamanho da vizinhança é 1, a rede deve estar satisfatoriamente bem ordenada e a taxa de aprendizagem é diminuída lentamente sobre um longo período para dar tempo dos neurônios expandirem igualmente através do vetor de entrada.

As distâncias entre neurônios de um mapa auto-organizativo são ordenadas aproximadamente iguais se os vetores de entrada aparecem com igual probabilidade através de uma seção do espaço de entrada. Se os vetores de entrada são apresentados com freqüência à rede neural, a camada do mapa de características tende a alocar os neurônios em uma mesma área do mapa de conhecimento. Por isso, mapas auto-organizativos, enquanto aprendem a

categorizar suas entradas, também aprendem a topologia e a distribuição de suas entradas.

Como podemos notar, mapas auto-organizativo diferem de aprendizado competitivo convencional nos quais os neurônios obtêm seus pesos atualizados. Ao invés de atualizar somente o vencedor, o mapa auto-organizativo atualiza os pesos do vencedor e seus vizinhos. O resultado é que neurônios vizinhos tendem a ter vetores pesos similares e respondem para vetores de entrada similares (DEMUTH & BEALE, 1994).

4.2.5 - Inicialização dos pesos

Os pesos da rede devem ser inicialmente pequenos e normalizados. Se os valores dos pesos forem muito grandes a rede pode não convergir ou os ciclos de treinamento serão muito lentos. À razão para isto pode ser explicada intuitivamente. Tipicamente, os vetores de treinamento de entrada estarão sobre uma região limitada do espaço de entrada, correspondendo a sua classe. Se os vetores pesos estão espalhados, então, a situação pode aparecer quando muito dos vetores pesos estão em uma orientação muito diferente da maioria dos vetores de entrada de treinamento. Esses neurônios não vencerão qualquer das competições e ficarão impossibilitados em formar o mapa topológico. A conseqüência disto é que a vizinhança no mapa auto-organizativo será povoada esparsamente com neurônios treinados, tanto que não podem existir neurônios suficientes para separar adequadamente as classes. Isto resultará em uma classificação ruim devido à inabilidade do mapa auto-organizativo de distinguir entre as entradas (BEALE & JACKSON, 1990).

4.2.6 - Regra de aprendizagem e *bias*

Uma das limitações de redes competitivas é que alguns vetores de entrada nem sempre são alocados na grade de neurônios. Em outras palavras, algum vetor peso pode iniciar longe de todos os vetores de entrada e nunca vencer a competição, não importando até quando o treinamento é continuado. O resultado é que seu peso não aprende e então nunca vence. Esse neurônio é chamado de neurônio morto. Para evitar que isto aconteça, *bias* são usados

para dar aos neurônios que raramente vencem a competição uma vantagem sobre os neurônios que vencem freqüentemente. Um *bias* positivo, adicionado a uma distância negativa, faz com que o neurônio provavelmente vença.

Para fazer este trabalho uma média de neurônios de saída é mantida. É equivalente a porcentagem de vezes que cada saída é 1. Saída 1 significa que o neurônio é vencedor. Assim a média é usada para atualizar os *bias* com a função de aprendizagem então os *bias* que freqüentemente ativam neurônios serão menores, e *bias* que não freqüentemente ativam neurônios serão maiores.

O resultado é que os *bias* de neurônios que não têm respondido muito freqüentemente aumentará versus os *bias* de neurônios que tem respondido freqüentemente. Quando os *bias* que não ativam freqüentemente neurônios aumentam o espaço de entrada o qual os neurônios respondem, aumenta e movem junto ao vetor de entrada. Eventualmente os neurônios responderão para um número igual de vetores tanto quanto outros neurônios. Isto tem dois efeitos bons. Primeiro, se um neurônio nunca vence uma competição porque seus pesos estão longe de qualquer vetor de entrada, seus *bias* eventualmente serão grandes o suficiente e serão capazes de vencer a competição. Quando isto acontece, ele moverá junto a um grupo de vetores de entrada. Uma vez que o peso tem movido junto a um grupo de vetor de entrada e o neurônio está vencendo consistentemente, seu *bias* diminuirá para zero. Por isso o problema de morte dos neurônios é resolvido.

A segunda vantagem de *bias* é que eles forçam cada neurônio a classificar fortemente a mesma porcentagem de vetores de entrada. Por isso, se uma região do espaço de entrada é associada com um número maior de vetores de entrada do que outra região, a região mais acumulada atrairá mais neurônios e será classificada dentro de subseções menores (DEMUTH & BEALE, 1994).

4.2.7 - Generalização

Um dos aspectos mais importantes de redes neurais é sua habilidade de generalização, isto é, classificar com sucesso os padrões que não tenham sido

apresentados previamente. Redes auto-organizativas generalizam colocando na mesma classe padrões similares aos quais ela classificou durante o treinamento. Isto significa que a identificação de regimes de escoamento através de um conjunto representativo de dados é uma proposta possível, desde que o conjunto representativo de padrões tenha sido classificado corretamente pela rede, isto é, a generalização permitirá entradas similares serem classificadas bem. Isto também significa que, mesmo com alguma alteração na entrada, a rede neural classificará bem pela sua similaridade com as entradas utilizadas no treinamento (BEALE & JACKSON, 1990).

4.3 – Exemplo de aplicação de uma rede neural auto-organizativa

Seja, então, o conjunto de dados de entrada denotados por $\mathbf{p} \in \Re^n$. Por sua vez, a rede neural auto-organizativa é definida a partir de modelos nodais ou neurônios, $\mathbf{w}_j \in \Re^n$, com j = 1, 2, ...l, cada qual associado aos dados de entrada segundo um critério de menor distância d(**p**, $\mathbf{w}_j$).

$$\mathbf{p} \Leftrightarrow w_j \rightarrow i(p) = \min_k \{d(\mathbf{p}, \mathbf{w}_j)\} \tag{4.15}$$

O treinamento de uma rede auto-organizativa corresponde a ajustar seus neurônios de forma que o mapeamento de todos os possíveis dados do vetor de entrada **p** sobre o conjunto $\mathbf{w}_j$ seja ordenado e geometricamente representativo da informação contida nos dados primários. Isso pode ser feito a partir de uma heurística em que cada neurônio compete pela captura de **p** e, conseqüentemente, pelo direito de ajustar sua parametrização interna. Os passos da heurística proposta são os seguintes:

1. Os neurônios i(p) são estruturados segundo uma malha n-dimensional de projeção e inicializados com valores pré-determinados ou aleatórios, preferencialmente extraídos do conjunto de dados de entrada p_n, com n = 1,2,...m.

2. Cada entrada p_n é associada ao neurônio w_j que mais lhe é semelhante segundo o critério (1), para uma definição conveniente de d(. , .). Uma lista é formada a partir destas associações.

3. Arbitrando-se uma vizinhança h_i em torno do neurônio i(p) sobre a malha de projeção, uma lista integrada é definida a partir das listas de cada neurônio pertencente à vizinhança.

4. Aqueles dados p_n pertencentes à h_i são empregados na construção de um elemento ξ_i, baricentro da vizinhança em torno de i(p), calculado a partir de uma média genérica convenientemente arbitrada. No caso de vetores do $\Re^n$ e distância euclidiana, normalmente se adota ξ_i como sendo a média aritmética dos elementos da lista integrada.

5. O neurônio i(p) é ajustado segundo uma taxa de aprendizado $\alpha \in (0, 1]$, isto é:

$$i(p) \leftarrow \alpha\xi_i + (1-\alpha)i(p) \tag{4.16}$$

e seus vizinhos segundo um critério de propagação ε, usualmente diminuindo de forma progressiva na medida em que os neurônios vizinhos estão mais distantes do neurônio central i(p), ou seja:

6. Os passos 4) e 5) são repetidos para cada neurônio da malha e suas respectivas vizinhanças.

7. O procedimento, como um todo é iterado ou, mais especificamente, os passos 2) a 6) até que i(p) coincida com ξ_i, cujo conjunto é representativo da essência dos dados de entrada p_n.

A título de ilustração, vamos considerar um exemplo numérico em que dados do $\Re^3$ devem ser abstraídos sobre uma rede neural auto-organizativa bidimensional hexagonal com 4 neurônios, conforme indicado na Figura 4.10. A relação topológica entre os dados de entrada é evidente, indicando a presença

dos 3 centróides definidos por (1, 1, 1), (2, 2, 2) e (3, 3, 3), em torno dos quais se distribuem uniformemente os dados de treinamento. Nesse caso, apenas uma inspeção visual direta do gráfico e das distribuições de probabilidade nos planos xy, xz e yz seria suficiente para inferir a relação entre os dados. Ocorre, porém, que mesmo numa situação simples como a proposta, a análise direta se torna impraticável na medida em que a complexidade e/ou a dimensão dos dados aumenta, justificando o emprego de métodos matemático-numéricos de agrupamento ("clusterização") de dados como as redes auto-organizativas e outros.

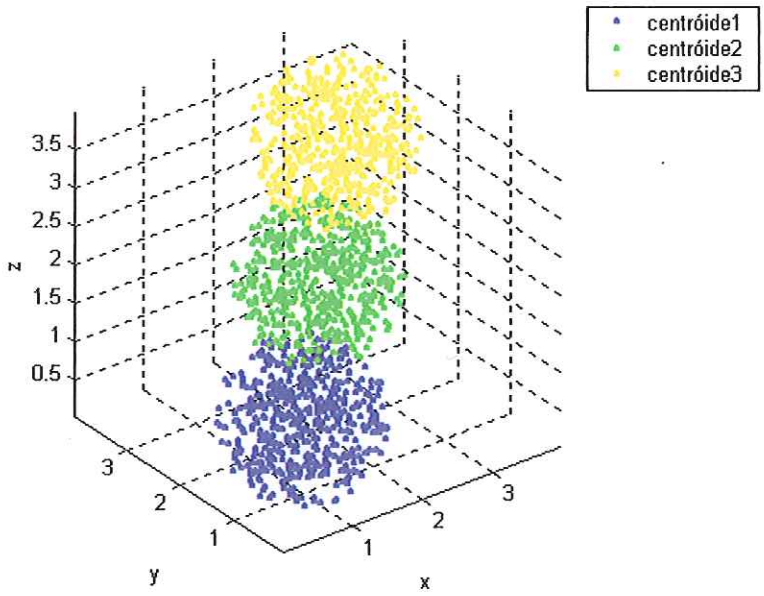

Figura 4.10: Exemplo de ajuste de uma rede auto-organizativa sobre pontos do $\Re^3$ concentrados sobre os centróides (1,1,1), (2,2,2) e (3,3,3).

Seguindo a heurística descrita acima, o primeiro passo se dá com a inicialização dos neurônios e com a definição de suas vizinhanças. No caso, adotamos valores uniformemente distribuídos (0.0, 1.0) , (0.0, 1.0) , (0.0, 1.0) e vizinhanças formadas pelos neurônios que distam 1 passo de malha do neurônio central. Na Figura 4.10 está representada os 3 centróides nas cores azul, verde e amarelo . É importante ressaltar que estas escolhas, embora não influenciem de forma significativa no caso estudado, podem aumentar ou diminuir substancialmente a convergência em problemas de maior

dimensionalidade e, portanto, devem ser feitas de forma extremamente criteriosa. O segundo passo consiste em calcular uma tabela de distâncias entre cada dado e cada neurônio da rede e formar uma lista de associações segundo o critério (1). Em seguida são formadas as listas integradas por vizinhanças e calculados os baricentros ξi adotando-se, no caso, $\alpha = 1$ e $\varepsilon = 0.25$ (constantes) para ajuste dos neurônios centrais e vizinhos segundo as fórmulas de aprendizado (2) e (3) respectivamente. Com isso, completam-se os passos 3, 4, 5 e 6, cujas iterações até um dado número de ciclos ou épocas correspondem ao passo 7.

Na Figura 4.11 está representado os centróides e os pesos dos neurônios em que a rede classificou cada centróide. Pode-se observar que os pesos da rede são uma média dos vetores de entrada e os pesos definem bem cada região do espaço de entrada.

A nova configuração da rede, obtida após 100 épocas, é mostrada na Figura 4.11, na qual se pode observar a tendência dos neurônios da SOM em se agrupar em torno dos centróides definidos inicialmente. É possível constatar também que os neurônios 3 e 2 são atraídos para o mesmo centróide e que competirão pela captura dos dados naquela região. O efeito disso durante o treinamento é o de eventualmente produzir um ciclo limite em que os valores se alternam entre estes neurônios e, conseqüentemente, o de limitar a convergência global. Procedimentos de fusão e extinção de neurônios, ativados em função do número de capturas e da convergência para um mesmo ponto no espaço dos dados respectivamente, podem ser definidos para evitar esse e outros tipos de problemas.

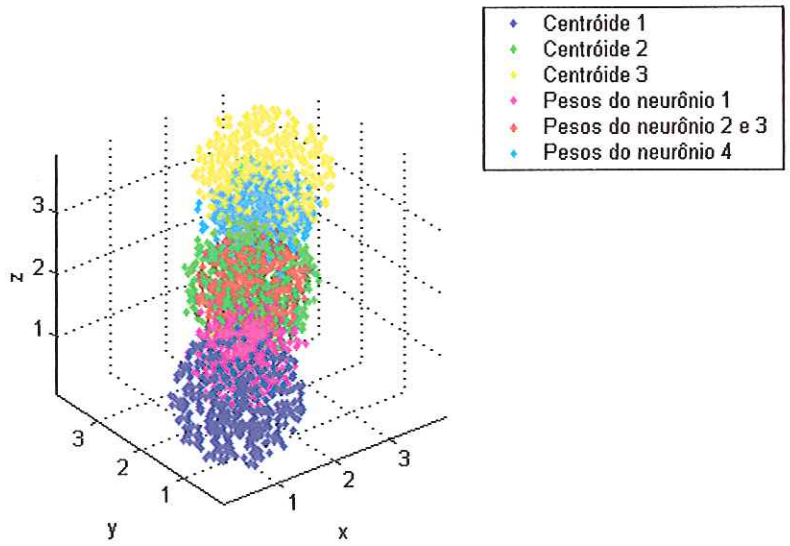

Figura 4.11: Exemplo de ajuste de uma rede neural auto-organizativa sobre pontos do $\Re^3$ concentrados sobre os centróides (1,1,1), (2,2,2), (3,3,3) – valores finais após o treinamento.

4.4 - Instalações experimentais

Vários testes experimentais foram feitos neste trabalho. As medidas foram realizadas no oleoduto piloto do Núcleo de Engenharia Térmica e Fluidos da Escola de Engenharia de São Carlos da Universidade de São Paulo, para testes transientes gás-líquido em escoamentos bifásicos.

O oleoduto piloto (Figuras 4.12 e 4.13) opera com misturas gás-líquido-líquido e possui seções de teste retilíneas com 12 m de extensão e diâmetros internos de 45, 30 e 24 mm, montadas em uma estrutura inclinável até ângulos de ± 10º. Um sistema de tanques instalados à jusante das seções de testes é responsável pela separação primária ar-líquido e, subseqüentemente, pela separação líquido-líquido. Bombas centrífugas equipadas com inversores de freqüência de 7,5 kW recirculam as fases líquidas, mensuradas com auxílio de placas de orifício instaladas nas respectivas linhas de injeção. Um compressor de parafuso de 50 kW assegura o suprimento de ar, cujo controle é feito através de servo-válvulas eletro-pneumáticas equipadas com sensores de vazão. A instrumentação de análise inclui sensores de pressão de resposta

rápida para medida da perda de carga total e diferencial, sensor capacitivo para medida da fração de fase e sensor acústico para ecografia do escoamento. Um microcomputador equipado com sistema de aquisição digitaliza os sinais medidos, tanto de operação quanto de análise, assim como os sinais de comando (servo-válvulas e inversores de freqüência).

Nesse trabalho foram feitos testes para um escoamento bifásico ar-água. Utilizou-se a seção de teste retilínea com 12 m de extensão e diâmetro interno de 30 mm.

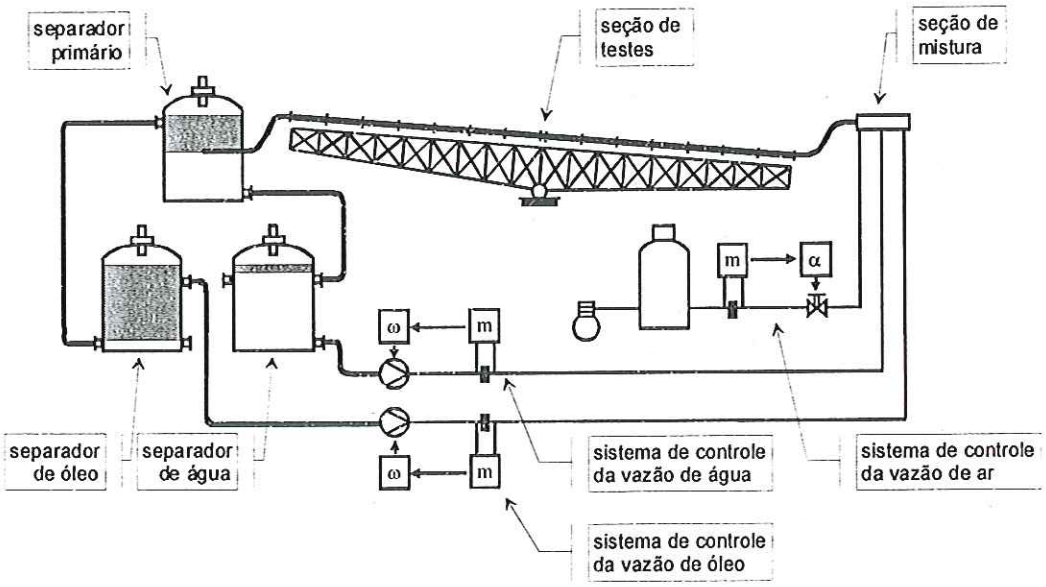

Figura 4.12: Representação esquemática do oleoduto trifásico piloto do Núcleo de Engenharia Térmica & Fluidos (NET&F).

Figura 4.13: Foto do oleoduto piloto do Núcleo de Engenharia Térmica & Fluidos (NET&F).

Capítulo 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 às medidas de capacitância elétrica, variação de pressão na tubulação e pressão flutuante. Essas medidas foram obtidas respectivamente por meio de uma sonda capacitiva e medidores de pressão. Para cada teste, estes sinais foram amostrados a taxas de 30 Hz até o máximo da capacidade das memórias de armazenamento (2^{14} amostras). Cada ensaio teve duração de 546 segundos. O quadro de ensaios está definido na Tabela 5.1.

Tabela 5.1: Codificação dos ensaios

Legenda	Ensaio	Q_l (Kg/s)	Q_g(Kg/s)
1	Estratificado liso	0,0800	0,0014
2	Estratificado ondulado	0,0840	0,0075
3	Estratificado rugoso	0,1060	0,0190
4	Intermitente	0,6910	0,0020
5	Bolhas	7,05	0,0120
6	Anular	0,3500	0,0400

Ensaios permanentes são realizados em número suficiente de pares de vazões de ar e água visando reproduzir, da melhor maneira possível, os diferentes regimes de escoamento em toda sua variabilidade. A matriz de ensaios é reproduzida na carta de Taitel e Duckler (1976) da Figura 5.1.

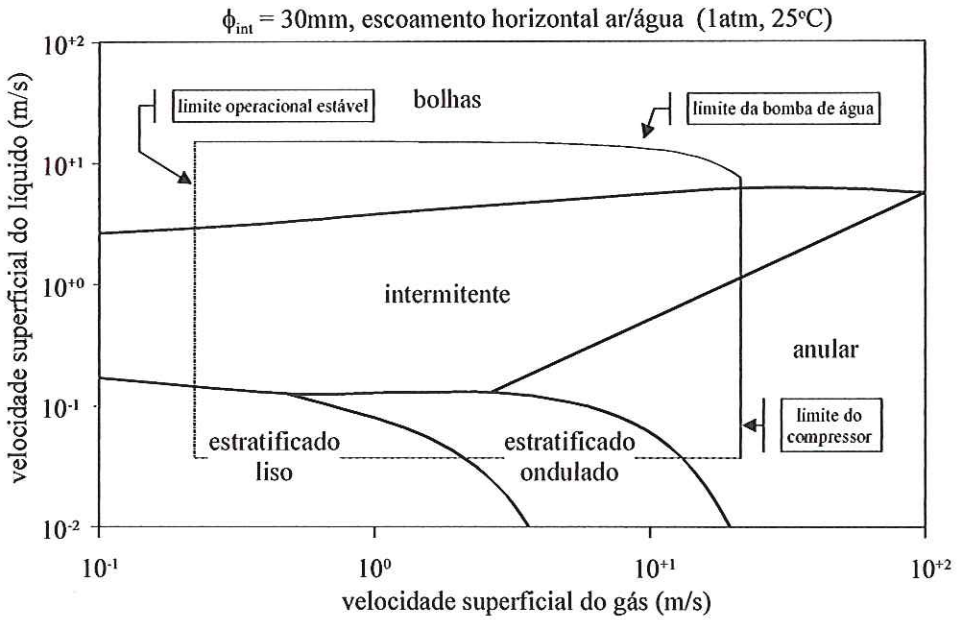

Figura 5.1: Mapa de Taitel e Dukler (1976) construído para um escoamento ar-água em tubulação horizontal de 30 mm de diâmetro interno.

Os dados dos regimes de escoamentos descritos na Tabela 5.1 estavam dispostos em matrizes de 16384 linhas por 3 colunas, onde 16384 é o número de amostras e 3 é, respectivamente, a medida de capacitância, variação de pressão na tubulação e pressão flutuante.

A arquitetura da rede foi definida, a partir de estudos preliminares, da seguinte maneira: camada de entrada e uma grade com 10 neurônios. O número de neurônios da grade foi ajustado no sentido de capacitar a rede à aprender tarefas complexas pela extração progressiva de aspectos significantes dos padrões de entrada (HAYKIN,1994). Como visto anteriormente, o número de neurônios na grade não é fixado previamente, ou seja, pode-se colocar um número de neurônios igual ao número de classes que se deseja identificar, ou não. Nesse trabalho optou-se em colocar um número de neurônios maior do que o número de regimes de escoamento que se deseja identificar. No caso deseja-se que a rede identifique 6 regimes de escoamentos diferentes e a grade possui 10 neurônios. O objetivo é ver se a rede consegue encontrar de forma autônoma os seis regimes já conhecidos, mesmo tendo 10 neurônios na grade. Depois de treinada, a rede identificou 6 regimes de escoamento diferentes.

A função topológica utilizada para a grade foi a hexagonal. A topologia hexagonal é melhor para visualização (KOHONEN, 2001). A função distância utilizada foi a Euclidiana, pois, com o mapa auto-organizativo, esta é a função mais utilizada. O valor utilizado da taxa de aprendizagem na fase de ordenação foi de 0,9 e o número de épocas foi 1000 e na fase de regulagem o valor da taxa de aprendizagem foi de 0,01 e o número de época foi 1000. Na literatura, é recomendado que o número de épocas na fase de regulagem seja maior do que na fase de ordenação. Nesse trabalho foi utilizado o mesmo número de épocas nas duas fases e a rede neural apresentou um bom desempenho.

Para o treinamento das redes neurais foram tomadas matrizes de 300 linhas por 3 colunas. Esse número foi determinado de forma que o processo de treinamento pudesse ser completado satisfatoriamente, num tempo não excessivamente longo e que não fossem perdidas características dos sinais analisados. Foram utilizadas 10 matrizes (300 x 3) de cada regime de escoamento no treinamento da rede neural.

Nas Figuras 5.2, 5.3, 5.4, 5.5, 5.6 e 5.7 estão plotados os dados de uma matriz (300 x 3) de cada regime de escoamento utilizada no treinamento da rede neural.

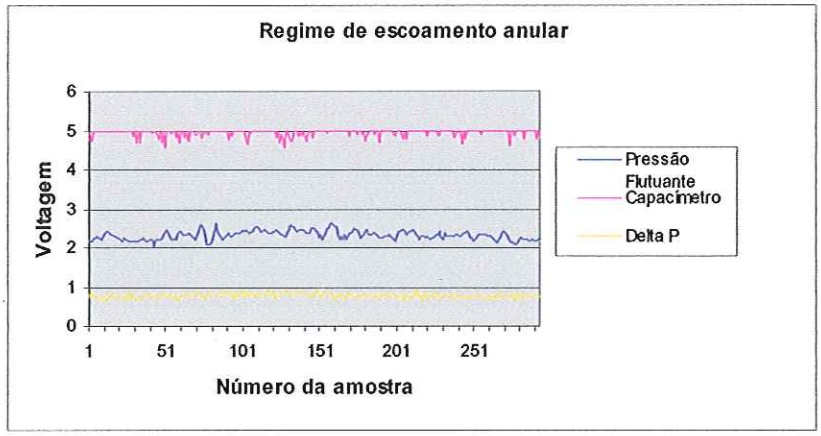

Figura 5.2: Dados de entrada do regime de escoamento anular para rede neural.

Observando os gráficos das Figuras 5.2, 5.3, 5.4, 5.5, 5.6, 5.7, nota-se que os valores das matrizes de treinamento não são muito diferentes de um regime de escoamento para o outro. Isso mostra que a rede neural auto-

organizativa é muito eficiente, pois, mesmo com valores próximos de um regime para o outro, ela conseguiu identificar corretamente os regimes de escoamento.

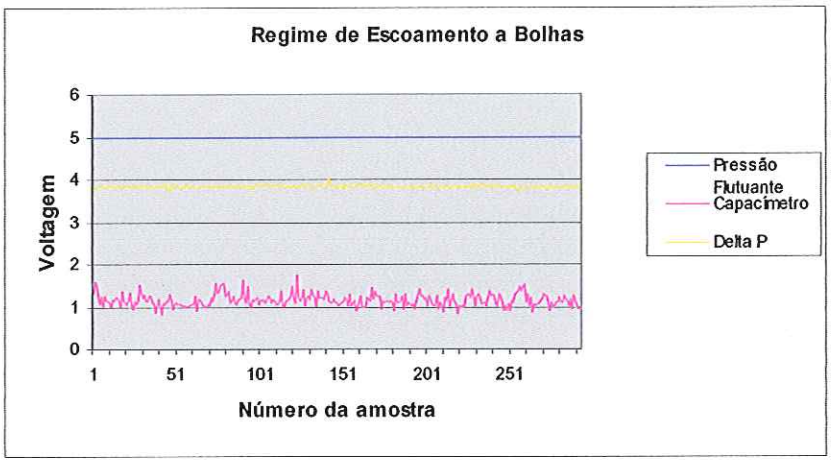

Figura 5.3: Dados de entrada do regime de escoamento a bolhas para rede neural.

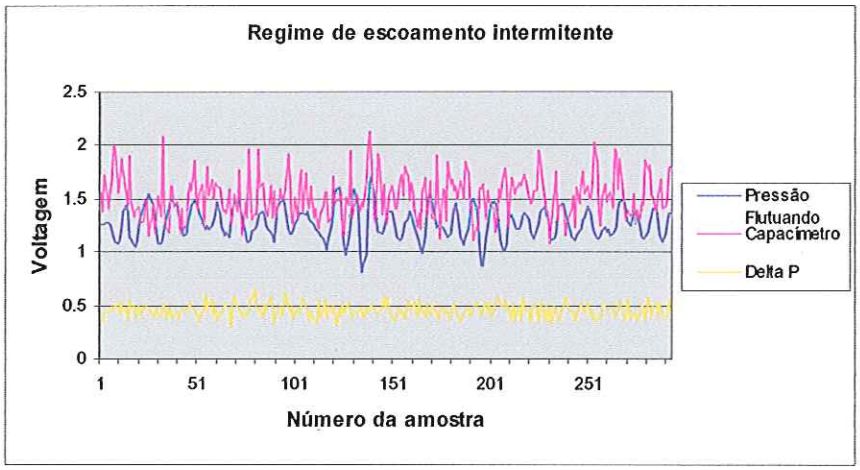

Figura 5.4: Dados de entrada do regime de escoamento intermitente para rede neural.

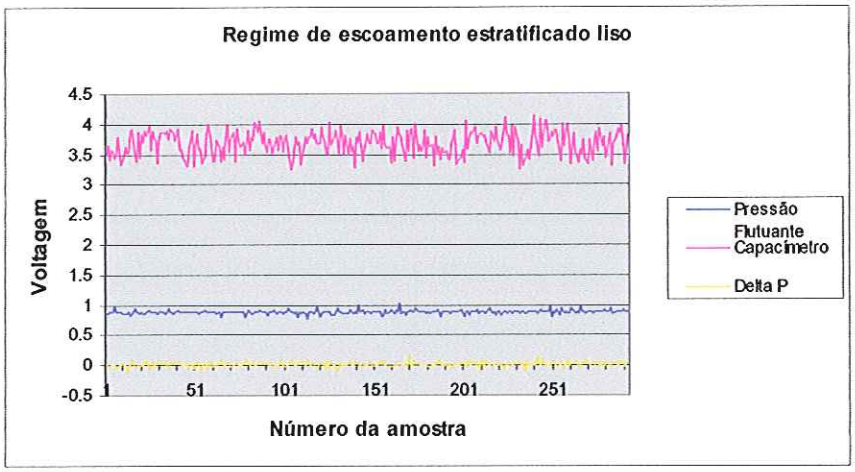

Figura 5.5: Dados de entrada do regime de escoamento estratificado liso para rede neural.

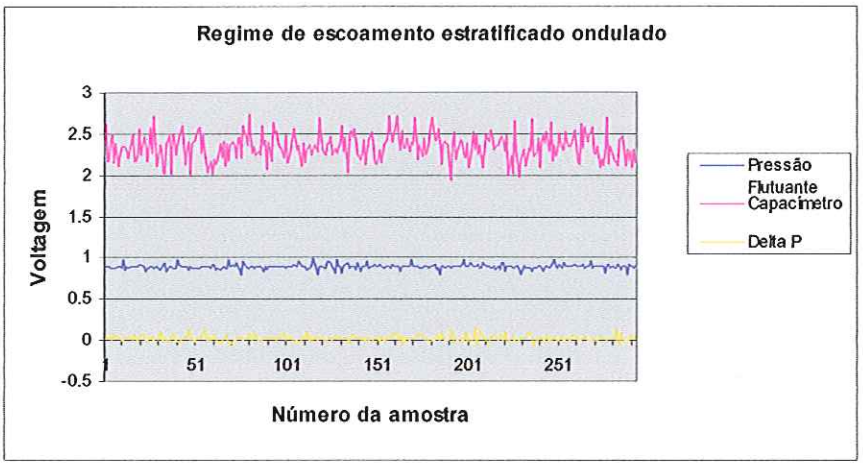

Figura 5.6: Dados de entrada do regime de escoamento estratificado ondulado para rede neural.

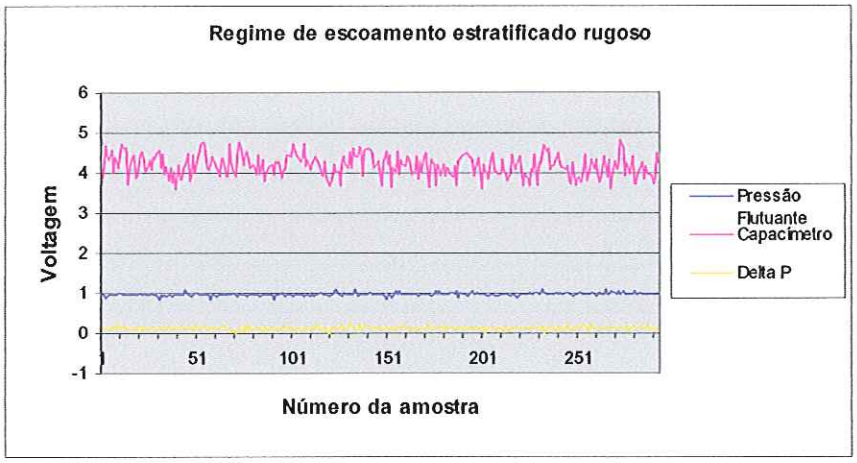

FIGURA 5.7: Dados de entrada do regime de escoamento estratificado rugoso para rede neural.

Depois de treinada, a rede neural identificou o regime de escoamento anular no neurônio 1, o regime de escoamento estratificado rugoso no neurônio 2, o regime de escoamento intermitente no neurônio 4, o regime de escoamento estratificado liso no neurônio 7, o regime de escoamento estratificado ondulado no neurônio 8, o regime de escoamento à bolhas no neurônio 10. Na tabela 5.2 está representado o treinamento da rede neural.

Tabela 5.2: Neurônio de identificação dos regimes de escoamento pela rede neural depois de treinada.

Regime de Escoamento	Neurônio de Identificação
anular	1
Estratificado rugoso	2
intermitente	4
Estratificado liso	7
Estratificado ondulado	8
Bolhas	10

Na Figura 5.8 está representado um gráfico com os exemplos de treinamento da rede neural para cada regime de escoamento e os pesos dos neurônios em que a rede neural identificou os regimes. Comparando com a

Tabela 5.2, observa-se que os pesos dos neurônios estão exatamente em cima de cada regime de escoamento dificultando até a visualização ou estão muito próximos do regime de escoamento o qual ele identificou. Os pesos da rede são uma média dos vetores de entrada e os pesos definem bem cada região do espaço de entrada.

Como podemos observar na Figura 5.8, o regime de escoamento estratificado liso e o regime de escoamento estratificado rugoso estão sobrepostos e mesmo assim a rede neural os identificou em neurônios diferentes, ou seja, a rede neural conseguiu capturar as diferenças entre os dois regimes comprovando assim a sua utilização na identificação de regimes de escoamento.

Para uma visualização melhor dos pesos de cada neurônio optou-se por plotar separadamente nas Figuras 5.9, 5.10, 5.11, 5.12, 5.13, 5.14 cada regime de escoamento com os respectivos pesos dos neurônios que os identificou.

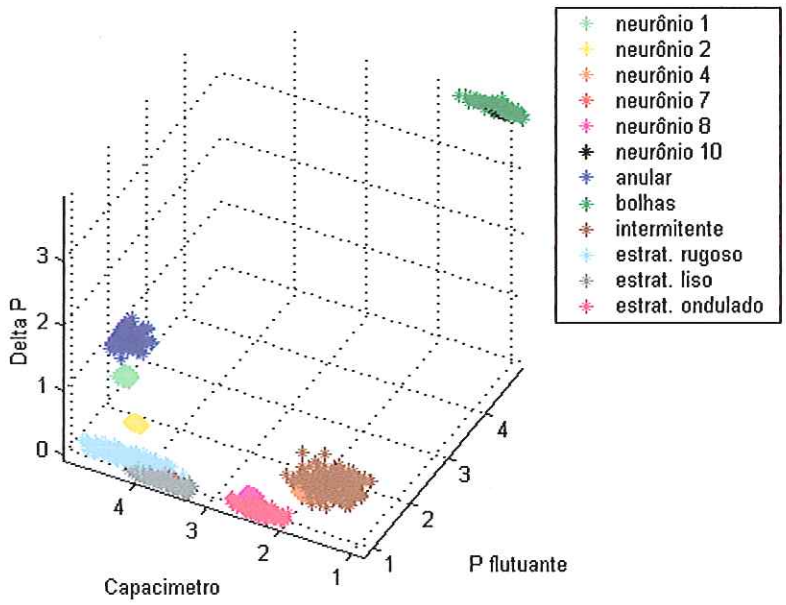

Figura 5.8: Exemplos de entrada de cada regime de escoamento e os respectivos pesos dos neurônios.

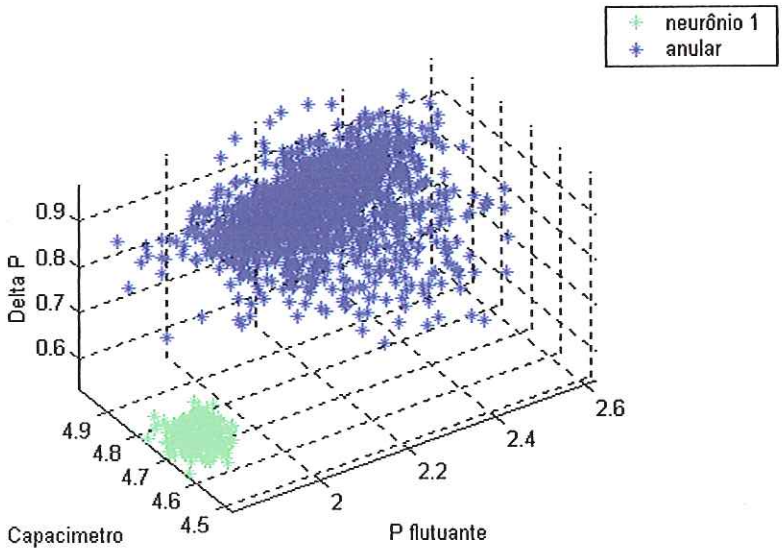

Figura 5.9: Regime de escoamento anular e pesos do neurônio 1.

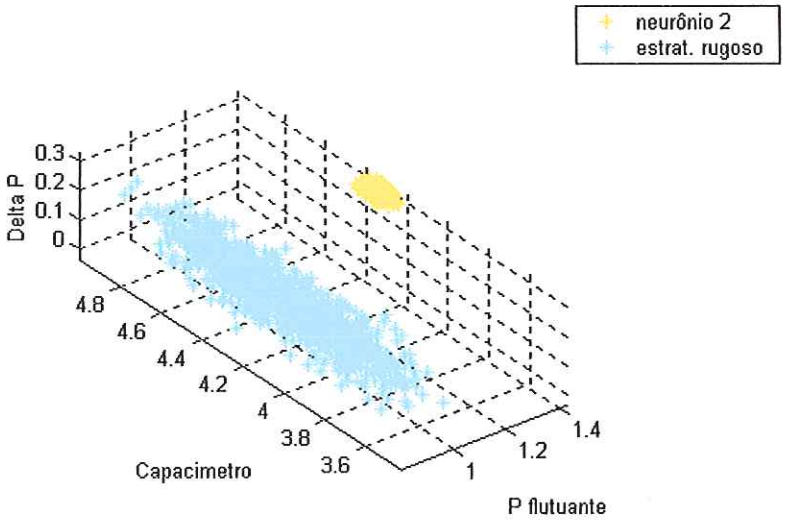

Figura 5.10 : Regime de escoamento estratificado rugoso e pesos do neurônio 2.

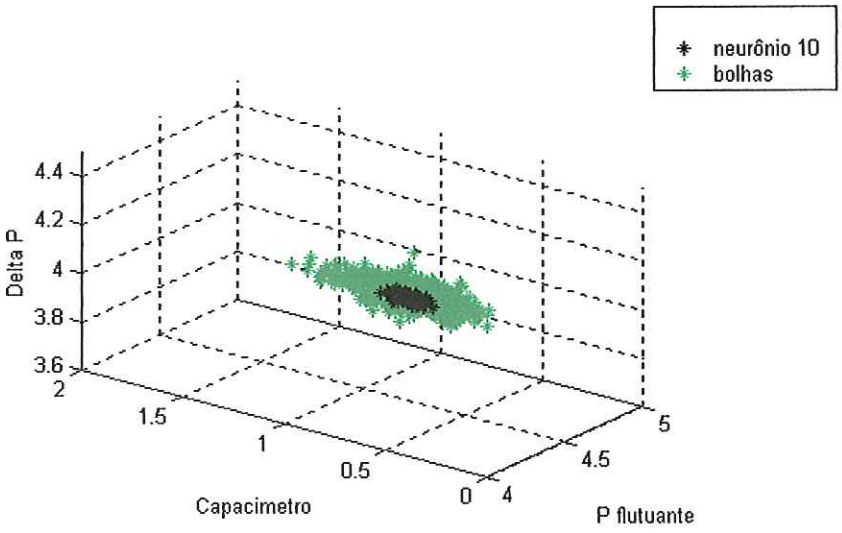

Figura 5.11: Regime de escoamento a bolhas e pesos do neurônio 10.

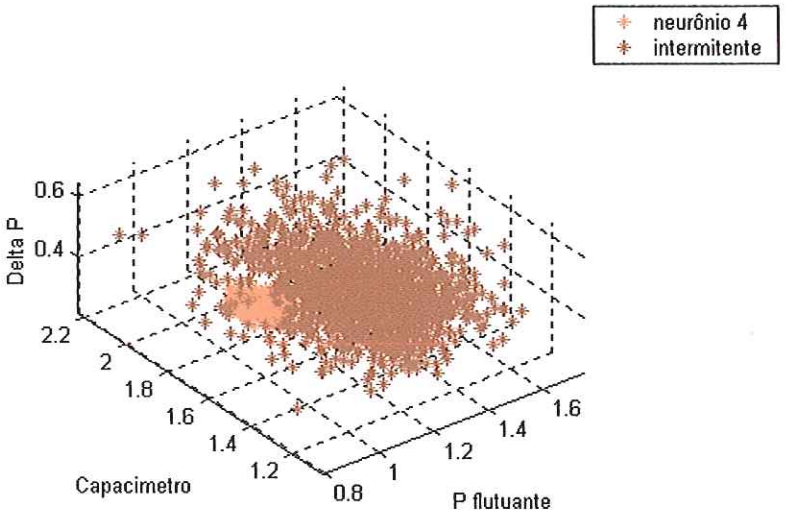

Figura 5.12: Regime de escoamento intermitente e pesos do neurônio 4.

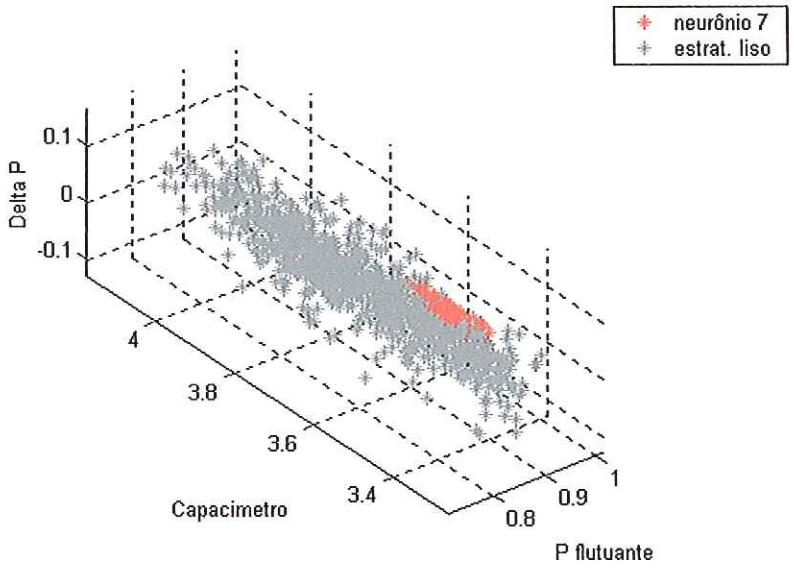

Figura 5.13: Regime de escoamento estratificado liso e pesos do neurônio 7.

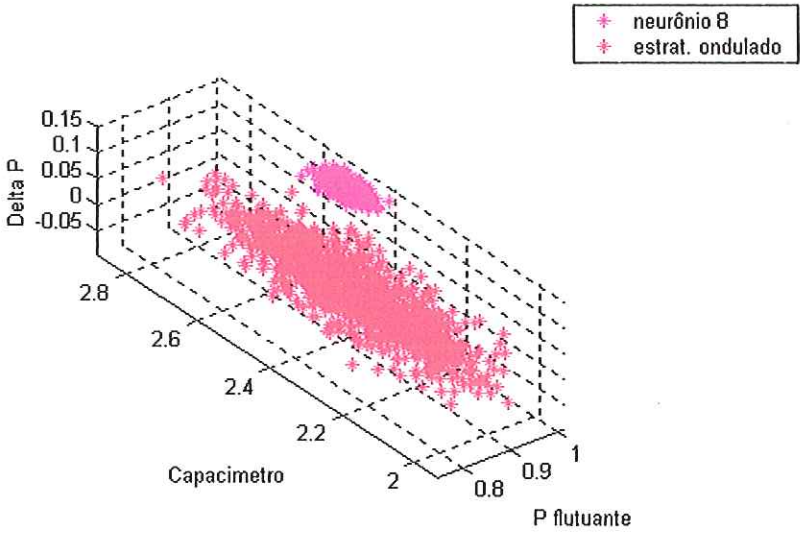

Figura 5.14: Regime de escoamento estratificado ondulado e pesos do neurônio 8.

Para a generalização os sinais característicos de diferentes regimes de escoamento foram apresentados à rede neural de forma que seus índices de reconhecimento correto pudessem ser levantados. Foram feitas simulações para vários testes de regimes de escoamentos que não foram utilizados no

treinamento. A seguir serão apresentados gráficos da classificação feita pela rede neural para vários testes.

O gráfico da Figura 5.15 apresenta a simulação de dados que não foram utilizados no treinamento. Foram apresentados 10 exemplos de cada regime de escoamento para a rede neural.

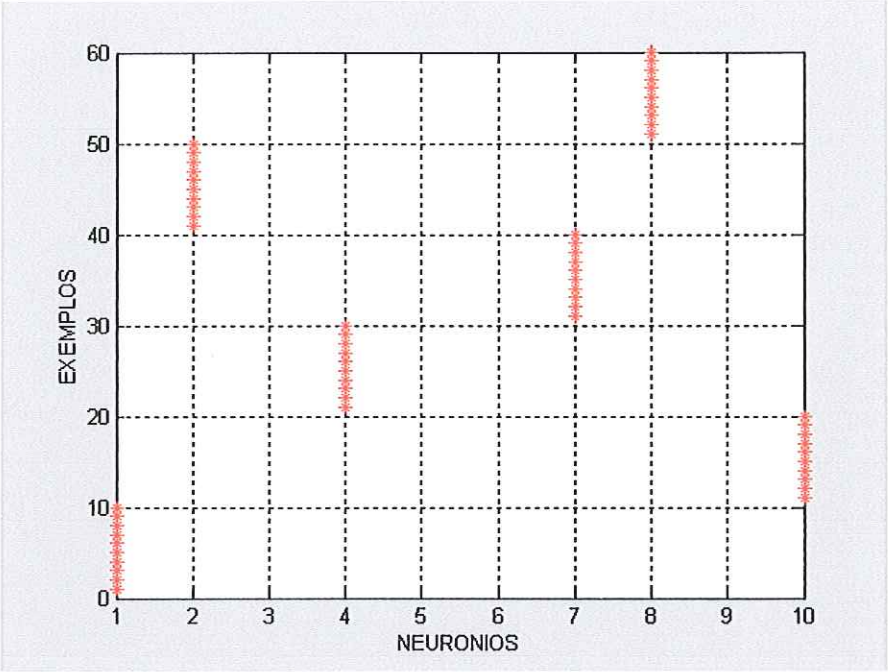

Figura 5.15: Gráfico da identificação da rede neural para dados não utilizados no treinamento.

Do exemplo 1 ao 10 a rede terá que identificar no mesmo neurônio como regime de escoamento anular, do 11 ao 20 como regime de escoamento a bolhas, do 21 ao 30 como regime de escoamento intermitente, do 31 ao 40 como regime de escoamento estratificado liso, do 41 ao 50 como regime de escoamento estratificado rugoso e do 51 ao 60 como regime de escoamento ondulado. Cada asterisco vermelho (*) corresponde a um exemplo, ou seja, uma matriz 300 x 3, de cada regime de escoamento.

Observando o gráfico da Figura 5.15 pode-se ver que a rede neural identificou corretamente os regimes de escoamento concordando com a identificação do treinamento.

O gráfico da Figura 5.16 apresenta outra simulação para dados não utilizados no treinamento e também não utilizados na simulação anterior. Para essa simulação os dados foram apresentados em uma seqüência diferente da qual a rede foi treinada. Primeiro foram apresentadas matrizes do regime de escoamento anular, estratificado rugoso, intermitente, bolhas, estratificado liso e estratificado ondulado. A identificação da rede neural deve ser igual , ou seja, ela deve continuar identificando os regimes de escoamento nos mesmos neurônios.

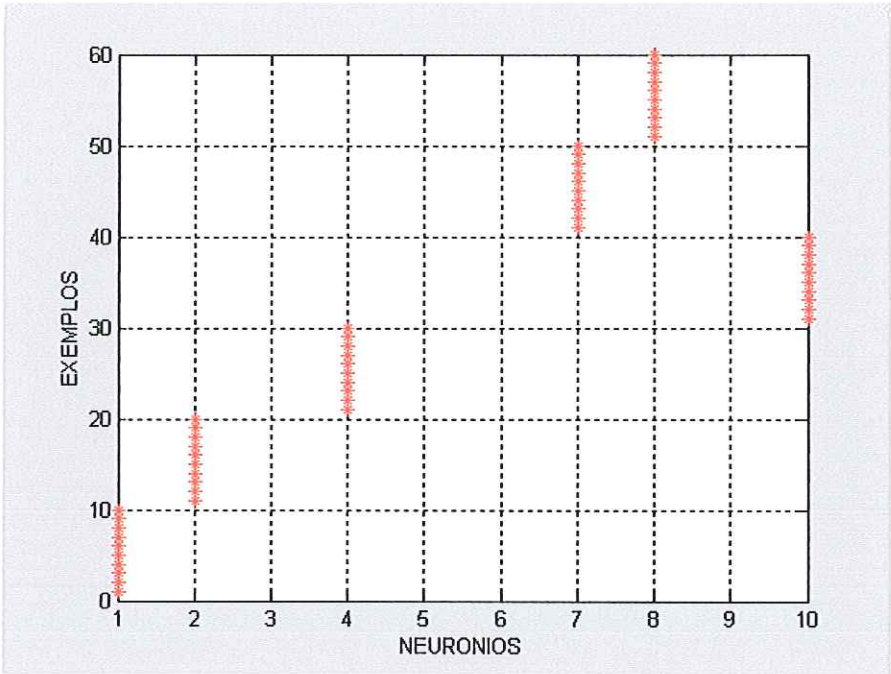

Figura 5.16: Gráfico da identificação da rede neural para dados apresentados em uma seqüência diferente da qual a rede neural foi treinada.

Do exemplo 1 ao 10 a rede terá que identificar no neurônio 1 como regime de escoamento anular, do 11 ao 20 no neurônio 2 como regime de escoamento estratificado rugoso, do 21 ao 30 no neurônio 4 como regime de escoamento intermitente, do 31 ao 40 no neurônio 10 como regime de escoamento a bolhas, do 41 ao 50 no neurônio 7 como regime de escoamento estratificado liso e do 51 ao 60 no neurônio 8 como regime de escoamento ondulado. Conforme o gráfico da Figura 5.16 observa-se que a rede neural identificou corretamente os regimes de escoamento.

O gráfico da Figura 5.17 apresenta uma terceira simulação para novos dados. Nessa simulação foram apresentados 5 exemplos de cada regime de escoamento de cada vez, ou seja, os exemplos foram misturados. Para o regime de escoamento a bolhas foram apresentados os 10 exemplos. A tabela abaixo mostra a ordem em que os regimes de escoamento foram apresentados à rede neural, o número de exemplos de cada regime de escoamento e o neurônio no qual os exemplos foram identificados.

Tabela 5.3: Dados da simulação

Regimes	**Número de exemplos**	**Neurônio**
Anular	1 a 5	1
Estratificado ondulado	6 a 10	8
Bolhas	1 a 10	10
Intermitente	1 a 5	4
Estratificado liso	6 a 10	7
Estratificado rugoso	1 a 5	2
Intermitente	6 a 10	4
Estratificado liso	1 a 5	7
Estratificado rugoso	6 a 10	2
Estratificado ondulado	1 a 5	8
Anular	6 a 10	1

O gráfico da Figura 5.17 mostra a identificação da rede neural. Como pode-se observar a rede neural identificou corretamente os regimes de escoamento.

Com base nas simulações feitas para dados não utilizados no treinamento da rede neural auto-organizativa, conclui-se que a rede neural auto-organizativa é uma ferramenta muito forte na identificação de regimes de escoamento bifásico.

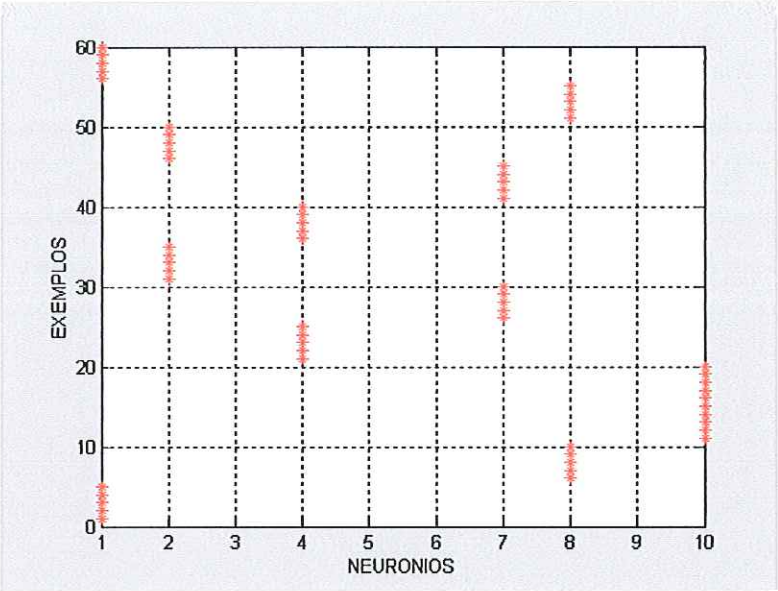

Figura 5.17: Gráfico da identificação da rede neural para dados não utilizados no treinamento, apresentando 5 exemplos de cada regime de escoamento.

Capítulo 6 – Conclusões e Sugestões

Neste trabalho foi demonstrado a utilização de redes neurais auto-organizativas para identificação de regimes de escoamento bifásico em tubo horizontal. Para treinar a rede neural auto-organizativa, utilizou-se os dados obtidos de um oleoduto piloto, do qual foi possível coletar medidas de capacitância, pressão flutuante e variação de pressão. Para verificar a generalização (identificação) das redes neurais, foram utilizados novos dados obtidos do mesmo circuito experimental, i.e. dados diferentes daqueles empregados no treinamento da rede neural.

A validação da metodologia proposta foi realizada por intermédio de testes: sinais característicos de diferentes regimes de escoamento foram apresentados à rede neural de forma que seus índices de identificação pudessem ser levantados. A rede neural teve um índice de identificação dos regimes de escoamento de 100%.

Crivelaro (1999) utilizou uma rede neural com várias camadas com aprendizado supervisionado, em associação a uma sonda de visualização direta, para a identificação de regimes de escoamento horizontal gás-líquido, produzidos em um circuito experimental. Obteve uma porcentagem mínima de acerto de 70%, uma porcentagem média de 82,8% e uma porcentagem máxima de 99%.

Comparando a porcentagem de acerto da rede neural auto-organizativa com a porcentagem de acerto da rede neural supervisionada com várias camadas concluímos que a rede neural auto-organizativa é mais eficiente do que a rede neural supervisionada com várias camadas.

Os resultados obtidos são extremamente encorajadores e justificam fortemente a continuidade das pesquisas nessa direção. Primeiramente, a rede neural auto-organizativa mostrou-se capaz de identificar, de forma completamente autônoma, todos os principais regimes de escoamento produzidos na seção de testes horizontal no oleoduto piloto do Núcleo de Engenharia Térmica & Fluidos da Escola de Engenharia de São Carlos. Em segundo lugar, foram obtidas taxas de detecção correta de 100%. O estudo de otimização da parametrização e critérios internos de treinamento da rede neural auto-organizativa mostrou que seu desempenho depende fundamentalmente de uma escolha criteriosa da duração temporal das matrizes de treinamento que lhe é apresentada. Nestas condições, uma rede auto-organizativa se revela uma ferramenta extremamente poderosa e flexível, tanto para a investigação científica de análise de dados experimentais, quanto para a aplicação direta em processos industriais de monitoração em linha. A continuidade desse trabalho pode se dar em muitas direções. Testar o procedimento proposto sobre um número maior e mais variado de regimes de escoamento multifásico, como por exemplo em escoamentos verticais gás-líquido e gás-sólido produzidos em circuitos experimentais. Uma outra perspectiva interessante é a de se produzir um sistema bifásico atípico, um tanque com duas entradas e uma saída por exemplo, e tentar identificar seus eventuais regimes de escoamento característicos através do procedimento proposto (rede neural auto-organizativa), assim como através de procedimentos complementares (análise tempo freqüência, análise fractal, etc.), de forma a poder confrontá-los e validá-los mutuamente.

Referências Bibliográficas

ANDREUSSI, P.; DONFRANCESCO, A.; MESSIA, M. (1988). An impedance method for the measurement of liquid hold-up in two-hase flow . *Int. J. Multiphase Flow*, v. 14, n. 6, p. 777-785.

BEALE, R.; JACKSON, T. (1990). *Neural Computing: An Introduction*. Institute of Physics Publisning, Bristol and Philadelphia.

BISHOP, C. M. (1994). Neural network validation: na illustration from the monitoring of multiphase flow. *IEE Conference Publication 3rd International Conference on Artificial Neural Networks,* n.372, p.41-46, May.

BRILL, J. P., (1992). State of the art in multiphase flow. *Journal of Petroleum Technology,* n.5, v. 44, p. 538-541, may.

CECCIO, S. L.; GEORGE, D. L. (1996). A review of electrical impedance techniques for the measurement of multiphase flows. *Journal of Fluids Engineering*, v. 118, p. 391-399, june.

COLLIER, J. G. (1981). *Convective boiling and condensation*. 2.ed. England, McGraw - Hill Book Company.

CRIVELARO, K. C. O. (1999). *Identificação de regimes de escoamento bifásico com auxílio de redes neurais.* São Carlos. 94p. Dissertação

(Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

DEMUTH, H.; BEALE, M. (1994). Neural networks toolbox user's guide. Massachusetts.

DANIELS, L. (1995). Dealing with two-phase flows. *Chemical Engineering*, v. 102, p. 70-78, june.

DELPRAT, N.; DIASPARRA, B.; HERVIEU, E. (1999). Identification des régimes d'une représentation spatio-fréquentielle. *Comptes Reudus de L'Academie Science./*no prelo*/*

DOEBELIN, E. O. (1990). *Measurement systems application and design*. 4. Ed. New York, McGraw-Hill.

DONG, F.; JIANG, Z. X.; QIAO, X. T.; XU L. A. (2003). Application of electrical tomography to two-phase pipe flow parameters measurement. *Flow measurement and instrumentation,* v. 14, p. 183-192.

DRAHOS, J.; CERMÁK, J. (1989). Diagnostic of gas-liquido flow patterns in chemical engineering systems. *Chemical Engeneering Processes*, v.26, p.147-164, Apr.

FAUSSET, L. (1994). *Fundamentals of neural networks: architectures, algorithms e applications*. New Jersey, Prentice-Hall.

FRANÇA, F.; ACIKGOZ, M.; CLAUSSE, A. (1991). An application of fractal techniques to flow regime identification. In: BURNS, A. P., ed. *Mult-phase production*. London, Elsevier Applied Science. p. 281-293

GRUBERT, J. P. (1995). Application of neural networks in stratified flow stability analysis. *Journal of Hydraulic Engineering*, v.121i7, p. 523-532, Jul.

HAGAN, M. T.; DEMUTH, H. B.; BEALE, M. (1996). *Neural network design.* Boston, PWS Publishing Company.

HAYKIN, S. (1994). *Neural network a comprehensive foundation.* New York, Macmillan College Publishing Company.

HERVIEU, E. (2001). Identification of gas-liquid flow regimes from a space-frequency representation by use neural networks. FOURTH INTERNATIONAL CONFERENCE ON MULTIPHASE FLOW, New Orleans-Lousiana, 2001. v. cd-rom, p. 1-12.

HSIEH, C. C.; WANG, S. B.; PAN, C. (1997). Dynamic visualization of two-phase flow patterns in a natural circulation loop. *Int. J.Multiphase Flow*, v. 23, n. 6, p. 1147-1170.

HSU, Y. Y.; SIMON, F. F.; GRAHAM, R. W. (1963). Aplication of hot-wire anemometry for two-phase flow measurements such as void-fraction and slip velocity. Apresentado para o ASME Winter Meeting, Philadelphia, USA **apud** DELHAY, J. M. (1969). Hot-film anemotry in two-phase flow. IN: Two-phase flow instrumentation. 11TH NATIONAL ASME/AICHE HEAT TRANSFER CONFERENCE. Agosto, 1969. Minneapolis, Minnesota, USA. P. 58-69.

KOHONEN, T. (2001). *Self-organizing maps.* Finland, Springer.

KOVÁCS, Z. L. (1996). *Redes neurais artificiais: fundamentos e aplicações.* São Paulo, edição acadêmica.

LIN, P. Y.; HANRATY, T. J. (1987). Detection of slug flow from pressure measurements. Int. J. Multiphase Flow, v.13, n.1, p.13-21.

MARQUES, F. D. (1999). *Tópicos em métodos não convencionais para controle de sistemas dinâmicos*. Departamento de Engenharia Mecânica da Escola de Engenharia de São Carlos. São Paulo/ Notas de Aula/

MI, Y.; LI, M.; XIAO, Z.; TSOUKALAS, L. H.; ISHII, M. (1997). Impedance void-meter and neural networks for vertical two-phase flows. OECD/CSNI Specialist Meeting on Advanced Instrumentation and Measurement Techniques, Santa Barbara. Proceedings. New York, p.1-14.

MI, Y.; ISHII, M.; TSOUKALAS, L. H. (2001). Flow regimes identification methodology with neural networks and two-phase flow models. *Nuclear Engineering and Design*, n. 204, p. 87-100.

MONJI, H.; MATSUI, G. (1998). Flow pattern identification of gas-liquido two-phse flow using a neural network. *Third International Conference on Multiphase Flow*, v. cd-rom, p. 1-8, Jun.

MOON, S. K.; CHANG, S. H. (1994). Classification and prediction of the critical heat flux using fuzzy theory and artificial neural networks. *Nuclear Engineering and Design*, p.151-161.

MOREIRA, J. R. S. (1989). *Transdutor de impedância para a medida da fração de vazio.* São Paulo. Dissertação (Mestrado) - Escola Politécnica da Universidade de São Paulo.

NYDAL, O. J.; PINTUS, S.; ANDREUSSI, P. (1992). Statistical characterization of slug flow in horizontal pipes. *Int. J. Multiphase Flow*, v.18, p.439-453, Jan.

REINECKE, N.; MEWES, D. (1996). Recent developments and industrial/research applications of capacitance tomography. *Measurement Science and Technology*, v. 7, p. 233-246,jan.

SEKOGUCHI, K.; INOUE, K. (1987). Void signal analysis and gas-liquido two-phase flow regime determination by a statistical pattern recognition method. *JMSE International Journal*, v.30, n.266, p.1266-1273.

SELEGHIM JUNIOR, P. (1996). Caracterisation des changements de configuration d'un ecoulement diphasique horizontal par l'application de methodes d'analyse temps-frequence. Grenoble. 301p. Tese (Doutorado) – De L'Institut National Polytechnique de Grenoble.

SELEGHIM JUNIOR, P.; HERVIEU, E. (1998a). An objective indicator for two-phase flow pattern transition. *Nuclear Engineering and Design*, v. 184, p. 421-435.

SELEGHIM JUNIOR, P.; HERVIEU, E. (1998b). Direct imaging of horizontal gas-liquid flows. *Measurement Science & Technology*, v. 9, n. 8, p.1492-1500.

SELEGHIM JÚNIOR, P. (2002). *Criação de uma nova linha de pesquisa em instrumentação e controle de escoamentos multifásicos industriais.* São Carlos. 133p. Tese (Livre-docência) – Escola de Engenharia de São Carlos, Universidade de São Paulo.

SOLDATI, A.; PLAGLIANTI,A.; GIONA, M. (1996). Identification of two-phase flow regimes via diffusional analysis of experimental time series. *Experiments in Fluids*, v. 21, p. 151-160, feb.

SPEDDING, P. L.; SPENCE, D. R. (1993). Flow regimes in two-phase gas-liquido flow. *Int. J. Multiphase flow*, v.19, n.2, p.245-280.

SUN, T. D.; MUDDE, R.; SCHOUTEN, J. C.; SCARLETT, B.; VAN DEN BLEEK, C. M. (1999). Image reconstruction of an electrical capacitance tomography system using an artificial neural network. In: 1st WORLD CONGRESS ON INDUSTRIAL PROCESS TOMOGRAPHY, Buxton, 1999. Anais. p. 174-180.

TAITEL, Y.; DUKLER, A. E. (1976). A model for predicting flow regime transitions in horizontal and near horizontal gas-liquido flow. *AIChE Journal*, v.22, n.1, p.47-55, Jan.

YAMASHITA, Y. (1997). Time delay neural networks for the classification of flow regimes. *Computers & Chemical Engineering*, v.21, p.367-371.

YAND, A. S.; KUO, T. C.; LING, P.H. (2003). Application of neural networks to prediction of phase transport characteristics in high-pressure two-phase turbulent bubbly flows. *Nuclear Engineering and Design*, v. 223, p. 295-313.

YAN, H.; LIU, Y. H.; LIU, C. T. (2004). Identification of flow regimes using back-propagation networks trained on simulated data based on a capacitance tomography sensor. *Measurement Science and Technology*, v. 15, p. 432-436.

WAMBSGANSS, M. W.; JENDRZEJCZYK, J. A.; FRANCE, D. M. (1994). Determination and characteristcs of the transition to two-phase slug flow in small horizontal channels. *Journal of Fluids Engineering*, v.116, p.140-146, Mar.

WANG, M. J.; LU, Z. Q.; FENG, J. K. (1991). Statistical identification of flow pattern and the transition for horizontal two-phase flow. 5th International