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

Paulo Roberto Barbosa

**CONTROLE DIFUSO EM TRANSPORTADORES PNEUMÁTICOS
DE SÓLIDOS – REDUÇÃO DO CONSUMO DE POTÊNCIA**

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.

Orientador: Prof. Assoc. Paulo Seleglim Jr.

São Carlos
-2005-

*À Graziela e
Aos meus pais Geralda e Benedito*

AGRADECIMENTOS

À Fundação de Amparo à Pesquisa do Estado de São Paulo – FAPESP pela bolsa concedida.

Ao Professor Associado Paulo Seleglim Junior pelo apoio e orientação.

Aos Técnicos de Laboratório Jorge Nicolau dos Santos, Roberto Prativiera, Hélio Trebi, Roberto Lourenço, Theodomiro Luchesi e Donizeti pela imprescindível colaboração na parte experimental deste projeto.

À Graziela pelo apoio, dedicação, compreensão e companheirismo durante o desenvolvimento deste trabalho.

À Kelen pelas discussões e sugestões em vários momentos e principalmente pela contribuição na parte de redes neurais auto-organizáveis.

Ao Professor Doutor Flávio D. Marques do Departamento de Engenharia de Materiais, Aeronáutica e Automobilística da EESC e ao Professor Doutor Carlos D. Maciel do Departamento de Engenharia Elétrica da EESC pelas sugestões e contribuições.

Aos amigos do Núcleo de Engenharia Térmica e Fluidos (NETeF – EESC – USP) Bruno, Cecília, Christian, Érica, Fabiana, Gisleine, Grazieli, Gustavo, Ivonete, José Antonio, Juliana, Karina, Keyll, Luben, Paula, Renato, Rodrigo, Teodora, Vanessa e Viviane.

Aos amigos de São Carlos André, Andréa, Beth, Eliz, Geraldo, Heráclito, Luciana, Luciane, Melina e Paulo Marcos pela convivência durante a elaboração deste trabalho.

A todos os funcionários e professores da EESC – USP.

SUMÁRIO

LISTA DE FIGURAS	ii
LISTA DE TABELAS	v
RESUMO	vi
ABSTRACT	vii
1 – INTRODUÇÃO	1
2 – REVISÃO BIBLIOGRÁFICA	4
2.1 – Transporte pneumático de sólidos	4
2.2 – Redes neurais artificiais	9
2.3 – Controladores difusos	12
2.5 – Regimes de escoamentos multifásicos	14
3 – METODOLOGIA	16
3.1 – Escoamentos gás-sólido	16
3.2 – Descrição do circuito experimental do NETeF – EESC – USP	18
3.3 – Aquisição de dados	20
3.4 – Redes neurais e controle neural	21
3.4.1 – Arquitetura das redes neurais	22
3.4.2 – Redes neurais recorrentes	26
3.4.3 – Aprendizado em redes neurais	28
3.4.4 - Estruturas dos controladores neurais	34
3.5 – Mapas auto-organizáveis	36
3.6 – Exemplo de aplicação de uma rede neural auto-organizável	40
3.7 – Modelo neural para detecção dos regimes	42
3.8 – Controle Difuso	43
3.8.1 - Modelos lingüísticos	47
3.8.2 - Modelo de Mamdani	49
3.8.3 - Modelo Takagi-Sugeno-Kang	51
3.8.4 - Estrutura dos controladores difusos	52
3.9 – Descrição do controlador difuso	56
4 – TESTES EXPERIMENTAIS E RESULTADOS	65
4.1 – Testes realizados e resultados da identificação de regimes	65
4.2 – Economia de energia	69
4.3 – Controlador difuso	70
5 – CONCLUSÕES E PERPECTIVAS	78
5.1 – Propostas de trabalhos futuros	79
5.1.1 - Otimização dos parâmetros do controlador difuso	79
5.1.2 - Implementação de um controlador neural	79
REFERÊNCIAS BIBLIOGRÁFICAS	81
APÊNDICE A – Simulação numérica do injetor de sólidos	92
APÊNDICE B – Válvula rotativa	99

LISTA DE FIGURAS

Figura 01: Primeiro sistema de transporte pneumático documentado (DINGLERS* 1847 apud MOLERUS,1996).....	5
Figura 02: Equipamento para dosar o carvão pulverizado (DINGLERS* 1869 apud MOLERUS,1996)	5
Figura 03: Disposição dos maçaricos na fornalha desenvolvida por Crampton (DINGLERS* 1871 apud MOLERUS,1996)	6
Figura 04: Válvula rotativa (DINGLERS* 1879 apud MOLERUS,1996)	7
Figura 05: Transporte pneumático de grãos para silos (DINGLERS* 1878 apud MOLERUS,1996)	8
Figura 06: Representação esquemática da evolução dos regimes de escoamento quando variando progressivamente a velocidade da fase transportadora (Adaptado de SAVAGE et al., 1996)	17
Figura 07: Fotos mostrando o conjunto e detalhes do transportador pneumático do NETeF	18
Figura 08: Representação esquemática do circuito de transporte pneumático experimental do NETeF – EESC – USP.	19
Figura 09: Instrumentação para medida e aquisição de dados.....	19
Figura 10: Painel frontal do programa de aquisição de dados.....	20
Figura 11: Diagrama de blocos do programa de aquisição de dados	21
Figura 12: Modelo básico do neurônio	23
Figura 13: Exemplos de função de ativação: (a) e (b) Degrau (c) Sigmoidal.....	24
Figura 14: Rede neural <i>feed-forward</i> de uma camada	25
Figura 15: Rede neural <i>feed-forward</i> de três camadas	26
Figura 16: Rede de uma camada com realimentação (a) Esquema de conexões (b) Diagrama de blocos	27
Figura 17: Rede multicamadas em sistemas dinâmicos.....	27
Figura 18: (a) Aprendizado supervisionado (b) Aprendizado não supervisionado	28
Figura 19: Ilustração da regra de aprendizado	28
Figura 20: Estrutura com modelo de referência.....	34
Figura 21: Estrutura de controle com modelo interno	35
Figura 22: Estrutura de controle com modelo preditivo	36
Figura 23: Grade bidimensional de neurônios	38
Figura 24: Mapa auto-organizável	39

Figura 25: Exemplo dos vetores: entradas e pesos antes do treinamento da rede.....	41
Figura 26: Comparação entre entradas e pesos do exemplo dos vetores.....	41
Figura 27: Conjuntos clássicos e conjuntos difusos (MARQUES, 2000)	44
Figura 28: Função de associação para um conjunto clássico A.	44
Figura 29: Funções de associação para um conjunto difuso A.	45
Figura 30: Função de associação clássica para o exemplo da febre.....	46
Figura 31: Função de associação difusa para o exemplo da febre.	46
Figura 32: Representação gráfica do método de inferência Max-min (MARQUES, 2000)	49
Figura 33: Representação gráfica do método de inferência Max-produto (MARQUES, 2000)	50
Figura 34: Estrutura interna de um controlador difuso.....	52
Figura 35: Estrutura de controle difusa de malha fechada	53
Figura 36: Estrutura de um controlador difuso-PI	54
Figura 37: Estrutura de um controlador difuso com PID subjacente.....	55
Figura 38: Controlador difuso para adaptação de parâmetros PID	55
Figura 39: Controlador difuso para correção da saída de um PID	56
Figura 40: Painel frontal da versão final do programa.	57
Figura 41: Funções de associação da variável P _{mont}	58
Figura 42: Funções de associação da variável Sensor 2.....	59
Figura 43: Funções de associação da variável Sensor 3.	59
Figura 44: Funções de associação da variável Sensor 4.	60
Figura 45: Funções de associação da variável Comando.	60
Figura 46: Comportamento das variáveis de entrada do controlador com o aumento da vazão de ar e $Q_{sol} = 0,0739$ kg/s.	62
Figura 47: Comportamento das variáveis de entrada do controlador com a diminuição da vazão de ar e $Q_{sol} = 0,0739$ kg/s.	63
Figura 48: Superfície de decisão com as variáveis Sensor2, P _{mont} e Comando.	63
Figura 49: Superfície de decisão com as variáveis Sensor3, P _{mont} e Comando.	64
Figura 50: Superfície de decisão com as variáveis Sensor4, P _{mont} e Comando.	64
Figura 51: Fotos dos regimes de escoamento.....	65
Figura 52: Teste com o controlador ($Q_{ar-inicial} = 0.017$ kg/s , $Q_{ar-final} = 0.015$ kg/s e $Q_{sol} = 0.0739$ kg/s).....	71
Figura 53: Teste com o controlador ($Q_{ar-inicial} = 0.013$ kg/s, $Q_{ar-final} = 0.016$ kg/s e $Q_{sol} = 0.1228$ kg/s).....	71
Figura 54: Teste com o controlador ($Q_{ar-inicial} = 0.014$ Kg/s , $Q_{ar-final} = 0.014$ kg/s e $Q_{sol} = 0.1437$ kg/s).....	72
Figura 55: Teste com o controlador ($Q_{ar-inicial} = 0.016$ kg/s, $Q_{ar-final} = 0.015$ kg/s e $Q_{sol} = 0.0739$ kg/s).....	72
Figura 56: Teste com o controlador ($Q_{ar-inicial} = 0.018$ kg/s, $Q_{ar-final} = 0.015$ kg/s e $Q_{sol} = 0.1395$ kg/s).....	73
Figura 57: Diagrama de estado com indicação dos tipos de ensaios realizados.	74
Figura 58: Ensaio do Tipo 1 ($Q_{sol} = 0.0739$ kg/s)	74

Figura 59: Ensaio do Tipo 1 ($Q_{sol} = 0.1395$ kg/s)	75
Figura 60: Ensaio do Tipo 1 ($Q_{sol} = 0.1437$ kg/s)	76
Figura 61: Ensaio do Tipo 2.....	76
Figura 62: Arquitetura interna do controlador neural proposto.	80
Figura 63: Geometria da conexão simulada	93
Figura 64: Detalhes da malha utilizada na simulação	94
Figura 65: Distribuição de pressão para o caso 1.....	94
Figura 66: Distribuição de pressão para o caso 2.	95
Figura 67: Distribuição de pressão para o caso 3.....	96
Figura 68: Distribuição de pressão para o caso 4.....	96
Figura 69: Distribuição de pressão para o caso 5.....	97
Figura 70: Distribuição de pressão para o caso 6.	97
Figura 71: Distribuição de pressão para o caso 7.	98
Figura 72: Válvula rotativa	100
Figura 73: Vista explodida da válvula rotativa.....	101
Figura 74: Válvula rotativa instalada no circuito.....	101

LISTA DE TABELAS

Tabela 01: Classificação da rede neural para o exemplo dos vetores.....	40
Tabela 02: Resultados do treinamento da rede neural auto-organizável.....	66
Tabela 03: Resultados da simulação 01.	67
Tabela 04: Resultados da simulação 02.	67
Tabela 05: Resultados da simulação 03.	67
Tabela 06: Classificação da rede neural para diferentes vazões mássicas.....	68
Tabela 07: Potência (em kW) consumida no transporte.....	70
Tabela 08: Potência (kW) consumida com controlador difuso.	77
Tabela 09: Configurações simuladas do injetor de sólidos.	94

RESUMO

Barbosa, P.R. (2005). Controle difuso em transportadores pneumáticos de sólidos – redução do consumo de potência. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2005.

O transporte pneumático de sólidos constitui uma aplicação comum em processos industriais petroquímicos, de mineração, de alimentos e agrícola. Entretanto, devido a limitações de ordem prática, a maioria das aplicações existente envolve o transporte de 1 a 400 toneladas por hora, através de distâncias de até 1000m. Entre estas limitações, o consumo de potência provavelmente é a mais severa. Um sistema de transporte seguro e que apresente uma redução no consumo de potência pode ser implementado com técnicas não convencionais de controle. Este trabalho descreve a implementação de um controlador difuso em um circuito experimental de 45 mm de diâmetro interno utilizado para transportar sementes de *Setaria Itálica* ao longo de 21 metros. Informações obtidas com um estudo prévio de identificação de regimes gás-sólido através de redes neurais auto-organizáveis foram utilizadas no projeto do controlador. Os resultados mostraram uma redução significativa de 41%, em média, no consumo de potência requerida para o transporte de uma mesma carga de sólido.

Palavras-chave: Controle difuso, redes neurais auto-organizáveis, transporte pneumático, regimes de escoamento.

ABSTRACT

Barbosa, P.R. (2005). Improving the power consumption in pneumatic conveying systems by fuzzy control strategy. Ph.D. Thesis - Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos, 2005.

The pneumatic conveying of solids in a gas stream is a recurrent process in petrochemical industries as well as in agricultural, food and mining. However, due to practical limitations the majority of existing systems have capacities ranging from 1 to 400 tones per hour over distances less than 1000 m, mainly because of a high power consumption per transported unit mass. A safe circuit with reduced power consumption can be designed using non-conventional control techniques. This work describes a fuzzy controller implementation for a 45mm i.d. pneumatic conveying system used to transport *Setaria Italica* seeds over a distance of 21 m. Data obtained in a previous study about gas-solid flow regime identification through a self-organizing neural network were used in the controller design. The results show that reduction in power consumption can reach 41 % when compared with classical non controller transport.

Keywords: Fuzzy control, self-organizing neural networks, pneumatic conveying, flow regime.

1 – INTRODUÇÃO

O transporte pneumático de sólidos constitui uma aplicação recorrente em processos industriais petroquímicos, de mineração, de alimentos e agrícola. O espectro de materiais que podem ser transportados é bastante amplo, incluindo pós, partículas e grãos, além de elementos mecânicos e componentes eletrônicos. Entretanto, devido a limitações de ordem prática, a maioria das aplicações existente envolve o transporte de 1 a 400 toneladas por hora, através de distâncias de até 1000m e tamanho médio do particulado inferior a 100 mm. Molerus (1996) discute essas características apontando as principais vantagens e desvantagens do transporte pneumático de sólidos:

Vantagens

- 1- Transporte livre de poeira de uma variedade de produtos.
- 2- Flexibilidade de roteamento, ou seja, o transporte pode ser feito de forma horizontal ou vertical pela inserção de um cotovelo.
- 3- Distribuição para áreas diferentes na fábrica e alimentação por diversas áreas.

Desvantagens

- 1- Alto consumo específico de potência.
- 2- Abrasão e desgaste do equipamento.
- 3- O projeto incorreto pode resultar na degradação das partículas.

Podem, ainda, ser acrescentados às vantagens deste tipo de transporte o baixo custo inicial do equipamento, a baixa despesa com manutenção e trabalho humano, a facilidade de automação e controle, a possibilidade de utilização da mesma tubulação para vários produtos e a segurança que permite o transporte de produtos de alto valor.

Dentre as desvantagens, o consumo específico de potência, ou demanda como é conhecido no jargão, provavelmente é a mais severa, principalmente no cenário atual de racionamento energético. De fato, para evitar a formação de estruturas densas como dunas e pistões, as quais, dependendo da disponibilidade de pressão da fase transportadora, podem causar surtos violentos ou bloqueio da linha, prefere-se

operar o sistema em regimes de escoamento homogêneo disperso. Para sustentar esse regime de transporte são necessárias altas velocidades cujas consequências em termos do aumento da perda permanente de pressão resultam num aumento substancial da potência requerida.

No entanto, as vantagens de versatilidade e flexibilidade fazem deste tipo de transporte a primeira escolha para uma grande variedade de material particulado. Marcus et al. (1990) apresentam uma lista de 300 produtos diferentes que têm sido transportados com sucesso, indo desde pós e pedras de mais de 50 mm até partes de produtos manufaturados.

Um sistema de transporte pneumático aperfeiçoado pode ser concebido com auxílio de técnicas de controle. Neste contexto, velocidades baixas de transporte são permitidas se a formação de agregados que precedem a transição para a fase densa for automaticamente detectada e destruída estabilizando, portanto, o regime de escoamento homogêneo em fase dispersa. Em outras palavras, o sistema de controle deve buscar a menor velocidade necessária para diminuir a potência consumida durante a operação, e ao mesmo tempo, suficiente para evitar os fenômenos de instabilidade do escoamento que podem se originar de acumulações significativas de partículas no fundo da tubulação. Conseqüentemente, respeitando estas condições, obtemos um escoamento estável e contínuo enquanto a energia gasta é reduzida.

Na literatura são encontrados vários parâmetros que caracterizam a velocidade mínima de transporte tais como velocidade de salto, velocidade de arraste, velocidade de suspensão, velocidade de deposição, velocidade crítica etc, como destacam Herbeteau e Bouard (2000). Todas estas definições são baseadas na observação visual ou em medidas como, por exemplo, perda de pressão, e todas têm valores numéricos semelhantes. No entanto, elas caracterizam mudança no tipo de escoamento que passa de uma fase instável para uma estável e vice-versa.

Na prática, estes valores variam dependendo da granulometria do particulado, diâmetro e geometria da tubulação etc, e informações como, por exemplo, quantos e quais são os regimes são desconhecidas.

Neste contexto, a identificação dos regimes de escoamento gás-sólido que ocorrem durante o transporte do material particulado é de extrema importância, pois produz informações suficientes para elaboração de técnicas de controle capazes de economizar energia e possibilitar uma operação segura.

Os objetivos deste trabalho são, portanto, a identificação de regimes gás-sólido e a implementação de uma estratégia de controle não convencional em um sistema de transporte pneumático de sólidos, visando essencialmente, segurança e redução do consumo de potência.

Mais especificamente, a identificação de regimes através de redes neurais auto-organizáveis e a implementação de um sistema de controle difuso são propostas em um circuito experimental de 45 mm de diâmetro interno, utilizado para transportar sementes de *Setaria Itálica*.

As contribuições deste trabalho de pesquisa são o estudo dos regimes de escoamento deste material particulado e a implementação de uma estratégia de controle difusa bastante simplificada tendo como entradas apenas valores de pressão estática tomados ao longo da linha de transporte.

O texto foi organizado com os capítulos de revisão bibliográfica, metodologia, testes experimentais e conclusões. O capítulo de conclusões apresenta ainda algumas propostas de trabalhos futuros. Duas contribuições importantes para o projeto do circuito são apresentadas nos apêndices: simulação numérica do injetor e válvula rotativa.

2 – REVISÃO BIBLIOGRÁFICA

Este capítulo apresenta a revisão bibliográfica dos temas envolvidos neste trabalho. A revisão foi dividida da seguinte forma: transporte pneumático de sólidos, redes neurais artificiais, controladores difusos e regimes de escoamentos multifásicos.

2.1 – Transporte pneumático de sólidos

O transporte pneumático de sólidos é uma dentre as inúmeras inovações que caracterizam a indústria no século XIX. Molerus (1996) cita uma investigação exaustiva realizada pelo “Dinglers Polytechnisches Journal” que revela os seguintes fatos:

O primeiro sistema de transporte pneumático documentado foi atribuído a Peugeot em Valentigney na França. Este sistema, que possuía um projeto extremamente simples, era utilizado desde 1847 para exaustão de poeira de quatorze moedores. O sistema pode ser visualizado na Figura 01.

Contrastando com este primeiro projeto, o segundo sistema documentado, patente britânica de Crampton, “Improvements in grinding, preparing and burning coal”, datada de 13 de agosto de 1868, revela um projeto surpreendentemente avançado.

Vários processos metalúrgicos de produção de aço requerem alta temperatura em fornalhas projetadas apropriadamente e o gás era naquela época, assim como nos dias atuais, a forma de combustível mais adequada. O sistema de Crampton foi projetado para evitar a, então necessariamente indireta, rota da gaseificação do carvão. Altas temperaturas requerem combustão quase estequiométrica e, conseqüentemente, a ventilação de carvão pulverizado com massa dosada precisamente para o local da queima na fornalha.

Figura 01: Primeiro sistema de transporte pneumático documentado (DINGLERS* 1847 apud MOLERUS,1996).

Muitos anos depois este tipo de equipamento pode parecer estranho, mas este não foi todo o caso em 1868. O princípio operacional adotado era o mesmo de um projeto de bastante sucesso que naquele tempo já vinha sendo utilizado há 70 anos: o descaroçador de algodão utilizado para a liberação das fibras do algodão.

Figura 02: Equipamento para dosar o carvão pulverizado (DINGLERS* 1869 apud MOLERUS,1996)

* DINGLERS POLYTECH. J., 407 (1847) apud MOLERUS, O. (1996) Overview: Pneumatic transport of solids. *Powder Technology*, v. 88, p. 309-321.

* DINGLERS POLYTECH. J., 293 (1869) apud MOLERUS, O. (1996) Overview: Pneumatic transport of solids. *Powder Technology*, v. 88, p. 309-321.

Fornalhas que operam de acordo com a invenção de Crampton têm sido utilizadas com sucesso. Esta experiência com peculiaridades do transporte pneumático é evidenciada por um segundo relato a respeito de seu sistema (DINGLERS* 1871 apud MOLERUS,1996).

Crampton utilizou uma série de tubos dispostos em paralelo (Figura 03). O relato afirma que a vantagem desta disposição é que, com um único tubo seria necessária uma certa extensão de seu comprimento após o cotovelo, para dispersar novamente as partículas comprimidas pela curva. Ao invés disso foi mantido o menor comprimento possível para criar uma intensa interferência da alta velocidade do gás dos tubos inferiores com uma baixa velocidade das partículas dos tubos superiores de forma que uma boa mistura gás/partícula fosse estabelecida.

Figura 03: Disposição dos maçaricos na fornalha desenvolvida por Crampton (DINGLERS* 1871 apud MOLERUS,1996)

Estes detalhes sobre esta patente foram mencionados neste breve histórico para mostrar que já naquela época tinha sido alcançado um padrão relativamente elevado de engenharia no projeto de sistemas de transporte pneumático. Entretanto esta excursão histórica demonstra o risco de qualquer patente: seu destino não é definido pela excelência das idéias utilizadas, mas sim pela situação econômica e tecnológica. O gás como combustível era disponível a partir de diferentes processos diretos e indiretos de gaseificação do carvão, de maneira que não havia necessidade real para uma então avançada técnica.

* DINGLERS POLYTECH. J., 359 (1871) apud MOLERUS, O. (1996) Overview: Pneumatic transport of solids. *Powder Technology*, v. 88, p. 309-321.

Equipamentos auxiliares, como os utilizados até hoje, foram inventados no final do século XIX. Como exemplo pode ser citada a válvula rotativa mostrada na Figura 04 e patenteada em 1877.

Figura 04: Válvula rotativa (DINGLERS* 1879 apud MOLERUS,1996)

Na definição de transporte pneumático está presente a característica de transporte limpo que leva o particulado do ponto A para o ponto B, então a primeira linha que transportou pneumaticamente grãos para silos (Figura 05) data de 1878 e está documentada também no “Dinglers Polytechnisches Journal”.

Recentemente, contribuições importantes para o transporte pneumático de sólidos têm sido publicadas. Por exemplo, Yan e Byrne (1997) investigaram a deposição do particulado e sua influência na medição da velocidade e concentração de sólidos. Rautiainen et al. (1999) apresentaram um estudo experimental do transporte pneumático em linhas verticais. Wypych (1999) analisou os fatores que contribuem para um transporte com grande capacidade e de longa distância. Reppenhagen et al. (2000) investigaram a escolha adequada do tamanho do ciclone. Pan (1999) faz um estudo sobre a influência das propriedades dos materiais no regime do escoamento. Por fim, Lech (2001) desenvolveu um modelo teórico baseado na velocidade do particulado e queda de pressão para medir a vazão mássica de sólido.

Especificamente sobre os efeitos das curvas e cotovelos em linhas de transporte pneumático, o trabalho de Levy e Mason (1998) apresenta um modelo numérico em secções transversais da tubulação resolvendo equações de volume finito para conservação de massa e quantidade de movimento e o de Kalman (2000) analisa

* DINGLERS POLYTECH. J., 52 (1879) apud MOLERUS, O. (1996) Overview: Pneumatic transport of solids. *Powder Technology*, v. 88, p. 309-321.

o atrito do particulado em várias curvas durante o processo de transporte. Uma investigação numérica e experimental sobre este tópico foi realizada por Schallert e Levy (2000) e Yilmaz e Levy (2001) que apresentam uma abordagem de dinâmica dos fluidos computacional (CFD) baseada no método de Lagrange (Lagrangian particle-source-in-cell).

Figura 05: Transporte pneumático de grãos para silos (DINGLERS* 1878 apud MOLERUS,1996)

Sobre o monitoramento ou análise de características de escoamentos gás-sólido podem ser citados os trabalhos de Ostrowski et al. (1997) e Jaworski e Dyakowski (2001) que utilizaram técnicas de tomografia por capacitância elétrica (ECT).

Mais especificamente sobre controle de sistemas de transporte pneumático, Neuffer et al. (1999) sugerem a utilização da ECT associada à técnica de lógica difusa com a função de associação otimizada através de algoritmos genéticos.

* DINGLERS POLYTECH. J., 132 (1878) apud MOLERUS, O. (1996) Overview: Pneumatic transport of solids. *Powder Technology*, v. 88, p. 309-321.

2.2 – Redes neurais artificiais

Redes neurais artificiais é um outro assunto importante a ser destacado nesta revisão. Trata-se de algoritmos computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos vivos. Aleksander e Morton* (1990 apud HAYKIN, 1994) definem, de forma mais específica, uma rede neural como um processador paralelo distribuído que tem a capacidade natural de armazenar conhecimento através de experiência e de fazê-lo disponível para o uso. São semelhantes ao cérebro em dois aspectos: o conhecimento é adquirido através de um processo de aprendizado e pesos sinápticos são utilizados para armazenar o conhecimento.

Ramón y Cajál introduziu, em 1911, a idéia dos neurônios como constituintes da estrutura cerebral (HAYKIN, 1994) e em 1943 foi dado o primeiro passo acerca das redes neurais artificiais quando Warren McCulloch, um neurofisiologista, e Walter Pitts, um jovem matemático, escreveram artigos sugerindo a construção de uma máquina baseada no cérebro humano. Estes pesquisadores mostraram que estas redes poderiam, em princípio, calcular qualquer função aritmética ou lógica.

O livro de Wiener chamado “Cybernetics” foi publicado em 1948 e trazia conceitos importantes de controle, comunicações e processamento estatístico de sinais.

Com o avanço dos computadores nos anos 50, foi possível começar a modelar os rudimentos das teorias desenvolvidas sobre o pensamento humano. A primeira aplicação prática veio em 1950 com a proposição da rede *perceptron* associada à regra de aprendizado de Frank Rosenblatt, que construiu e demonstrou a habilidade deste tipo de rede no reconhecimento de padrões. Ao mesmo tempo, Bernard Widrow e Tedd Hoff desenvolveram um algoritmo de aprendizado similar ao *perceptron* de Rosenblatt na estrutura e capacidade, mas que sofriam das mesmas limitações.

Uma série de trabalhos foram feitos até que no final da década de 60 teve início uma retração de praticamente todo o investimento nessa área devido a sérias críticas feitas principalmente por Minsky e Papert, com a alegação de que, além de utilizar somente processos de aproximação empíricos, não realizava algumas operações booleanas. Esta situação durou até o início dos anos 80 quando finalmente o assunto ganhou credibilidade novamente. Dois trabalhos que podem ser destacados, então, são o de Hopfield (1982) que apresentou um sistema computacional neural composto por muitos elementos de processamento interconectados e o de Rumelhart et al. (1986) com o desenvolvimento do algoritmo de “back-propagation”, que na

* ALEKSANDER, I.; MORTON, H. (1990) *An introduction to neural computing*. London, Chapman and hall apud HAYKIN, S. (1994) *Neural networks: a comprehensive foundation*. New Jersey, Prentice hall.

verdade já havia sido utilizado em 1974 na tese de doutorado de Werbos pela Universidade de Harvard. Este algoritmo é visto como uma resposta às críticas feitas por Minsky e Papert nos anos 60 (HAGAN et al., 1996).

Esta área teve um longo caminho desde que McCulloch e Pitts escreveram sobre o assunto em 1943 e, de fato, da interdisciplinaridade entre as neurociências, psicologia, matemática, física e engenharia, surgiu uma nova área que continua crescendo em teoria, projetos e aplicações, como mostram os trabalhos de Alvarez et al. (1999) e Mlanic et al. (1997) sobre o controle de processos químicos e Ramirez-Beltran e Jackson (1999) e Wang et al. (1998), especificamente sobre o controle do PH na obtenção de sal primário e em misturas de ácido acético com hidróxido de sódio, respectivamente. Orille & Sowilam (1999) sobre o controle do torque em motores de indução. Martins e Coelho (2000) propõem a associação de redes neurais a controladores PID em problemas térmicos. Benne et al. (2000) estudaram o processo de evaporação industrial na produção do açúcar. Neuroth et al. (2000) sugere, em um primeiro estágio, a utilização de redes neurais na determinação de parâmetros importantes e, na seqüência, uma estrutura difusa responsável pelo controle de sistemas de transporte de gás e óleo. E ainda, Westenskow (1997), com estudos mais abrangentes sobre a utilização de controle de realimentação na área médica.

Um tipo especial de rede neural que recebeu muita atenção nesta revisão foi a chamada rede neural auto-organizável. O início dos estudos deste tipo de rede aconteceu em 1958 quando Frank Rosenblatt criou um classificador “espontâneo”. Na verdade tratava-se de uma rede com aprendizado não supervisionado baseada na idéia do perceptron, treinada para classificar vetores de entrada em duas classes com mesmo número de elementos.

No final da década de 60 e início da década de 70, Stephen Grossberg desenvolveu várias redes competitivas com bons resultados que utilizavam inibição lateral. Alguns comportamentos interessantes obtidos por estas redes foram diminuição de ruídos, realce do contraste e normalização de vetores (HAGAN et al., 1996).

Em 1973, Christoph Von der Malsburg introduziu uma regra de aprendizado auto-organizável que permitia a classificação das entradas baseada na forma das respostas que neurônios vizinhos produziam para entradas similares. A topologia destas redes imitava a estrutura previamente encontrada por David Hubel e Torton Wiesel no córtex de gatos. Apesar de um grande interesse inicial, esta regra não utilizava cálculos locais para assegurar que os pesos estavam normalizados, o que a tornava biologicamente pouco plausível.

Grossberg (1976) estendeu o trabalho de von der Malsburg, redescobrimo a “Regra Instar” (regra introduzida por Nils Nilsson no livro *Learning Machines* de 1965). Grossberg mostrou que esta regra dispensava a necessidade de re-normalização dos pesos, já que, vetores pesos que aprendem a reconhecer vetores de entrada normalizados serão automaticamente normalizados.

Os trabalhos de Grossberg e von de Malsburg enfatizam a coerência biológica de seus modelos. Outro influente pesquisador, Tuevo Kohonen (KOHONEN, 2001), propõe fortemente o uso de redes competitivas. No entanto, a ênfase de seu trabalho está nas aplicações de engenharia e na descrição matemática das redes. Durante os anos 70, Kohonen desenvolveu uma versão simplificada da Regra Instar e inspirado nos trabalhos de Grossberg e Malsburg encontrou uma forma eficiente de incorporar topologia a uma rede competitiva.

Atualmente vários artigos têm sido publicados apresentando resultados interessantes destas técnicas nas mais diversas linhas de pesquisa, como por exemplo, os trabalhos de Yang et al. (1999) sobre a utilização de mapas auto-organizáveis na classificação de tipos de madeira; Greaves e Gasteiger (2001) sobre a utilização de redes neurais auto-organizáveis como ferramenta auxiliar no desenvolvimento de tinturas; Dutta et al. (2003) sobre análise de cinco tipos de chá de diferentes qualidades com 100% de classificação correta e Gabor (1998) que aplicou modelos auto-organizáveis na área médica como alternativa de grande sensibilidade para métodos clássicos como eletroencefalograma.

Outras aplicações de modelos neurais auto-organizáveis incluem ainda os trabalhos de Zulkifli e Meeran (1999) sobre a decomposição de características com interação em sistema de identificação; Serrano-Cinca (1996) descreveu um sistema de apoio à decisão para a área financeira; Mbshou et al. (2003) utilizaram redes auto-organizáveis aliadas a técnicas de fluorescência na detecção da qualidade de maçãs armazenadas em três condições diferentes e obtiveram resultados promissores quando comparado com perceptron multicamada e análise de discriminante quadrático; Reibnegger e Wachter (1996) demonstraram que técnicas não supervisionadas podem produzir resultados interessantes e significativos na análise da composição química do leite reproduzindo resultados obtidos com técnicas convencionais com redução da dimensão do conjunto de dados e melhorando a compreensão de características ocultas na matriz de dados; Zhang et al. (1996) empregaram redes neurais auto-organizáveis em um sistema de monitoramento de máquinas automatizado, que a partir de um conjunto de dados multidimensional produzia como saída, as condições operacionais dos equipamentos; Kowalski e Orlowska-Kowalska (2003) sobre o diagnóstico de defeitos em motores de indução;

Polanski (2003) mostrou que este tipo de rede neural pode ser uma ferramenta muito útil em estratégias de mapeamento de fármacos descobrindo aspectos de similaridade molecular facilmente negligenciados por profissionais da área; Granger et al. (1998) com aplicações no tratamento de pulsos de radar em equipamentos de guerra, analisando três aspectos: qualidade, tempo de convergência e complexidade computacional; Moshou e Ramon (2003) sobre controle de vibração de um equipamento muito utilizado para aplicação de pesticidas na agricultura; Ig et al. (1997) sugerem conceitos de aprendizado híbrido baseado em redes neurais auto-organizáveis para controle adaptativo de robôs.

Na área de imagens, Sukhaswami e Pujari (1996) propõem um método para restaurar geometricamente imagens com defeitos ou aberrações e Banarse et al. (2000) investigaram a utilização destes modelos neurais em problemas de classificação de imagens e reconhecimento de caligrafias.

Foram ainda investigados modelos com arquitetura paralela visando aplicações em tempo real como Mailachalam e Srikanthan (2002) com aplicações em processamento de vídeo e Srivastava et al. (2003) que estimaram o grau de insegurança em sistemas de gestão de energia.

O grande número de artigos publicados recentemente comprova a importância destas técnicas em aplicações industriais nas mais diversas áreas.

2.3 – Controladores difusos

Um outro tópico de destaque nesta revisão são os controladores difusos. Lofti Zadeh sugeriu a lógica difusa para controle pela primeira vez em 1972 (WARWICK et al., 1992). Experimentalmente, este tipo de controlador tem produzido resultados positivos como o sistema de operação automática de trens aplicado ao sistema do metrô de Sendai no Japão pela Hitachi (LEE, 1990). Muitos avanços têm ocorrido, desde 1974, quando as primeiras aplicações significativas de controladores difusos foram publicadas por E. H. Mamdani e seus alunos no Queen Mary College (MAMDANI, 1974 e MAMDANI et al., 1976). Atualmente existem vários conceitos teóricos e práticos muito importantes. Ao aspecto prático se referem tanto o uso experimental quanto industrial no controle de processos.

Dois períodos podem ser considerados: no primeiro se concentram experimentos em escala laboratorial e o desenvolvimento de protótipos com raras instalações industriais. No segundo, que se iniciou no final dos anos 80, um vasto

número de aplicações comerciais é observado, em particular foram projetados vários produtos eletrônicos domésticos como aspiradores de pó, lavadoras, geladeiras, câmeras fotográficas etc. Subseqüentemente, uma série de aplicações industriais começou a ser divulgada (PEDRYCZ, 1993).

O trabalho de Tong et al. (1980) discute o controle difuso no processo de tratamento biológico de água e esgoto. Este tipo de controle é complexo pelos seguintes motivos: (i) falta de instrumentação adequada, (ii) pouco entendimento do comportamento biológico e (iii) dificuldade de identificação de um modelo do processo. Os resultados com este controlador foram promissores. Estudos de simulação mostraram claramente uma performance adequada. Outro exemplo é o controle da purificação de água (YAGISHITO et al., 1985).

Pappis e Mamdani (1977) discutiram o uso de controladores difusos para o controle do tráfego em uma intersecção simples de duas ruas, com resultados melhores do que os obtidos com as técnicas convencionais, anteriormente empregadas.

Experimentos sobre o processo de aquecimento de água foram executados por van Nauta Lemke e Kickert (1976). O principal objetivo destes experimentos era o controle da temperatura da água na saída de um tanque, sujeito à existência de ruídos, assimetrias em torno do valor desejado e não linearidades. A comparação com um controlador PI ajustado adequadamente mostrou que o controle difuso possuía uma resposta mais rápida e com a mesma precisão. Uma versão simplificada deste mesmo controlador (número de variáveis reduzido) produziu uma resposta ainda mais rápida, porém com grandes oscilações em torno do valor desejado.

Um piloto automático para navios, projetado com o auxílio de conjuntos difusos foi desenvolvido e testado com sucesso em um modelo de simulação (van AMERONGEN et al., 1977).

Este tipo de controlador tem sido empregado também na área de fluidos, mais relacionada ao presente trabalho, como mostram as publicações de Franzen e Pluschkell (1994) sobre a aplicação de conjuntos difusos no reconhecimento de padrões de escoamentos, Annunziato e Pizzuti (1999) discutem sobre a utilização de regras difusas na fusão de modelos fluidodinâmicos e neurais para monitoração de escoamentos multifásicos e Neuroth (2000) discute a utilização de controladores difusos em escoamentos gás-óleo.

2.5 – Regimes de escoamentos multifásicos

Um fluido multifásico pode escoar segundo diversas organizações topológicas chamadas regimes de escoamento ou configurações de escoamento. As duas fases de uma mistura gás-líquido, por exemplo, podem escoar horizontalmente de forma dispersa (regimes a bolhas ou gotas pulverizadas) ou segregada (regimes anular ou estratificado).

O desenvolvimento de técnicas de instrumentação específicas para escoamentos multifásicos teve um grande impulso a partir de meados dos anos 70, quando Estados Unidos, França e Japão passaram a investir maciçamente na geração termonuclear de energia.

Num contexto mais amplo, as técnicas de análise de sinais representam um recurso imprescindível na instrumentação de escoamentos multifásicos, tendo em vista a grande complexibilidade de seus mecanismos básicos. Um dos primeiros trabalhos nesta linha é o de Hubbard e Dukler (1966) sobre a caracterização de diversos regimes de escoamento com base na análise espectral de sinais de pressão. Também podem ser citados os trabalhos de Vince e Lahey (1982), Matsui (1984), Mishima e Ishii (1984), Sekoguchi et al. (1987), Barnea et al. (1980) entre outros.

Especificamente em leitos fluidizados, Letzel et al. (1997) estudaram a caracterização de regimes através da análise de séries temporais caóticas; Li e Kuipers (2002) com estudo computacional sobre a influência da pressão na transição de regimes; Monazam e Shadle (2004) desenvolveram um método transiente para caracterização; Bi et al. (2000) apresentam uma revisão sobre regime de fluidização gás-sólido; Zijerveld et al. (1998) realizaram estudos experimentais com silicone granulado; Chen et al. (1995) identificaram regimes trifásicos (gás-líquido-sólido) em diferentes condições e Kwak e Li (1996) e Bai et al. (1996) conduziram estudos mais abrangentes sobre regimes de fluidização em sistemas gás-sólido.

A respeito da utilização de técnicas de tomografia para visualização ou identificação dos regimes, Lehner e Wirth (1999) utilizaram um sistema de tomografia computadorizada (raio-x) para obter a fração volumétrica de sólido em um reator gás sólido; Ostrowski et al. (2000) aplicaram técnicas de tomografia por capacitância elétrica na tubulação horizontal de um transportador pneumático e Xu e Xu (1997) identificaram regimes de escoamento gás-líquido através de tomografia por ultra-som.

Recentemente, outros trabalhos têm sido publicados como, por exemplo, Bi e Grace (1996) estudaram transições de regimes através de analogias entre escoamentos gás-líquido vertical e transporte vertical gás-sólido; Geyen et al. (1999)

utilizaram simulação numérica para reproduzir e analisar três regimes de escoamento encontrados experimentalmente em tubos verticais; Mblodtsof (2003) faz uma análise teórica de regimes de escoamento gás-sólido vertical com diferentes diâmetros e densidades do material particulado; Wu et al. (2001) desenvolveram um sistema de identificação de regimes de escoamento trifásico óleo-gás-água em tubos horizontais através de um modelo neural e Barbosa e Seleglim Jr (2003) propuseram uma estratégia também neural, baseada na identificação de regimes gás-sólido e controle, para reduzir o consumo de energia em transportadores pneumáticos de sólidos.

Sobre escoamentos gás-líquido em tubulações horizontais, Crivelaro et al. (2002) aplicaram um modelo neural para processar os sinais de uma sonda de visualização direta e diagnosticar o regime e Klein et al. (2004) investigaram a existência de sub-regimes através da análise tempo-freqüência de escoamentos intermitentes.

3 – METODOLOGIA

Este capítulo apresenta as principais técnicas e métodos utilizados neste trabalho. Na primeira seção são discutidos os regimes de escoamentos gás-sólido que ocorrem nos transportadores pneumáticos de sólidos de forma a apresentar a fenomenologia deste tipo de escoamento. Na sequência são apresentados o circuito experimental e a instrumentação incluindo o sistema e o programa para aquisição de dados.

O capítulo traz ainda uma discussão sobre redes neurais e controle neural, redes neurais auto-organizáveis utilizadas para a identificação, as estratégias de controle baseadas em lógica difusa e a descrição da implementação do controlador difuso.

3.1 – Escoamentos gás-sólido

A dificuldade de operar uma linha de transporte pneumático em velocidades de transição de regime de escoamento deriva do comportamento peculiar apresentado por este tipo de aplicação (histerese). Isso pode ser melhor compreendido com a realização de um experimento numa linha horizontal em que a velocidade da fase transportadora é variada lentamente de zero até um determinado valor máximo, acima do qual o regime disperso é plenamente desenvolvido e permanente. Os diferentes estágios deste experimento são indicados no gráfico da Figura 06, no qual U_p denota a velocidade das partículas e U_g a velocidade da fase gasosa transportadora.

No estágio indicado por (a), U_g não é suficientemente alta de forma que $U_p = 0$ até que um determinado valor crítico $U_g = U_1$ seja alcançado, quando as forças turbulentas se igualam às forças de atrito e ao peso próprio das partículas.

Após esse ponto, no estágio indicado por (b), $U_g > U_1$, as partículas são capturadas pelo escoamento gasoso central e o regime disperso se estabelece

assintoticamente, ou seja, $U_p \rightarrow U_g$. Diminuindo U_g a partir de um dado valor máximo, estágio indicado por (c), e dependendo da granulometria do particulado, diferentes regimes de escoamento podem se estabelecer, dentre os quais os mais comuns são os regimes estratificado, intermitente e a dunas, até que outro valor crítico $U_g = U_2$ seja alcançado.

Figura 06: Representação esquemática da evolução dos regimes de escoamento quando variando progressivamente a velocidade da fase transportadora (Adaptado de SAVAGE et al., 1996)

Nesse ponto, as forças de sustentação se igualam ao peso próprio das partículas, algumas delas sedimentam formando um leito fixo na parte inferior do tubo, e outras começam a quicar e a rolar a uma velocidade $U_p = U_3$. Operar a linha de transporte pneumático na zona de transição significa fixar $U_2 < U_g < U_1$ e administrar um comportamento fortemente histerético em U_p , assim como na perda de carga e outros parâmetros macroscópicos relevantes. Portanto, uma operação segura nestas condições requer estratégias de controle especiais o que, de fato, é uma das metas principais deste trabalho.

3.2 – Descrição do circuito experimental do NETeF – EESC – USP

Os testes foram realizados no circuito experimental (CNPq/PADCT 62.0012/99-4, CNPq/PRONEX 466.107/2001-3, FAPESP 98/12921-1 e FAPESP 03/13819-6) do Núcleo de Engenharia Térmica e Fluidos da Escola de Engenharia de São Carlos da Universidade de São Paulo (Figura 07). A linha de transporte desenhada esquematicamente na Figura 08 possui uma seção de testes transparente de 45 mm de diâmetro interno, com 12 m de comprimento na horizontal e 9 m na vertical.

(a) vista geral

(b) detalhe da seção horizontal

Figura 07: Fotos mostrando o conjunto e detalhes do transportador pneumático do NETeF

A alimentação de ar é assegurada por um compressor Worthington de 60cv (1) capaz de imprimir velocidades de até cerca de 40 m/s na tubulação de transporte. O controle da vazão de ar é feito com auxílio de uma servo-válvula (2), dotada de comando elétrico (4-20 mA) e atuador pneumático. A vazão de ar é determinada por uma placa de orifício (3), instrumentada com transmissores para a medida da temperatura e das pressões diferencial e absoluta. A introdução do particulado na seção de testes é feita através de um venturi (4) alimentado por uma válvula helicoidal (5) ligada a um silo de armazenagem (10). A vazão de sólido é determinada pela rotação do motor de acionamento da válvula helicoidal, controlada por um pequeno inversor de frequência (6). Na saída da seção de testes, um ciclone (7) é responsável pela separação do particulado e do ar, retornando o particulado para um reservatório de coleta (8) (operação em batch) ou para o silo de armazenagem através de uma válvula rotativa (9) (operação contínua).

Figura 08: Representação esquemática do circuito de transporte pneumático experimental do NETeF – EESC – USP.

Além dos transmissores de pressão, construídos a partir de sensores Motorola do tipo MPX e de conversores tensão/corrente Burr-Brown XTR106* (Figura 09a), o circuito é provido de um sistema de aquisição de sinais da National Instruments (Figura 09b) constituído por um chassi PXI – 1000B, módulo de aquisição Multifunction I/O 6025E e módulo processador PXI 8170, que garante a comunicação com o computador.

(a) medidor de pressão

(b) sistema de aquisição

Figura 09: Instrumentação para medida e aquisição de dados.

* O tempo de resposta dos sensores e dos conversores é, respectivamente, de 1ms e 40 μ s.

3.3 – Aquisição de dados

Para a aquisição e armazenamento dos dados foi implementado um programa no software LabVIEW®. No total foram utilizados 13 canais correspondentes a 13 sensores de pressão, sendo que 2 sensores (localizados antes da seção de alimentação) além de contribuírem como dados de entrada para rede neural foram também utilizados nos cálculos das vazões de ar de acordo com normas técnicas específicas (ASME MFC,1989). Estes dois sensores correspondem aos valores de pressão diferencial na placa de orifício, devidamente instalada para o cálculo da vazão, e pressão a montante.

Já no caso do controlador foram utilizados como dados de entrada os valores da pressão a montante e de 3 sensores localizados na parte horizontal do circuito. Maiores detalhes das implementações da rede neural e do controlador serão apresentados nas seções 3.7 e 3.9, respectivamente.

Os dados adquiridos pelo programa são mostrados em um gráfico (Figura 10) e armazenados em um arquivo do tipo texto. As vazões de sólido e ar nos testes foram definidas através deste programa, fixando respectivamente valores para o inversor de frequência e para a servo-válvula.

Figura 10: Painel frontal do programa de aquisição de dados.

A Figura 11 mostra também o diagrama de blocos do programa, no qual podem ser identificadas estruturas dos tipos: *while* que finaliza a operação quando o botão stop é pressionado, *for* responsável pela aplicação de um filtro passa-baixa em 50 Hz e pela sub-amostragem dos dados e *case* que funciona como botão de emergência.

Figura 11: Diagrama de blocos do programa de aquisição de dados

O filtro e a sub-amostragem foram utilizados, nesta ordem, para eliminar uma fonte de ruído em 60 Hz e o efeito “aliasing” causado por ruído em altas frequências identificado por testes realizados previamente com a transformada de Fourier do sinal. Desta forma as aquisições por segundo mostradas na figura 10 com o valor 20.000 devem ser divididas por 200 (sub-amostragem) resultando na frequência de aquisição de 100 Hz utilizada neste trabalho.

3.4 – Redes neurais e controle neural

Atualmente as redes neurais são consideradas um tópico muito importante na área de sistemas de controle. Estas técnicas, propostas inicialmente pelas ciências neural e de informação como resultados de estudos sobre mecanismos e estruturas do cérebro, têm propiciado o desenvolvimento de novos modelos computacionais para resolução de problemas complexos.

Para proporcionar uma avaliação racional de novos métodos é essencial comparar tecnologias emergentes com técnicas convencionais bem estabelecidas. Sendo assim, com referência as redes neurais aplicadas ao controle e identificação, as seguintes características são importantes (MOSCINSKI e OGONOWSKI, 1995):

- As redes neurais são de grande importância na área de controle não linear. Isto se deve a habilidade teórica em aproximar aplicações não lineares arbitrárias, além de apresentar uma modelagem mais simples do que os esquemas de aproximação convencionais, baseados em polinômios, por exemplo.

- As redes neurais possuem uma estrutura totalmente paralela o que naturalmente sugere programação paralela. Este tipo de implementação quando comparado com esquemas convencionais apresenta maior grau de tolerância a erros e maior velocidade computacional. Além disso, a unidade de processamento elementar (neurônio) possui uma estrutura muito simples, o que também resulta em um aumento na velocidade de processamento.

- Um número considerável de fabricantes tem produzido “hardwares” dedicados com implementação VLSI “Very Large-Scale Integration”, o que traz velocidade adicional e aumenta a escala de redes que podem ser implementadas.

- A respeito de aprendizagem e adaptação, as redes podem ser treinadas com dados do sistema a ser estudado, gravados previamente. Uma rede treinada adequadamente possui a habilidade de generalizar quando exposta a dados diferentes dos utilizados no treinamento. É possível, ainda, adaptar a rede on-line.

- Fusão de dados. As redes neurais podem operar simultaneamente sobre dados quantitativos (numéricos) e qualitativos (simbólicos). Neste aspecto, os modelos neurais são posicionados num cenário intermediário entre sistemas de engenharia tradicional e técnicas de processamento como inteligência artificial.

- As redes neurais processam naturalmente vários impulsos e produzem várias saídas, o que as torna aplicáveis a sistemas multivariáveis.

Do ponto de vista dos sistemas de controle a habilidade das redes neurais em lidar com sistemas não lineares é talvez a mais significativa. Métodos baseados em redes neurais possuem um valor imenso no projeto de controladores adaptativos não lineares requerendo pouco conhecimento da dinâmica do sistema. Os algoritmos de aprendizagem podem ser utilizados diretamente como estratégias de controle.

3.4.1 – Arquitetura das redes neurais

A arquitetura da rede é definida pela forma como os elementos básicos de processamento de dados são interconectados. A unidade básica de processamento de

uma arquitetura conexionista é freqüentemente chamada de neurônio devido à analogia com a neurofisiologia, mas outros nomes como perceptron ou adaline também são utilizados (MOSCINSKI e OGONOWSKI, 1995). Um modelo básico de neurônio é ilustrado a seguir na Figura 12:

Figura 12: Modelo básico do neurônio

O neurônio é composto por três partes:

- 1 - Uma soma ponderada, i.e, pesos multiplicados pelas entradas.
- 2 - Um sistema dinâmico linear (SISO – “Single Input – Single Output”).
- 3 - Uma função não linear, chamada função de ativação.

A soma ponderada s_i é descrita por

$$s_i(t) = \sum_{j=1}^{N_i} w_{ij} x_j(t) + \sum_{k=1}^{M_i} b_{ik} u_k(t) + z_i \quad (1)$$

Ou seja, em termos das entradas internas x_i , entrada externas (controle) u_k e correspondentes pesos w_{ij} e b_{ik} , juntamente com constantes z_i que fazem o papel das tradicionais *bias*. A variável t que representa o tempo que pode ser discreto ou contínuo.

A equação (1) pode ser escrita na forma de matriz como

$$s_i(t) = W_i x(t) + B_i u(t) + z_i \quad (2)$$

O sistema dinâmico linear possui entrada v_i e saída y_i . A variável y_i é a saída do i -ésimo neurônio. Este modelo matemático pode ser escrito como

$$T_i y_i(t) + y_i(t) = v_i(t) \quad (3)$$

ou de uma forma mais genérica como

$$a_0 y_i(t) + a_1 y_i(t) = v_i(t) \quad (4)$$

O modelo discretizado no tempo pode ser representado por

$$T_i y_i(t+1) + (1 - T_i) y_i(t) = v_i(t) \quad (5)$$

A função de ativação f_i (não linear) produz o sinal v_i em termos do somatório s_i :

$$v_i = f_i(s_i) \quad (6)$$

Existem diferentes funções de ativação e a escolha depende do problema considerado. No caso de reconhecimento de padrões, por exemplo, a função degrau é a mais utilizada (Figura 13a e 13b), enquanto que no projeto de sistemas de controle ou identificação a função sigmoidal (Figura 13c) parece ser mais popular.

Figura 13: Exemplos de função de ativação: (a) e (b) Degrau (c) Sigmoidal

Se nas equações (3 e 5) $T_i = 0$ para todos os neurônios, então a rede é chamada de estática. Neste caso, os N neurônios estáticos em paralelo alimentados pelo vetor $x = (x_1, \dots, x_L)^T$ e produzindo o vetor de saída $y = (y_1, \dots, y_N)$ constituem uma rede de uma camada “feed-forward” ilustrada na Figura 14.

Figura 14: Rede neural *feed-forward* de uma camada

Esta rede de uma camada implementa um mapeamento estático não linear relacionando a entrada x a saída y :

$$y = F(Wx) \quad (7)$$

onde

$$W = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1L} \\ \vdots & \vdots & \ddots & \vdots \\ w_{N1} & w_{N2} & \cdots & w_{NL} \end{bmatrix} \quad (8)$$

e

$$F = \text{diag} (f_1(s_1), \dots, f_N(s_N)).$$

Conseqüentemente, a rede juntamente com as entradas de controle pode ser descrita como dois mapeamentos (um linear e outro não-linear):

$$y = F(Wx + Bu + z) \quad (9)$$

Conectando três camadas na seqüência obtemos uma rede de três camadas *feed-forward* ilustrada na Figura 15. A primeira camada, composta por três neurônios, é chamada de camada de entrada. A saída da camada de entrada $y^1 = (y_1, y_2, y_3)^T$ é a entrada da próxima camada (camada intermediária), composta por dois neurônios. A terceira camada (camada de saída) é alimentada pelo vetor $y^2 = (y_4, y_5)^T$ e produz o vetor de saída da rede $y^3 = (y_6, y_7, y_8)^T$.

Figura 15: Rede neural *feed-forward* de três camadas

A rede neural implementa um mapeamento não linear relacionando as entradas x e a saída y^3 , da seguinte forma composta:

$$y^3 = [F^3 [W^3 F^2 [W^2 F^1 [W^1 x]]]] \quad (10)$$

sendo F^1 , F^2 e F^3 matrizes das funções de ativação e W^1 , W^2 e W^3 matrizes de pesos.

3.4.2 – Redes neurais recorrentes

As redes neurais recorrentes, baseadas no trabalho de Hopfield (1982), têm sido muito utilizadas em problemas de otimização e endereçamento de informações em memória. Uma versão da rede de Hopfield com atraso é mostrada na Figura 16. A entrada de controle neste caso é considerada nula. Claramente, a rede representa um sistema dinâmico discreto no tempo com o vetor de estado x .

Figura 16: Rede de uma camada com realimentação (a) Esquema de conexões
(b) Diagrama de blocos

A escolha dos pesos determina os estados de equilíbrio deste sistema dinâmico não linear e assim, o equilíbrio específico para o qual a trajetória de estado converge depende das condições iniciais $x_1(0), \dots, x_N(0)$.

Evidentemente, obtém-se a seguinte relação:

$$y(t+1) = F(W(t))(y(t)) \quad (11)$$

Finalmente, uma rede neural multicamadas representando um sistema dinâmico não linear é desenhada esquematicamente na Figura 17.

Figura 17: Rede multicamadas em sistemas dinâmicos

3.4.3 – Aprendizado em redes neurais

A formulação clássica dada pela teoria das aproximações é expressa como:

Dada uma função multivariável contínua $h(x)$ a ser aproximada por outra função $H(x,w)$, sendo w o vetor de parâmetros. Seja $\{x\}$ um conjunto de exemplo para treinamento de x . Encontrar w^* tal que

$$r [H(x,w^*),h(x)] \leq r [H(x,w),h(x)] \quad (12)$$

para $x \in \{x\}$ e p representando uma função distância.

Tipicamente, p é a soma dos quadrados das diferenças. O processo de atualização dos pesos de forma a minimizar p obtendo o melhor valor w^* para o parâmetro w é chamado de aprendizagem. A aprendizagem ou processo de aprendizado pode ser supervisionado ou não supervisionado e estas estruturas estão representadas na Figura 18.

Figura 18: (a) Aprendizado supervisionado (b) Aprendizado não supervisionado

Uma regra de aprendizagem geral, baseada no trabalho de Amari (1990) é formulada a seguir (Figura 19):

Figura 19: Ilustração da regra de aprendizado

O vetor peso w_i aumenta na proporção do produto da entrada x pelo sinal de aprendizagem r_i . O sinal r_i é, em geral, uma função de w_i , x e as vezes de d (valor desejado ou de referência). Então

$$r_i = r_i(w_i, x_i, d_i) \quad (13)$$

O incremento do vetor peso é produzido por

$$\Delta w_i(t) = g r_i[w_i(t), x(t), d(t)] x(t) \quad (14)$$

onde g é um número positivo chamado de constante de aprendizado e determina a taxa de aprendizado.

O vetor peso adotado no tempo t se torna no instante seguinte em

$$w_i(t+1) = w_i(t) + g r_i[w_i(t), x(t), d(t)] x(t) \quad (15)$$

A convenção do sobrescrito é utilizada para indexar os passos de treinamento discretos no tempo como mostra a equação abaixo. Para o k -ésimo passo temos

$$w_i^{k+1} = w_i^k + g r_i(w_i^k, x^k, d_i^k) x^k \quad k = 1, 2, \dots \quad (16)$$

O aprendizado contínuo no tempo pode ser expresso como

$$\frac{dw_i(t)}{dt} = g r_i[w_i(t), x(t), d(t)] x(t) \quad (17)$$

Existem várias regras de aprendizado e as mais utilizadas são apresentadas a seguir:

Regra de Hebb

$$r_i = f(w_i^T x) = f_i(s_i) \quad (18)$$

e

$$\Delta w_i = g f_i(s_i) x \quad (19)$$

Assim os pesos w_{ij} são adaptados através de

$$\Delta w_{ij} = g f_i(s_i) x_j \quad (20)$$

Este aprendizado requer a inicialização dos pesos com valores pequenos, i.e, próximos de zero. A regra de Hebb (1949) representa um aprendizado puramente não-supervisionado *feed-forward*. Esta regra estabelece que se o produto da saída e entrada, ou termo de correlação $f_i(s_i) x_j$, é positivo, os pesos devem ser aumentados, caso contrário os pesos devem ser reduzidos.

Regra Perceptron

O sinal de aprendizagem na regra perceptron é a diferença entre o valor desejado e a resposta atual do neurônio. Assim, o aprendizado é supervisionado e:

$$r_i = d_i - y_i \quad (21)$$

A função degrau (Figura 13b) é utilizada e, então,

$$y_i = \text{degrau}(s_i) = \text{degrau}(w_i^T x) \quad (22)$$

As correções dos pesos neste método são obtidas por

$$\Delta w_i = g[d_i - \text{degrau}(s_i)] x \quad (23)$$

ou

$$\Delta w_{ij} = g[d_i - \text{degrau}(w_i^T x)] x_j \quad \text{para } j = 1, \dots, L \quad (24)$$

Como a resposta do neurônio é binária, a equação anterior se reduz a:

$$\Delta w_i = \pm 2 g x \quad (25)$$

na qual o sinal + ocorre se $d_i = 1$ e $\text{degrau}(w_i^T x) = -1$

Regra Delta

A regra de aprendizagem delta pode ser aplicada somente de forma supervisionada e se a função de ativação for diferenciável. O sinal de aprendizagem para esta regra é chamado de “delta” e definido como

$$r_i = [d_i - f_i(w_i^T x)] f'_i(w_i^T x) \quad (26)$$

Esta regra pode ser facilmente derivada da condição do mínimo erro ao quadrado entre y_i e d_i . Calculando o vetor gradiente com respeito a w_i temos

$$E = \frac{1}{2} (d_i - y_i)^2 \quad (27)$$

que é uma expressão equivalente a

$$E = \frac{1}{2} [d_i - f_i(w_i^T x)]^2 \quad (28)$$

e o vetor gradiente de erro é obtido por

$$\nabla E = -(d_i - y_i) f'_i(w_i^T x) x \quad (29)$$

Uma vez que a minimização do erro requer que as mudanças nos pesos ocorram na direção contrária ao gradiente, obtemos:

$$\Delta w_i = -\eta \nabla E \quad (30)$$

onde η é uma constante positiva. Assim, substituindo eq.(29) na eq.(30) encontramos:

$$\Delta w_i = \eta (d_i - y_i) f'(s_i) x \quad (31)$$

Regra Widrow-Hoff

Esta regra de aprendizado supervisionado independe da função de ativação dos neurônios desde que o erro quadrático entre o valor desejado d_i e o valor de ativação s_i seja minimizado.

O sinal de aprendizagem para esta regra é dado por

$$r = d_i - s_i = d_i - w_i^T x \quad (32)$$

Assim, o incremento do vetor peso nesta regra é igual a:

$$\Delta w_i = g(d_i - s_i) x \quad (33)$$

Esta regra pode ser considerada um caso especial da regra delta se a função de ativação for igual a função identidade, i.e., $f_i(s_i) = s_i$.

A velocidade de convergência e a convergência propriamente dita de uma regra de aprendizagem dependem da constante γ . Uma versão adaptativa da função de ativação identidade foi proposta (WIDROW e LEHR, 1990) para tornar o algoritmo de aprendizagem mais confiável e eficiente. Nesta versão a constante γ é corrigida de acordo com

$$g(x) = \begin{cases} \frac{x}{x^T x}, & \text{se } x^T x \neq 0 \\ 0 & \text{se } x^T x = 0 \end{cases} \quad (34)$$

e o incremento do peso correspondente é

$$\Delta w_i = \begin{cases} \alpha g(x)(d_i - y_i), & \text{se } x^T x \neq 0 \\ 0, & \text{outros} \end{cases} \quad (35)$$

onde α é um fator de redução constante.

Se assumirmos que $x \neq 0$ temos que $x^T x \neq 0$. A dinâmica do erro dos neurônios cujos pesos são ajustados pela regra acima (que agora passa a ser a regra delta) pode ser obtida com a eq.(34):

$$E_i^{k+1} = d_i^{k+1} - y_i^{k+1} \quad (36)$$

e

$$E_i^{k+1} - E_i^k = y_i^k - y_i^{k+1} = - \left[(w^{k+1})^T - (w^k)^T \right] x = - \left(\frac{a E_i^k x^T}{x^T x} \right) x = -a E_i^k$$

ou seja,

$$E_i^{k+1} = (1 - a) E_i^k \quad (37)$$

De acordo com a equação anterior o erro E_i^k converge para 0 a uma taxa de $(1-a)$ se, e somente se, $0 < a < 2$.

Uma generalização da regra acima de forma a incluir os casos de funções de ativação não-diferenciáveis foi proposta por Sira-Ramirez e Zak (1991). A regra é descrita como:

$$w_i^{k+1} = \begin{cases} w_i^k + \frac{a E_i^k q(x)}{x^T q(x)} & \text{se } x^T q(x) \neq 0 \\ w_i^k & \text{outros} \end{cases} \quad (38)$$

onde $0 < a < 2$.

A regra generalizada se torna a anterior quando o gerador q é igual a identidade, i.e., $q(x) = x$.

Sendo f a função degrau ("hard limiter") temos que:

$$q(x) = \begin{bmatrix} f(x_1) \\ \vdots \\ f(x_L) \end{bmatrix}$$

a adaptação do algoritmo permite que sejam consideradas funções de associação não lineares e a convergência é garantida.

Aplicações deste algoritmo no controle adaptativo de sistemas lineares desconhecidos são discutidas em Kuschewski et al. (1993).

Regra delta para redes multicamadas *feed-forward* e algoritmo *back-propagation*

Esta seção focaliza o algoritmo de treinamento aplicado a redes neurais multicamadas *feed-forward*. Este algoritmo é conhecido como *back-propagation* ou algoritmo de treinamento de retro-propagação do erro.

De maneira similar ao caso simples da regra delta apresentado anteriormente, padrões de entrada são submetidos sequencialmente durante o processo de treinamento. O erro pode ser expresso como:

$$E = \frac{1}{2} \sum_{m=1}^P \left(d^m - y(x^m, w) \right)^T \left(d^m - y(x^m, w) \right) \quad (39)$$

onde d^m denota a saída desejada correspondente a entrada x^m , P denota o número de padrões de treinamento (d^m, x^m) (número de exemplos) e $y(x^m, w)$ denota o vetor de saída da rede correspondente a entrada x^m e a matriz peso w . A regra delta opera, então, como um algoritmo de aproximação estocástico. No entanto, para simplificação, será considerado neste texto $P=1$ e o caso determinístico.

Durante a fase de classificação ou associação, a rede opera na direção da entrada para a saída. Para demonstrar o algoritmo de *back-propagation*, um exemplo ilustrado na Figura 10 será considerado. O erro pode, então, ser escrito como:

$$E = \frac{1}{2} \left[(d_6 - y_6)^2 + (d_7 - y_7)^2 + (d_8 - y_8)^2 \right] \quad (40)$$

onde d_6 , d_7 e d_8 denotam as saídas desejadas da rede, respectivamente para as entradas x_1 , x_2 e x_3 . O algoritmo para ajustar os pesos $W = \{w_{ij}\}$ de forma a minimizar $E(W)$ é dado através do método da inclinação máxima por:

$$w_{ij}^{k+1} = w_{ij}^k - g \frac{\partial E(w_{ij}^k)}{\partial w_{ij}}, \quad g > 0 \quad (41)$$

E a fórmula geral para ajuste dos pesos é dada por:

$$w_{ij}^{k+1} = w_{ij}^k + g \delta_i y_j \quad (42)$$

onde δ_i representa um erro equivalente associado ao neurônio i . Por exemplo, para neurônios da camada de saída como o neurônio 8 (referente a saída y_8) tem-se:

$$\delta_8(x) = (d_8 - y_8(x)) f'_8(s_8(x)) \quad (43)$$

E para os neurônios da camada intermediária, como por exemplo o de número 4, tem-se:

$$\delta_4 = \left((d_6 - y_6) f'_6(s_6) w_{64} + (d_7 - y_7) f'_7(s_7) w_{74} + (d_8 - y_8) f'_8(s_8) w_{84} \right) f'_4(s_4) \quad (44)$$

Observe que a regra para o ajuste dos pesos da camada intermediária tem a mesma estrutura da regra para camada de saída. Entretanto o erro equivalente é descrito por uma fórmula mais extensa. O procedimento tem início na camada de

saída e o erro é propagado no sentido contrário a alimentação ao longo de toda estrutura da rede.

O algoritmo de back-propagation é uma das mais conhecidas formas de ajuste de pesos em redes neurais e tem sido utilizado em diferentes versões não somente em redes estáticas como apresentado anteriormente, mas também em redes chamadas de dinâmicas ou com atraso no tempo (MOSCINSKI e OGONOWSKI, 1995).

3.4.4 - Estruturas dos controladores neurais

Modelos de sistemas dinâmicos e seus inversos têm utilidade imediata no controle. Na literatura especializada existe um número considerável de estruturas bem estabelecidas e analisadas profundamente no controle não linear. Na seqüência são apresentadas descrições de estruturas de controle mais representativas.

Uma estrutura muito conhecida é chamada de controle com modelo de referência (*Model reference control*). Neste caso, o desempenho desejado do sistema em malha fechada é especificada por um modelo estável de referência M , definida pelo par entrada-saída $\{r(t), y^r(t)\}$. O sistema de controle faz a saída da planta $y^p(t)$ convergir assintoticamente para a saída do modelo de referência, i.e., $\lim_{t \rightarrow \infty} \|y^r(t) - y^p(t)\| \leq e$, para alguma constante $e \geq 0$ especificada. A estrutura de um controle com modelo de referência para um sistema não linear, utilizando um modelo conexionista, é ilustrada na Figura 20. Nesta estrutura o erro definido anteriormente é utilizado para treinar a rede que age como um controlador. Esta abordagem é vista também como um treinamento de um modelo inverso da planta. No entanto, o modelo como um todo é considerado um controle adaptativo direto.

Figura 20: Estrutura com modelo de referência

Outra estrutura é chamada de controle com modelo interno IMC (Internal model control) na qual são enfatizadas as direções diretas e inversas do modelo. Esta estrutura traz mais realidade para o controle de sistemas não lineares e tem sido completamente analisada com relação à estabilidade e robustez.

Neste caso, um modelo do sistema é colocado em paralelo com o sistema real. A diferença entre as saídas do modelo e do sistema é utilizada como realimentação. Este sinal de realimentação é processado, então, por um sub-sistema de controle na direção direta e as propriedades do IMC sugerem que esta parte do controlador deve estar relacionada com o sistema inverso. O modelo do sistema M e o controlador C (modelo inverso) são construídos com redes neurais (Figura 21). O sub-sistema F é tipicamente um filtro linear projetado para fornecer robustez ao sistema em malha fechada. Deve, ainda, ser ressaltado que a aplicabilidade deste modelo está limitada a sistemas estáveis em malha aberta.

Figura 21: Estrutura de controle com modelo interno

Nas áreas de controle preditivo e ótimo, as redes neurais têm sido introduzidas como uma lei de realimentação natural e computacionalmente adequada. Tem sido, ainda, demonstrado que este método possui propriedades de estabilidade muito desejadas para sistemas não lineares.

Nesta abordagem um modelo neural fornece uma previsão da resposta da planta sobre uma determinada situação. As previsões fornecidas pela rede passam por uma rotina de otimização numérica de forma a minimizar o critério de performance especificado no cálculo de um sinal de controle adequado.

Geralmente, o sinal de controle $\tilde{u}$ é escolhido para minimizar o critério de desempenho quadrático que pode ser visto como um compromisso entre o erro e o custo do controle.

$$J = \sum_{j=N_1}^{N_2} \left(y^r(t+j) - y^m(t+j) \right)^2 + \sum_{j=N_1}^{N_2} I_j \left(\tilde{u}(t+j-1) - \tilde{u}(t+j-2) \right)^2 \quad (45)$$

sendo N_1 e N_2 constantes que definem o intervalo operacional considerado. Os valores de I são os pesos de controle.

A solução ótima u é aplicada à planta assim que encontrada pelo algoritmo de otimização. O valor atual da saída da planta y^p é medido e enviado juntamente com o sinal de referência r para outra rede neural C . Esta rede é um controlador treinado para produzir a mesma saída da rotina de otimização. Como resultado, uma lei de controle não linear com realimentação é obtida. Uma representação desta estrutura é mostrada na Figura 22.

Figura 22: Estrutura de controle com modelo preditivo

Estruturas mais específicas e com equacionamento em espaço de estado tem sido propostas, como o controlador com auto-aprendizado (NGUYEN e WIDROW, 1990) e o controle adaptativo não linear com auto-sintonia (CHEN, 1990).

3.5 – Mapas auto-organizáveis

Os mapas auto-organizáveis são uma classe especial de redes neurais artificiais baseadas na aprendizagem competitiva (não supervisionada). Neste tipo de aprendizagem, os neurônios de saída da rede competem entre si para serem ativados ou não, sendo que apenas um neurônio (ou apenas um por grupo) é ativado a cada vez que uma entrada é apresentada. O neurônio de saída que vence a competição é chamado de neurônio vencedor (winning neuron ou winning-takes-all). Uma forma de induzir este tipo de competição entre os neurônios de saída é o uso de respostas

negativas (lateral inhibitory connections), idéia originalmente proposta por Rosenblatt em 1958.

Um mapa ou sistema auto-organizável pode ser interpretado informalmente como uma aplicação não linear, ordenada e suave de dados com alta dimensionalidade nos elementos de um espaço vetorial ordenado de dimensão pequena.

Em um mapa auto-organizável, os neurônios são dispostos em uma grade, usualmente unidimensional ou bidimensional. Mapas com dimensões superiores também são possíveis, mas não são comuns. No decorrer do processo de aprendizagem competitiva, os neurônios se tornam sintonizados de acordo com os vários padrões de entrada (ou classes de padrões de entrada) (KOHONEN, 2001). Na medida em que um mapa auto-organizável projeta sobre uma grade a informação contida nos dados primários, sem alterar significativamente suas relações topológicas, ele pode ser entendido como uma ferramenta de abstração.

Um mapa auto-organizável é ainda caracterizado pela formação de um mapa topográfico dos padrões de entrada no qual as localizações espaciais (as coordenadas) dos neurônios na grade são indicativos de características estatísticas intrínsecas contidas nos padrões de entrada.

O desenvolvimento de mapas auto-organizáveis como um modelo neural é motivado por uma característica do cérebro humano: o cérebro é organizado em vários setores de forma que entradas sensoriais diferentes são representadas por mapas computacionais topologicamente organizados. Em particular, entradas sensoriais como, por exemplo, o tato, visão e audição são mapeadas em diferentes áreas do córtex cerebral de maneira topologicamente organizada (HAYKIN, 1999).

O principal objetivo de um mapa auto-organizável ou rede neural auto-organizável é transformar um padrão de sinal de entrada de dimensão arbitrária em uma mapa discreto uni ou bidimensional e realizar esta transformação adaptativamente em uma forma organizada topologicamente.

Figura 23: Grade bidimensional de neurônios

A Figura 23 mostra um diagrama esquemático de uma grade de neurônios bidimensional freqüentemente utilizada como mapa discreto.

Cada neurônio na grade é completamente conectado aos nós de alimentação da camada de entrada. Esta rede representa uma estrutura feedforward com uma camada computacional simples constituída por neurônios dispostos em linhas e colunas. Uma grade unidimensional é um caso especial da situação descrita anteriormente constituída apenas por uma linha ou coluna de neurônios.

A posição física dos neurônios é definida de acordo com uma função de topologia que gera, por exemplo, uma grade (ou malha) retangular, hexagonal ou randômica. O procedimento para identificar o neurônio vencedor é semelhante ao utilizado em camadas competitivas. No entanto, ao invés de atualizar apenas o neurônio vencedor i , todos os neurônios dentro de uma certa vizinhança $N_v(d)$ são atualizados com a utilização da chamada regra de Kohonen. Especificamente, todo neurônio $i \in N_v(d)$ é ajustado por,

$${}_i w(q) = {}_i w(q-1) + \alpha(p(q) - {}_i w(q-1)) \quad (46)$$

ou

$${}_i w(q) = (1 - \alpha) {}_i w(q-1) + \alpha p(q) \quad (47)$$

A vizinhança $N_v(d)$ contém todos os índices dos neurônios que estão dentro do raio d , ou seja,

$$N_v(d) = \{j, d_{ij} \leq d\} \quad (48)$$

Dessa forma, toda vez que um vetor p é apresentado à rede, o neurônio com o vetor de pesos mais próximo dele vencerá a competição. O vetor de pesos do neurônio vencedor e de seus vizinhos sintonizam-se na direção do vetor de entrada p . Repetindo este processo várias vezes, neurônios vizinhos aprendem quais vetores são similares uns aos outros.

É também possível definir a função distância de diferentes maneiras, por exemplo, escolhendo um agrupamento retangular ou hexagonal dos neurônios e vizinhanças, no entanto o desempenho da rede não é sensível à forma exata das vizinhanças (HAGAN et al., 1996).

Outra possibilidade é a especificação de diferentes topologias para a localização original dos neurônios, as mais comuns são a retangular, hexagonal e randômica.

A arquitetura de um mapa auto-organizável pode também ser representada como indicada na Figura 24.

Figura 24: Mapa auto-organizável

Esta arquitetura é semelhante a uma rede neural competitiva, porém não existe a utilização de “bias”. Na Figura 24, a distância N geralmente é dada por $N = -\|W - P\|$, sendo P o vetor de entrada e W o vetor peso, e C representa a função de transferência competitiva que, como descrito anteriormente, retorna o vetor de saída A com o valor 1 para o neurônio vencedor e 0 para os demais.

3.6 – Exemplo de aplicação de uma rede neural auto-organizável

Para mostrar com maior detalhes e de uma forma simplificada o funcionamento da rede auto-organizável implementada neste trabalho, um exemplo extremamente simples foi apresentado ao modelo. Neste exemplo, o seguinte conjunto de nove vetores foi utilizado como entrada:

$$V_1 = (1 \ 2 \ 1)$$

$$V_2 = (2 \ 1 \ 2)$$

$$V_3 = (2 \ 2 \ 3)$$

$$V_4 = (9 \ 7 \ 10)$$

$$V_5 = (10 \ 8 \ 10)$$

$$V_6 = (10 \ 8 \ 9)$$

$$V_7 = (-3 \ -5 \ 6)$$

$$V_8 = (-3 \ -4 \ 5)$$

$$V_9 = (-4 \ -5 \ 6)$$

Uma malha com quatro neurônios foi definida para mostrar a habilidade da rede em reduzir para três neurônios correspondentes aos três grupos de vetores mostrados anteriormente.

O resultado obtido pela rede neural após o treinamento foi o seguinte:

Tabela 01: Classificação da rede neural para o exemplo dos vetores.

Vetores	Neurônio
V_1, V_2 e V_3	03
V_4, V_5 e V_6	01
V_7, V_8 e V_9	04

A dimensão dos dados deste exemplo permite a visualização do processo de aprendizagem. Na Figura 25 os vetores de entradas foram desenhados como pontos, ou seja, cada eixo do gráfico representa uma coordenada, e são comparados com os pesos dos neurônios antes do treinamento da rede. Nesta etapa os neurônios foram todos inicializados com valores unitários, ou seja, os pesos dos quatro neurônios eram iguais ao vetor (1, 1, 1), o que, inclusive dificulta a visualização na Figura 25.

Figura 25: Exemplo dos vetores: entradas e pesos antes do treinamento da rede.

Após o treinamento, os pesos dos neurônios passaram a ter a distribuição espacial mostrada na Figura 26. É possível constatar que o neurônio 2 foi extinto e praticamente se fundiu com o neurônio 3.

Figura 26: Comparação entre entradas e pesos do exemplo dos vetores.

Na seqüência são apresentados, de forma mais genérica, os passos utilizados para a implementação de uma rede neural auto-organizável.

Denotando os dados de entrada por $P \in \mathfrak{R}^n$ e a rede neural por sua vez definida a partir de modelos nodais ou neurônios, $w_j \in \mathfrak{R}^n$ com $j = 1, 2, \dots, k$, cada qual associado aos dados de entrada segundo um critério de menor distância, denotado por $d(P, w_j)$.

$$P \Leftrightarrow w_j \rightarrow i(P) = \min \{d(P, w_j)\} \quad (49)$$

Como dito anteriormente, o treinamento de uma rede neural auto-organizável corresponde a ajustar seus neurônios de forma que o mapeamento de todos os possíveis dados do vetor de entrada P sobre o conjunto w_j seja ordenado e geometricamente representativo da informação contida nos dados primários. Isso pode ser feito através dos seguintes passos:

1. Os neurônios são estruturados segundo uma malha n -dimensional de projeção e inicializados com pesos pré-determinados ou aleatórios.
2. Cada entrada P_n é associada ao neurônio que mais lhe é semelhante segundo o critério de distância estabelecido.
3. Defini-se uma vizinhança N em torno do neurônio $i(P)$ sobre a malha de projeção.
4. O peso do neurônio vencedor é ajustado segundo uma taxa de aprendizado $\alpha \in (0,1]$ (eq. 46) e seus vizinhos segundo um critério de propagação e, usualmente diminuindo de forma progressiva na medida em que os neurônios vizinhos estão mais distantes do neurônio central $i(P)$. Isto pode ser realizado através da utilização de uma ponderação de ajuste dada pela função gaussiana, por exemplo. Este processo é executado para cada neurônio da malha e suas respectivas vizinhanças.
5. O processo como um todo é iterado, ou mais especificamente os passos de 2) a 4), são repetidos até que nenhuma alteração no mapa seja constatada.

3.7 – Modelo neural para detecção dos regimes

Esta seção descreve alguns detalhes sobre a implementação, realizada no software Matlab®, da rede neural auto-organizável utilizada neste trabalho. A principal vantagem deste tipo de modelo é o aprendizado não supervisionado, ou seja, não existe a necessidade de conhecimento *a priori* (pares entrada/saída). Este aspecto é

de fundamental importância, já que os regimes em situações práticas podem variar dependendo da granulometria do particulado, diâmetro e geometria da tubulação etc, e portanto informações sobre quantos e quais são os regimes não são conhecidas. As posições físicas dos neurônios foram definidas por uma malha hexagonal e as distâncias foram calculadas com uma função euclidiana. O vetor de entrada foi composto por 3900 elementos, e a grade possuía seis neurônios de saída, para testar a habilidade do modelo em reduzir e classificar os quatro regimes avaliados, descritos com detalhes no capítulo 04.

3.8 – Controle Difuso

Antes de descrever os principais aspectos do controle difuso ou fuzzy, é interessante apresentar os fundamentos da lógica envolvida nesta técnica.

A lógica difusa, também chamada por alguns autores de nebulosa, foi proposta originalmente por Lotfi Zadeh em 1965 com o trabalho “Fuzzy Sets” (ZADEH, 1965) e, então, desenvolvida como uma forma de manipulação e processamento de informações vagas em um universo de incertezas. Essa abordagem tem-se desenvolvido para prover algoritmos de processamento suave da informação utilizando dados imprecisos (NAGAMINE, 2001). Uma das principais características desta abordagem é a possibilidade de associação parcial de um elemento a um conjunto, o que permite as transições suaves de uma regra para outra.

A proposta de um modelo difuso é capturar o funcionamento de um sistema com sua construção podendo ser compreendida como um processo no qual uma coleção de objetos chamados de variáveis ou parâmetros do modelo é relacionada a outros objetos chamados de conectivos ou operadores do modelo. O tipo de conectivo utilizado define dois grupos de modelos distintos: modelos matemáticos e modelos lógicos. Nos modelos matemáticos, também conhecidos como clássicos ou “crisp”, são utilizadas as operações aritméticas, enquanto que nos modelos lógicos os conectivos são do tipo lógico booleano, tais como, E, OU e SE-ENTÃO (NAGAMINE, 2001).

As transições entre um membro e um não-membro, nos conjuntos clássicos, são abruptas e bem definidas, já nos conjuntos difusos existe uma transição gradual (YAGER e FILEV, 1994). Esta diferença pode ser visualizada na Figura 27, na qual as únicas possibilidades para um elemento, no caso dos conjuntos clássicos, são pertencer (elemento a) e não pertencer (elemento b) ao conjunto A. Já no caso de um

conjunto difuso, as fronteiras do conjunto são mais amenas, o que permite a idéia de um elemento ser membro parcial do conjunto A.

Figura 27: Conjuntos clássicos e conjuntos difusos (MARQUES, 2000)

Considere-se um universo de discurso* X com um conjunto A contido em X. A função característica associada com A chamada de função de associação é o mapeamento:

$$\mu_A : X \rightarrow \{0,1\} \quad (50)$$

O mapeamento é um conceito importante no relacionamento da teoria de conjuntos às representações por funções da informação. A função acima apresenta, no caso de conjuntos clássicos, a idéia de que qualquer elemento pertencente ao conjunto A recebe o valor 1 e qualquer elemento não pertencente ao conjunto A recebe o valor 0. Ou seja,

Figura 28: Função de associação para um conjunto clássico A.

No caso de um elemento em um universo de discurso que contem conjuntos difusos, a transição entre estes dois valores (0 e 1) é feita de forma gradual. Esta transição possui vários níveis chamados de graus de associações e está de acordo com o fato das fronteiras de conjuntos difusos serem ambíguas e vagas.

Conseqüentemente, a pertinência de um elemento nesse conjunto é definida

* O universo de discurso pode ser definido como o espaço das entradas.

de maneira a refletir esta incerteza e ambigüidade através da extensão do alcance da função característica do par binário $\{0,1\}$ para o intervalo $[0,1]$. A função de associação neste caso é dada, então, por

$$\mu_A : X \rightarrow [0,1] \quad (51)$$

E a função passa a ter outra forma como, por exemplo, as seguintes:

Figura 29: Funções de associação para um conjunto difuso A.

Os conjuntos difusos podem ser utilizados na construção de conjuntos de termos ou de vocábulos, tornando possível o desenvolvimento de uma estratégia lingüística de controle. A noção de conjunto de termos representa uma abstração do valor da variável e é considerada um ponto crucial em muitos sistemas de inteligência artificial (ROSS, 1995).

Um exemplo da naturalidade destas funções de associação é dado pela situação na qual um médico autoriza uma ligação para sua residência caso a criança esteja com uma febre muito alta (acima $38,5^{\circ}\text{C}$). Na prática, o médico seria com certeza avisado caso o termômetro mostrasse $38,0^{\circ}\text{C}$.

De fato não é possível utilizar a lógica convencional (binária) para modelar esta situação adequadamente, já que um paciente com uma temperatura de 38°C não satisfaz o critério para sofrer de febre muito alta. Mesmo que a temperatura seja medida com 5 casas decimais de precisão a situação é a mesma. A alta precisão não altera o fato de que um paciente com temperatura do corpo abaixo de $38,5^{\circ}\text{C}$ não pertence a categoria dos pacientes com febre muito alta.

Figura 30: Função de associação clássica para o exemplo da febre.

Como descrito anteriormente, para modelar fatos incertos como, por exemplo, febre muito alta, ao invés da distinção estrita entre dois valores de associação (1 para verdadeiro e 0 para falso) são permitidos todos os graus de associação intermediários. Esta noção de ser mais ou menos elemento de um conjunto é ilustrada na Figura 31 para este exemplo.

Figura 31: Função de associação difusa para o exemplo da febre.

O gráfico da Figura 31 apresenta para cada valor de temperatura do corpo T um grau de associação ($\mu(T)$) ao conjunto febre muito alta. O grau de associação pode também ser interpretado como grau de verdade, dada a afirmação de que o paciente sofre de febre muito alta. Observe que neste caso uma temperatura de $38,5^{\circ}\text{C}$ é considerada ligeiramente diferente de 38°C e não mais um disparo.

Este processo de produção de funções de associação para cada entrada ou saída do sistema a partir de um dado físico é chamado de *difusificação*. Todos os conjuntos difusos que representam as variáveis exatas (físicas) relacionadas por funções de associação formam a *base de conhecimento*.

A base de conhecimento contém informações imprecisas, porém significativas na modelagem de um sistema. Contudo, essa imprecisão é completamente resolvida, na medida em que os conjuntos de entrada e saída difusos e a estratégia de manipulação do conhecimento são definidos.

Um algoritmo difuso processa as funções de associação de cada um dos conjuntos difusos, e os resultados são combinados através de uma série de instruções ou regras, formando a chamada *base de regras*. Frequentemente, para estabelecer um grau de confiança em que esta base de regras é verdadeira, cada uma das saídas difusas é multiplicada por um fator de escala adequado (NAGAMINE, 2001).

Os modelos de sistemas difusos são divididos basicamente em duas categorias que diferem fundamentalmente na habilidade de representar diferentes tipos de informação, ou seja, na forma de representar a base de regras. A primeira inclui os modelos lingüísticos que são baseados em coleções de regras SE-ENTÃO com vagos predicados e usam raciocínio difuso. Nesse tipo de modelo, quantidades difusas são associadas com rótulos lingüísticos, e um modelo difuso é essencialmente uma expressão qualitativa do sistema. A segunda categoria de modelos é baseada no método de raciocínio de Takagi-Sugeno-Kang. Esses modelos são formados por regras lógicas que têm uma combinação de modelos difusos e exatos (YAGER e FILEV, 1994).

3.8.1 - Modelos lingüísticos

Na manipulação da base de conhecimento, um conjunto de regras de inferência é adotado. O método mais comum para representar o conhecimento humano é através de expressões naturais de linguagem do tipo:

SE (premissa) ENTÃO (conclusão)

Uma coleção de expressões como a anterior é chamada de base de regras da forma SE-ENTÃO. Essa forma supõe que, conhecido um fato (premissa, hipótese ou antecedente) então é possível inferir, ou deduzir, outro fato (conclusão ou conseqüente). Esta forma de representação do conhecimento, caracterizada como conhecimento superficial é bastante apropriada no contexto lingüístico, pois expressa o conhecimento humano empírico e heurístico na sua própria linguagem de comunicação.

Para estabelecer uma relação difusa R entre duas variáveis A e B , baseada nos comandos condicionais SE-ENTÃO existem várias técnicas que fazem uso do comando lógico de implicação, ou seja, $R = A \rightarrow B$. Dentre estes métodos os mais conhecidos são:

1- Clássico (proposto por Zadeh em 1973):

$$\mu_R(x, y) = \max \{ \min [\mu_A(x), \mu_B(y)], 1 - \mu_A(x) \} \quad (52)$$

2- Mínima correlação ou implicação de Mamdani:

$$\mu_R(x, y) = \min [\mu_A(x), \mu_B(y)] \quad (53)$$

3- Implicação de Lukasiewicz:

$$\mu_R(x, y) = \min \{1, [1 - \mu_A(x) + \mu_B(y)]\} \quad (54)$$

4- Implicação de Brouwerian:

$$\mu_R(x, y) = \begin{cases} 1, & \text{para } \mu_A \leq \mu_B \\ \mu_B(y), & \text{outros} \end{cases} \quad (55)$$

5- Implicação R-SEQ (seqüência lógica padrão):

$$\mu_R(x, y) = \begin{cases} 1, & \text{para } \mu_A \leq \mu_B \\ 0, & \text{outros} \end{cases} \quad (56)$$

6- Implicação somas limitadas:

$$\mu_R(x, y) = \min \{1, [\mu_A(x) + \mu_B(y)]\} \quad (57)$$

7- Implicação correlação produto:

$$\mu_R(x, y) = \max \{ \mu_A(x) \cdot \mu_B(y), [1 - \mu_A(x)] \} \quad (58)$$

$$\mu_R(x, y) = \mu_A(x) \cdot \mu_B(y) \quad (59)$$

A maioria dos sistemas envolve mais de uma regra. O processo de obtenção do conseqüente global a partir da contribuição de cada conseqüência individual é conhecido como agregação das regras. As estratégias de agregação definem os sistemas como sendo conjuntivos ou disjuntivos (ROSS, 1995).

Nos sistemas de regras conjuntivos as regras devem ser satisfeitas conjuntamente, i.e., os conectivos “E” são utilizados. Neste caso, a saída agregada (conseqüente) y é encontrada através da intersecção de todas as regras conseqüentes individuais y^i , com $i = 1, \dots, r$ (r número de regras), ou seja:

$$y = y^1 \text{ E } y^2 \text{ E } \dots \text{ E } y^r \quad \text{ou} \quad y = y^1 \cap y^2 \cap \dots \cap y^r \quad (60)$$

que é definida por funções de associação,

$$\mu_y(x) = \min (\mu_{y^1}(x), \dots, \mu_{y^r}(x)) \quad , \quad \text{para } x \in X \quad (61)$$

sendo x a entrada e X o universo de discurso.

Os sistemas de regras disjuntivos requerem que seja satisfeita, no mínimo, uma regra. Neste caso, os conectivos “OU” são utilizados e a saída agregada é obtida através da união das contribuições individuais.

$$y = y^1 \text{ OU } y^2 \text{ OU } \dots \text{ OU } y^r \quad \text{ou} \quad y = y^1 \cup y^2 \cup \dots \cup y^r \quad (62)$$

que é definida por funções de associação,

$$\mu_y(x) = \max(\mu_{y^1}(x), \dots, \mu_{y^r}(x)) , \quad \text{para } x \in X \quad (63)$$

3.8.2 - Modelo de Mamdani

Este modelo, que foi o utilizado neste trabalho, é baseado no método de implicação de Mamdani (eq. 53) para inferência e a saída agregada é dada por:

$$\mu_{B_n^k}(a(i), a(j)) = \max[\min[\mu_{A_{n1}^k}(a(i)), \mu_{A_{n2}^k}(a(j))]], \quad \text{para } k = 1, \dots, r \quad (64)$$

onde A_{n1}^k e A_{n2}^k representam os k-ésimos conjuntos difusos antecedentes e B_n^k representa o k-ésimo conjunto difuso conseqüente para a n-ésima regra com entradas $\alpha(i)$ e $\alpha(j)$. A representação gráfica desta interpretação pode ser visualizada na Figura 32.

Figura 32: Representação gráfica do método de inferência Max-min (MARQUES, 2000)

Uma outra técnica de implicação que também pode ser utilizada é a do max-produto.

$$\mu_{B_n^k}(a(i), a(j)) = \max[\mu_{A_{n1}^k}(a(i)), \mu_{A_{n2}^k}(a(j))], \quad \text{para } k = 1, \dots, r \quad (65)$$

A representação gráfica desta técnica de implicação do max-produto é apresentada na Figura 33.

Regra 1

Regra 2

Figura 33: Representação gráfica do método de inferência Max-produto (MARQUES, 2000)

Na maioria dos sistemas a saída de um processo difuso precisa ser uma quantidade escalar e não conjuntos difusos. Um valor físico da saída de um sistema é, então, obtido através da *dedifusificação* do conjunto de saída difuso. Na literatura existem vários métodos de dedifusificação como, por exemplo:

1 – Princípio da máxima associação, também chamado de método da altura, é baseado nos picos das funções de associação.

2 – Método da média ponderada, válido somente para saídas com funções de associação simétricas.

3 – Média da associação máxima, muito semelhante ao primeiro método, porém inclui vários pontos de máximo.

4 – Centro das somas, semelhante ao método da média ponderada, porém mais eficiente computacionalmente.

5 – Método dos centróides, ou centro de área ou gravidade, é o mais utilizado e com maior apelo físico, o valor exato é obtido através do centróide da área determinada pela união das funções de associação da saída, ou seja,

$$y^* = \frac{\int \mu_{B_n^k}(y) y dy}{\int \mu_{B_n^k}(y) dy} \quad (66)$$

sendo y^* o valor obtido pela dedifusificação e B_n^k o k-ésimo conjunto difuso conseqüente para a n-ésima regra.

3.8.3 - Modelo Takagi-Sugeno-Kang

Um outro modelo conhecido é o método de raciocínio de Takagi-Sugeno-Kang (TKS). A diferença deste método para os modelos lingüístico como, por exemplo, o de Mamdani é o formato especial da base de regras com a parte conseqüente funcional ao invés de difusa (YAGER e FILEV, 1994). Com este tipo de saída de um número real exato, o conjunto conseqüente de inferência será um conjunto difuso discreto com um número finito de pontos, o que aumenta a eficiência de processamento computacional.

Como dito anteriormente, no modelo TSG as regras antecedentes descrevem regiões difusas no espaço de entrada e as regras conseqüentes são funções exatas do modelo de entrada, i.e.,

$$\text{SE } x_1 \text{ é } A_1 \text{ e ... e } x_n \text{ é } A_n \text{ ENTÃO } y_i = f(x_1, \dots, x_n) \quad (67)$$

onde, $A_1, \dots, A_n$ são conjuntos difusos atingidos pelos respectivos valores físicos $x_1, \dots, x_n$, y_i é a i-ésima relação difusa e f normalmente representa uma combinação linear aplicada aos valores exatos.

Segundo Wang (1994), a saída do modelo TSK contendo r regras difusas é a média ponderada,

$$mp = \frac{\sum_{i=1}^r w_i y_i}{\sum_{i=1}^r w_i} \quad (68)$$

onde, y_i é a saída da i-ésima regra e w_i é dado por,

$$w_i = \prod_{j=1}^r \mu_{A_j}(x_j) \quad (69)$$

com μ denotando uma função de associação.

A vantagem deste sistema é a capacidade de descrever sistemas complexos, permitindo a decomposição em subsistemas simples, em alguns casos até sistemas lineares.

3.8.4 - Estrutura dos controladores difusos

Um controlador difuso é, então, composto por três etapas: difusificação, Inferência difusa e dedifusificação. Este tipo de controlador possui estruturas estáticas e determinísticas como mostra a Figura 34, as quais podem ser descritas através de curvas características de entrada e saída.

Figura 34: Estrutura interna de um controlador difuso

A princípio existem duas formas possíveis de implementação. Na primeira forma, geralmente chamada de "offline", as três etapas são transformadas em uma tabela de referência da qual são derivados os valores de comandos. Valores intermediários podem ser calculados através de interpolação numérica.

No segundo tipo de implementação, chamada de "online", os valores são avaliados a todo momento durante o processo. Este é o tipo padrão de implementação para os controladores difusos.

Existem várias maneiras diferentes para utilização de controladores difusos em aplicações de controle de malha fechada. A estrutura mais básica talvez seja a que utiliza sinais de um sensor do processo como sinal de entrada para o controlador e a saída como valores de comando para guiar os atuadores do processo. Esta estrutura está representada esquematicamente na Figura 35.

Figura 35: Estrutura de controle difusa de malha fechada

Freqüentemente combinações de controladores difusos com técnicas convencionais são encontradas em aplicações industriais. Na maioria dos casos as saídas do controlador difuso servem como parâmetros de referência como, por exemplo, ganhos fornecidos a controladores convencionais ao invés de guiar atuadores diretamente.

Para controladores difusos não é possível descrever aspectos dinâmicos internos já que se trata de um campo de características não lineares. Assim, qualquer propriedade dinâmica deve ser implementada através de um pré-processamento apropriado dos dados de entrada medidos.

O controlador difuso-PI (Proporcional e Integrativo) mostrado na Figura 36 utiliza como entradas o sinal do erro $e(t)$ e sua derivada $de(t)/dt$ obtidos através de pré-processamento dos dados medidos. Neste caso, se o sinal de erro e sua derivada forem utilizados como entradas a configuração será essencialmente a de uma generalização do controlador PI convencional.

Figura 36: Estrutura de um controlador difuso-PI

O benefício deste tipo de controlador é não possuir um ponto operacional especial. As regras avaliam a diferença entre o valor medido e o valor desejado, ou seja, o sinal $\text{erro}(t)$. As regras avaliam ainda a tendência do sinal de erro para determinar quando diminuir ou aumentar a variável controlada. O valor absoluto da variável de comando não influencia nesta avaliação.

A vantagem deste modelo quando comparado com o controlador PI convencional é a possibilidade de implementar estratégias não lineares com auxílio de regras lingüísticas. Para valores pequenos de $\text{erro}(t)$, é possível ainda, considerar apenas a tendência do erro.

Uma outra estrutura muito utilizada em indústrias químicas e de tecnologia de processos é o controlador difuso com PID convencional subjacente (Figura 37). Estas aplicações utilizam o controlador PID especificamente para parâmetros simples do processo. Usualmente, um operário supervisiona o ponto operacional do processo global.

Com os controladores difusos é possível aproveitar esta experiência e o conhecimento do operário para formar uma base de regras utilizando muito menos esforço ou tempo do que a modelagem matemática convencional do problema.

Figura 37: Estrutura de um controlador difuso com PID subjacente

O próximo exemplo de estrutura mostra como um controlador difuso pode ser utilizado na sintonia automática dos parâmetros de um controlador PID convencional. Neste caso, o controlador difuso interpreta constantemente as reações do processo e calcula os ganhos ótimos P, I e D.

Esta estrutura (Figura 38) é adequada a processos com característica que se alteraram no tempo.

Figura 38: Controlador difuso para adaptação de parâmetros PID

Num último exemplo (Figura 39) os controladores difuso e PID trabalham em paralelo. As saídas dos dois controladores são somadas, sendo que a saída do controlador difuso é nula em condições normais de operação. Na verdade, o controlador PID comanda o processo e a parte difusa é acionada somente quando uma anormalidade como, por exemplo, uma forte perturbação é detectada.

Figura 39: Controlador difuso para correção da saída de um PID

3.9 – Descrição do controlador difuso

Nesta seção serão descritos os detalhes do controlador difuso utilizado neste trabalho. Trata-se da estrutura mostrada na figura 35, porém com os valores desejados incorporados na base de regra. O controlador foi implementado no software LabVIEW® com a utilização do *PID Control Toolkit for Windows*. O programa de aquisição foi então modificado para incluir a opção de controle. O painel frontal da versão final pode ser visualizado na Figura 40. Nesta figura as escalas dos dois gráficos representam volts e número da amostra, no capítulo de resultados serão mostrados os sinais devidamente convertidos para pressão [kPa] e tempo [s].

Figura 40: Painel frontal da versão final do programa.

É possível verificar que foram adicionados o botão controle e uma janela de gráfico mostrando o sinal de comando para a válvula de ar.

As modificações do diagrama de blocos incluem uma estrutura do tipo case que ativa o controlador quando o botão “controle” do painel frontal é pressionado e dois subprogramas: um para carregar as informações (base de regras e base de conhecimento) previamente armazenadas em um arquivo específico e outro que utiliza estas informações e as entradas para calcular o sinal de comando e pode ser visto como o controlador propriamente dito.

Devido à alta frequência de aquisição, fixada para filtrar ruídos previamente identificados no sistema, tornou-se necessária a concentração da informação obtida pelos sensores antes da apresentação para o controlador. Isto foi realizado através do cálculo da média de cada 25 pontos adquiridos, ou seja, a cada 25 pontos um comando era enviado para a válvula. Testes com médias ponderadas que priorizavam os pontos mais recentes também foram efetuados, mas não apresentaram diferenças significativas no desempenho do controlador.

As variáveis de entrada foram definidas pelos valores de pressão de três sensores localizados na parte central da seção horizontal do circuito (Sensores 2,3 e 4) e do valor de pressão a montante, medido na tubulação de ar. As quatro variáveis de entrada foram, então, chamadas neste trabalho de P_{mont}, Sensor2, Sensor3 e Sensor4. A variável de saída, denominada de Comando, representa o sinal de comando (em volts) para a válvula da tubulação de ar.

A seguir é apresentada a base de conhecimento utilizada neste trabalho (Figuras 41, 42, 43, 44 e 45). A construção desta base foi baseada nos valores obtidos nos ensaios para identificação de regimes.

Figura 41: Funções de associação da variável P_{mont}.

Para a variável P_{mont} foram elaborados sete conjuntos difusos cujos nomes e valores podem ser visualizados na Figura 41. Como se trata de uma operação em tempo real, os valores de todas as variáveis foram utilizados em volts para evitar um aumento no tempo de processamento. Para se ter uma idéia dos níveis de pressão os valores de P_{mont} (volts) mostrados na Figura 41 correspondem a uma variação de 0 a 15,8 kPa.

Figura 42: Funções de associação da variável Sensor 2

As variáveis Sensor2, Sensor3 e Sensor4 foram todas divididas em cinco conjuntos difusos representando as quantidades: Mínimo (Min), Médio (Méd), Alto (Alto), Muito Alto (M. Alto) e Extremamente Alto (Ext. Alto).

Figura 43: Funções de associação da variável Sensor 3.

Figura 44: Funções de associação da variável Sensor 4.

Para a variável de saída Comando, foram elaborados cinco conjuntos difusos representando as categorias: Muito Pequeno (M Peq), Pequeno (Peq), Normal (Normal), Grande (Gra) e Muito Grande (M Gra), mostrados na Figura 45.

Figura 45: Funções de associação da variável Comando.

A idéia principal utilizada para construção da base de regras, já discutida no capítulo de introdução, é buscar uma velocidade que seja por um lado a menor possível para reduzir o consumo de potência, e por outro, alta o suficiente para que não ocorra o bloqueio da tubulação. Neste contexto e aceitando que o controlador

deve ser mais severo nos regimes mais perigosos, como dunas grandes e escoamento sobre a camada depositada, as seguintes regras foram então implementadas com pesos maiores nas situações mais instáveis:

1. IF (Pmont is M.Baixo) AND (Sensor2 is Med) THEN (Comando is M. Gra) (1,0)
2. IF (Pmont is M.Baixo) AND (Sensor3 is Med) THEN (Comando is M. Gra) (1,0)
3. IF (Pmont is M.Baixo) AND (Sensor4 is Med) THEN (Comando is M. Gra) (1,0)
4. IF (Pmont is Baixo) AND (Sensor2 is Alto) THEN (Comando is Gra) (1,0)
5. IF (Pmont is Baixo) AND (Sensor3 is Alto) THEN (Comando is Gra) (1,0)
6. IF (Pmont is Baixo) AND (Sensor4 is Alto) THEN (Comando is Gra) (1,0)
7. IF (Pmont is Normal) AND (Sensor2 is Min) THEN (Comando is Normal) (0,5)
8. IF (Pmont is Normal) AND (Sensor3 is Min) THEN (Comando is Normal) (0,5)
9. IF (Pmont is Normal) AND (Sensor4 is Min) THEN (Comando is Normal) (0,5)
10. IF (Pmont is Alto) AND (Sensor2 is Alto) THEN (Comando is Normal) (0,5)
11. IF (Pmont is Alto) AND (Sensor3 is Alto) THEN (Comando is Normal) (0,5)
12. IF (Pmont is Alto) AND (Sensor4 is Alto) THEN (Comando is Normal) (0,5)
13. IF (Pmont is M. Alto) AND (Sensor2 is M. Alto) THEN (Comando is Normal) (0,5)
14. IF (Pmont is M. Alto) AND (Sensor3 is M. Alto) THEN (Comando is Normal) (0,5)
15. IF (Pmont is M. Alto) AND (Sensor4 is M. Alto) THEN (Comando is Normal) (0,5)
16. IF (Pmont is Ext. Alto) AND (Sensor2 is Ext. Alto) THEN (Comando is Peq) (0,5)
17. IF (Pmont is Ext. Alto) AND (Sensor3 is Ext. Alto) THEN (Comando is Peq) (0,5)
18. IF (Pmont is Ext. Alto) AND (Sensor4 is Ext. Alto) THEN (Comando is Peq) (0,5)
19. IF (Pmont is Emerg) AND (Sensor2 is Med) THEN (Comando is M. Gra) (1,0)
20. IF (Pmont is Emerg) AND (Sensor3 is Med) THEN (Comando is M. Gra) (1,0)
21. IF (Pmont is Emerg) AND (Sensor4 is Med) THEN (Comando is M. Gra) (1,0)
22. IF (Pmont is Alto) AND (Sensor2 is M. Alto) THEN (Comando is Normal) (0,5)
23. IF (Pmont is Alto) AND (Sensor3 is M. Alto) THEN (Comando is Normal) (0,5)
24. IF (Pmont is Alto) AND (Sensor4 is M. Alto) THEN (Comando is Normal) (0,5)

A construção destas regras foi baseada nas curvas obtidas nos estudos de identificação de regimes (descritos com detalhes na seção 4.1) como, por exemplo, as mostradas na Figura 46 para uma vazão fixada de sólido de 0,0739 kg/s.

Figura 46: Comportamento das variáveis de entrada do controlador com o aumento da vazão de ar e $Q_{sol} = 0,0739 \text{ kg/s}$.

O ensaio que produziu as curvas da Figura 46 foi realizado da menor para a maior vazão, i.e., com o aumento gradual da vazão de ar, que pode ser inclusive representada nestas condições pela variável Pmont. Este comportamento sugere que para valores chamados de altos em qualquer um dos 3 sensores, e se a variável Pmont apresentar valores baixos (regras 4,5 e 6) o circuito estará operando na parte decrescente da curva e por isso a variável comando deve receber um valor alto (aumentar a vazão), por outro lado se Pmont apresentar também valores altos (regras 10,11 e 12) o circuito estará na parte crescente da curva e por isso o valor comando pode ser reduzido.

Os conjuntos difusos foram escolhidos para este trabalho exatamente por refletirem uma certa imprecisão ou incerteza na associação dos valores exatos medidos através dos sensores às classes Pequeno, Grande, Muito Grande etc. Esta incerteza está presente no sistema estudado e pode ser comprovada através da análise da Figura 47 que mostra o mesmo ensaio da Figura 46, porém com os valores adquiridos com a diminuição da vazão de ar, i.e., variando da maior para a menor vazão.

Figura 47: Comportamento das variáveis de entrada do controlador com a diminuição da vazão de ar e $Q_{sol} = 0,0739$ kg/s.

Como pode ser visto na Figura 47, o comportamento das curvas neste caso não é o mesmo, fato este que é compatível com a histerese descrita na Seção 3.1.

Portanto, para a elaboração das funções de associação foram considerados vários ensaios realizados de formas diferentes.

Devido a dimensão das entradas, foram desenhados três gráficos de superfície de decisão, onde cada sensor da linha horizontal (Sensor2, Sensor3 e Sensor4) foi combinado com P_{mont} e Comando. Os gráficos são mostrados nas Figuras 48, 49 e 50.

Figura 48: Superfície de decisão com as variáveis Sensor2, P_{mont} e Comando.

Figura 49: Superfície de decisão com as variáveis Sensor3, Pmont e Comando.

Figura 50: Superfície de decisão com as variáveis Sensor4, Pmont e Comando.

O método de inferência utilizado foi o Max-Min e o método de dedifusificação foi o centro de gravidade (Seção 3.8.2).

4 – TESTES EXPERIMENTAIS E RESULTADOS

Este capítulo apresenta os testes experimentais realizados e os resultados da identificação de regimes e do desempenho do controlador. Uma discussão sobre regimes e consumo de energia é também apresentada.

4.1 – Testes realizados e resultados da identificação de regimes

Este item descreve os testes experimentais para construção da base de dados e os resultados obtidos com a rede neural auto-organizável descrita na seção 3.7.

O sólido utilizado era constituído de sementes de *Setaria italica* (painço), com diâmetro médio $D_p = 2,5$ mm e densidade aproximada de 800 kg/m^3 . Os sinais de pressão foram isolados eletronicamente e amostrados a uma taxa de 100 Hz. A vazão mássica do sólido variou de 0,0739 Kg/s a 0,1437 Kg/s e a vazão de ar variou de 0,013 kg/s a 0,02 kg/s de forma a produzir os 4 regimes de escoamentos chamados neste trabalho de homogêneo, dunas com cristas, dunas grandes e escoamento sobre a camada depositada, com base em observações na parte horizontal do circuito.

A Figura 51 mostra fotos destes regimes de escoamentos obtidos nos ensaios.

Figura 51: Fotos dos regimes de escoamento

No escoamento homogêneo a velocidade do ar é bastante alta e as partículas encontram-se dispersas na tubulação. Com uma velocidade de ar um pouco menor tem início a formação de dunas com cristas como pode ser visto na Figura 51. Diminuindo ainda mais a velocidade do ar as partículas começam a se depositar no fundo da tubulação e a formar dunas grandes nas quais claramente se observa algumas partículas sendo agregadas por essa estrutura e outras (do lado oposto) sendo arrastadas pela corrente de ar. Finalmente com uma última redução do ar, o regime de escoamento sobre uma camada depositada é atingido.

Trechos dos sinais contendo 300 pontos foram fornecidos à rede para treinamento que resultou, a princípio, em uma classificação com 100% de acerto, como mostra a Tabela 02. As vazões de ar e sólido dos arquivos utilizados no treinamento foram, respectivamente, as seguintes: 0,019 kg/s e 0,1437 kg/s para o homogêneo, 0,015 kg/s e 0,1228 kg/s para o dunas com cristas, 0,014 kg/s e 0,1037 kg/s para o dunas grandes e 0,013 kg/s e 0,1037 kg/s para o escoamento sobre a camada depositada.

Tabela 02: Resultados do treinamento da rede neural auto-organizável.

Regimes de escoamento	Exemplos	Neurônio
Escoamento sobre a camada depositada	01 ao 10	04
Dunas grandes	11 ao 20	06
Dunas com cristas	21 ao 30	05
Homogêneo	31 ao 40	01

Os números dos exemplos na Tabela 02 significam que os sinais de 01 ao 10, que de fato correspondiam ao regime de escoamento sobre a camada depositada, foram todos classificados no mesmo neurônio, o de número 04, e assim por diante.

Como pode também ser visto na Tabela 02, a rede reduziu de seis para quatro o número de neurônios, confirmando a existência de quatro regimes distintos.

Para avaliar o desempenho da rede foram realizadas simulações. Uma vez que a rede já havia sido treinada (Tabela 03), os parâmetros foram salvos e trechos diferentes dos utilizados no treinamento foram, então, apresentados à rede. Nas três primeiras simulações foi também alterada a ordem de apresentação dos exemplos.

Os resultados da simulação 01 mostram uma classificação idêntica à do treinamento.

Tabela 03: Resultados da simulação 01.

Regimes de escoamento	Exemplos	Neurônio
Dunas grandes	01 ao 10	06
Homogêneo	11 ao 20	01
Escoamento sobre a camada depositada	21 ao 30	04
Dunas com cristas	31 ao 40	05

Na simulação 02, mostrada na Tabela 04, a ordem de apresentação dos exemplos (ainda grupos de 10) foi novamente alterada e a mesma classificação foi obtida.

Tabela 04: Resultados da simulação 02.

Regimes de escoamento	Exemplos	Neurônio
Dunas com cristas	01 ao 10	05
Dunas grandes	11 ao 20	06
Homogêneo	21 ao 30	01
Escoamento sobre a camada depositada	31 ao 40	04

Na simulação 03 os exemplos deixaram de formar grupos de 10, mas mesmo com esta modificação a rede continuou a classificar corretamente.

Tabela 05: Resultados da simulação 03.

Regimes de escoamento	Exemplos	Neurônio
Dunas com cristas	01 ao 06	05
Dunas grandes	07 ao 13	06
Homogêneo	14 ao 20	01
Escoamento sobre a camada depositada	21 ao 30	04
Homogêneo	31 ao 33	01
Dunas grandes	34 ao 36	06
Dunas com cristas	37 ao 40	05

Na sequência, outros ensaios com diferentes vazões de sólido e ar foram considerados de maneira a produzir resultados mais abrangentes. A mesma rede já treinada e utilizada nestas três primeiras simulações foi novamente aplicada a estes ensaios. O objetivo desta análise era investigar o comportamento da rede na avaliação do mesmo regime em diferentes vazões. O resultado da classificação foi sumarizado na Tabela 06, na qual o nome do regime (abreviações) definido visualmente é comparado com o número do neurônio obtido através da rede. Os arquivos utilizados no treinamento estão sinalizados com um asterisco.

Foram apresentados 10 exemplos (trechos dos sinais) de cada arquivo, ou seja, de cada par vazão de ar e vazão de sólido. Na maioria dos casos, os 10

exemplos foram classificados em um mesmo neurônio, mas situações na qual dois neurônios foram utilizados também ocorreram (Tabela 06). Para o regime homogêneo a classificação foi perfeita, i.e., mesmo variando a vazão de sólido a rede continuou apontando para o mesmo neurônio 01. No regime dunas com cristas um resultado também muito bom foi obtido, já que cerca de 80 % dos exemplos apresentados, inclusive variando as vazões de ar e sólido, foram classificados corretamente. Já nos regimes dunas grandes e escoamento sobre a camada depositada, a porcentagem de acerto foi pequena, respectivamente 33% e 50%. A razão destes baixos índices talvez seja a seleção dos sinais para treinamento. Uma possibilidade para a melhoria destes valores seria, por exemplo, a escolha de um outro sinal, que representasse melhor o regime a ser identificado.

Tabela 06: Classificação da rede neural para diferentes vazões mássicas

$Q_{ar} \setminus Q_{sol}$ (kg/s)	0,0739	0,1037	0,1228	0,1343	0,1395	0,1437
0,0200	Homo 01	Homo 01	Homo 01	Homo 01	Homo 01	Homo 01 *
0,0150	Cristas 04	Cristas 05	Cristas 05	Cristas 05	Cristas 05	Cristas 05
0,0143	Cristas 05	Cristas 05	Cristas 05 *	Cristas 05	Cristas 05 e 04	Cristas 04
0,0140	Dgrandes 05 e 06	Dgrandes 06 *	Dgrandes 05 e 06	Dgrandes 05	Dgrandes 05	Dgrandes 05
0,0130	Camada 05	Camada 04 *	Camada 04 e 05	Camada 05 e 06	Camada 04	Camada 04 e 05

Outro fato que deve ser observado é que estes regimes possuem vazões bastante próximas, o que significa que na parte inferior da Tabela 06 é provável que estejam presentes áreas de transição de regimes, o que contribuiria para o desempenho apresentado pela rede neural. É importante ainda salientar que a classificação visual foi definida de acordo com o regime que predominou na maior parte do tempo, uma vez que é possível que ocorra a transição de regimes mesmo com as vazões fixadas.

No entanto, apesar destas possibilidades muito interessantes a serem exploradas, os estudos sobre identificação de regimes foram finalizados neste ponto, uma vez que os resultados obtidos até aqui são suficientes para continuação do trabalho: os estudos de economia de energia e de controle difuso para redução do consumo de potência, apresentados a seguir.

4.2 – Economia de energia

Um outro tópico importante deste trabalho é a quantificação da economia de energia que pode ser obtida quando o sistema opera próximo à linha de transição para fase densa, operação que só é possível com a utilização de alguma estratégia de controle. Neste contexto, a potência consumida (W) para transportar o material particulado em cada um dos ensaios realizados e descritos na seção anterior foi calculada (BARBOSA, 2002) assumindo escoamento isotérmico ($RT = \text{cte}$) e conservação de energia num determinado trecho da linha, ou seja,

$$W = Q_{\text{ar}} R T \ln \left(\frac{P_1}{P_2} \right) \quad (70)$$

com P_1 indicando a pressão estática na entrada da seção de testes, a 1,5 m a jusante do alimentador de sólidos, e P_2 indicando a pressão na saída, a 1,5 m a montante do ciclone.

Os resultados podem ser visualizados na Tabela 07 que apresenta também na última linha o cálculo da economia que pode ser obtida com a proposta de redução da velocidade do ar. Por exemplo, para uma vazão de sólido de 0,0739 kg/s, é possível obter uma redução do consumo de potência de 48,9 %, se ao invés de trabalharmos em condições nominais de operação, i.e consumindo 1,707 kW, efetuarmos a diminuição da vazão de ar para 0,013 kg/s, passando a consumir 0,871 kW.

De uma maneira geral, os resultados mostram a possibilidade de economia de cerca de 52 %, em média, da potência consumida para transportar uma mesma carga de sólidos.

Tabela 07: Potência (em kW) consumida no transporte

$Q_{ar} \setminus Q_{sol}$ (kg/s)	0,0739	0,1037	0,1228	0,1343	0,1395	0,1437
0,0200	1,707	1,871	1,893	1,798	1,704	1,510
0,0150	1,112	1,367	1,240	1,104	1,108	0,971
0,0143	1,068	1,288	1,147	0,986	1,031	0,914
0,0140	1,001	1,148	0,955	0,984	0,941	0,865
0,0130	0,871	0,663	0,917	0,844	0,745	0,878
Economia ®	48,9 %	64,5 %	51,5 %	53,1 %	56,2 %	41,8 %

4.3 – Controlador difuso

Testes com o controlador difuso (implementação descrita na seção 3.9) foram realizados para verificação de desempenho. Nos primeiros testes, a aquisição de dados foi iniciada com o sistema em vários pontos operacionais diferentes (vazões de sólido e ar). O botão de controle foi acionado na sequência para demonstrar a habilidade do controlador em levar o circuito para a vazão que a inferência difusa determinou como a ideal, sem oscilações. Os resultados podem ser visualizados nas Figuras 52, 53, 54, 55 e 56. Estes gráficos possuem dois eixos verticais: o do lado esquerdo apresenta os valores de pressão em kPa obtidos dos quatro sensores considerados e o do lado direito mostra o valor do comando em volts enviado para a válvula na tubulação de ar. Este formato de gráfico permite uma excelente comparação entre as variáveis de entrada e saída e mostra elementos da dinâmica do circuito considerado, por exemplo, como um pequeno atraso na resposta, melhor visualizado nos ensaios iniciados com a vazão de ar ligeiramente menor do que a determinada como ideal (Figuras 53 e 54).

Figura 52: Teste com o controlador ($Q_{ar-inicial} = 0.017 \text{ kg/s}$, $Q_{ar-final} = 0.015 \text{ kg/s}$ e $Q_{sol} = 0.0739 \text{ kg/s}$)

Figura 53: Teste com o controlador ($Q_{ar-inicial} = 0.013 \text{ kg/s}$, $Q_{ar-final} = 0.016 \text{ kg/s}$ e $Q_{sol} = 0.1228 \text{ kg/s}$)

Figura 54: Teste com o controlador ($Q_{ar-inicial} = 0.014 \text{ Kg/s}$, $Q_{ar-final} = 0.014 \text{ kg/s}$ e $Q_{sol} = 0.1437 \text{ kg/s}$)

Figura 55: Teste com o controlador ($Q_{ar-inicial} = 0.016 \text{ kg/s}$, $Q_{ar-final} = 0.015 \text{ kg/s}$ e $Q_{sol} = 0.0739 \text{ kg/s}$)

Figura 56: Teste com o controlador ($Q_{ar-inicial} = 0.018 \text{ kg/s}$, $Q_{ar-final} = 0.015 \text{ kg/s}$ e $Q_{sol} = 0.1395 \text{ kg/s}$)

Como pode ser visto através dos gráficos em todos os casos o controlador estabilizou o escoamento numa determinada vazão de ar (aproximadamente 0.014 kg/s) que pode ser alterada através do chamado ajuste fino da superfície de decisão realizado pela alteração das funções de associação. No entanto, esta vazão representa um compromisso entre a segurança e a economia de potência.

O objetivo, como já foi discutido em capítulos iniciais, era observar a resposta do controlador em situações de uma iminente bloqueio. Para isso, dois tipos de perturbação foram considerados: o primeiro, indicado por “Tipo 1” na Figura 57, consiste em um vazamento na tubulação de ar, simulado através da abertura proposital de uma válvula de alívio, localizada entre o sensor de medição de vazão (Placa de orifício) e a seção de alimentação. O segundo tipo de perturbação, indicado por “Tipo 2” na Figura 57, consiste no aumento repentino da vazão de sólido. A Figura 57 é um esboço do diagrama de estado que representa a relação entre a perda de pressão ao longo da linha, a velocidade superficial da fase transportadora e a descarga do sólido transportado (cada linha no esboço representa uma descarga de sólido fixada) que para este circuito e tipo de material particulado pode ser encontrado em detalhes em (BARBOSA, 2002). A linha tracejada representa a linha de união das

pressões mínimas. De acordo com a figura os dois tipos de perturbação levam o circuito para a região de instabilidade.

Figura 57: Diagrama de estado com indicação dos tipos de ensaios realizados.

Os resultados dos ensaios do Tipo 1 são mostrados nas Figuras 58, 59 e 60, para diferentes vazões fixadas de sólido.

Figura 58: Ensaio do Tipo 1 ($Q_{sol} = 0.0739 \text{ kg/s}$)

No ensaio da Figura 58, a vazão inicial de ar era de 0.013 kg/s ou seja, ligeiramente menor do que a ideal segundo o controlador. A correção para a vazão ideal pode ser identificada pelo comportamento inicial das curvas do ensaio, uma vez que o controlador foi acionado aos 3 segundos. Na sequência o vazamento teve início e foi aumentado gradualmente, o efeito disto nas curvas de pressão foi um comportamento decrescente, contrastando com o comportamento crescente da curva de comando, mostrando que o controlador decidiu aumentar a vazão de ar para compensar o vazamento.

Figura 59: Ensaio do Tipo 1 ($Q_{sol} = 0.1395$ kg/s)

Os ensaios das Figuras 59 e 60, realizados com uma vazão maior de sólido mostram um comportamento semelhante ao anterior. Nestes ensaios a válvula de alívio foi aberta e fechada novamente. O efeito desta ação pode ser visto nos segundos finais dos ensaios, mostrando que o controlador volta a estabilizar o escoamento assim que o vazamento é eliminado.

Figura 60: Ensaio do Tipo 1 ($Q_{sol} = 0.1437 \text{ kg/s}$)

Figura 61: Ensaio do Tipo 2

Os ensaios do Tipo 2 produziram resultados semelhantes ao mostrado na Figura 61 onde a vazão de sólido variou de 0.0739 kg/s a 0.16 kg/s. O aumento das pressões, devido ao acúmulo de sólido na tubulação provocado pelo aumento repentino da vazão, pode ser claramente visualizado na Figura 61. Esta situação de aumento continua até um determinado momento (110 seg) em que o controlador dispara pulsos de vazões de ar para tentar “limpar” a tubulação.

Nesta situação, e naquelas mostradas nos ensaios do Tipo 1, caso não houvesse o controlador o sistema teria sido certamente danificado pelo bloqueio da linha de transporte. O que demonstra que o controlador difuso proposto proporciona efetivamente uma operação segura do circuito.

A potência consumida durante a utilização do controlador foi também medida para verificar a porcentagem de economia obtida, dentre as possibilidades que já haviam sido levantadas anteriormente (Tabela 07). O consumo médio de potência para cada vazão de sólido é mostrado na Tabela 08, que inclui ainda a economia referente a condições nominais de operação (regime homogêneo).

Tabela 08: Potência (kW) consumida com controlador difuso.

Q_{sol} (kg/s)	0,0739	0,1037	0,1228	0,1343	0,1395	0,1437
Potência	1,04	1,171	1,011	0,984	0,995	0,908
Economia	39,1%	37,4%	46,5%	45,2%	41,6%	39,8%

Os resultados mostram uma economia considerável de 41% em média. Isto significa que dos possíveis 52% de economia, aferidos por um estudo anterior (Tabela 07), 41% foram efetivamente obtidos após a implementação do controlador proposto.

5 – CONCLUSÕES E PERSPECTIVAS

Uma técnica de controle do escoamento gás-sólido que ocorre em transportadores pneumáticos de sólidos foi proposta neste trabalho. O algoritmo de controle é baseado em uma estrutura difusa que tem como entradas valores de pressão medidos em quatro pontos da tubulação e como saída o sinal de comando para a válvula da tubulação de ar.

Testes experimentais com o controlador realizados com sementes de *Setaria itálica* em uma linha de transporte pneumático de 12 metros na horizontal, 9 metros na vertical e 45 milímetros de diâmetro interno, mostraram uma redução significativa de 41%, em média, no consumo de potência requerida para o transporte de uma mesma carga de sólidos.

A construção da base de regras e de conhecimento do controlador foi baseada em um estudo prévio de identificação de regimes gás-sólido através de redes neurais auto-organizáveis que identificou quatro regimes de escoamento chamados de homogêneo, dunas com cristas, dunas grandes e escoamento sobre a camada depositada.

Foram realizados dois tipos de perturbação para verificar o desempenho do controlador em situações de um iminente bloqueio da linha de transporte: vazamentos na tubulação de ar e aumento excessivo da vazão de sólido. Nos dois casos o sistema foi propositalmente levado para área de transição para fase densa, ou seja, área de instabilidade. No primeiro caso, o controlador decidiu aumentar a vazão de ar para compensar o vazamento e no segundo, o controlador produziu pulsos na vazão de ar para desobstruir a linha de transporte demonstrando possibilitar efetivamente uma operação segura e ao mesmo tempo uma redução significativa no consumo de potência requerida para o transporte.

5.1 – Propostas de trabalhos futuros

As propostas de trabalhos futuros são compostas por dois itens: otimização dos parâmetros do controlador difuso e implementação de um controlador neural.

5.1.1 - Otimização dos parâmetros do controlador difuso

Uma contribuição interessante na seqüência deste trabalho seria o estudo mais específico de métodos de otimização dos parâmetros do controlador difuso implementado neste trabalho. A escolha destes valores até este momento foi baseada na simples observação do consumo de potência nos ensaios para identificação de regimes.

No caso da utilização de um algoritmo, como por exemplo, redes neurais ou algoritmo genético, a discussão passaria a ser sobre controle ótimo.

5.1.2 – Implementação de um controlador neural

Uma segunda proposta de trabalho futuro é a implementação de uma outra estrutura de controlador, o controlador neural. Esta estrutura neural, discutida anteriormente (Seção 3.4), pode ser utilizada para mudança automática da parametrização de um controlador PID, por exemplo. Na literatura esta mudança é conhecida como ganhos programados. Mais especificamente, é proposto um modelo baseado em dois modelos neurais independentes e seqüenciais, o primeiro sendo responsável pela detecção do regime de escoamento e determinação de ganhos e valores de referência (“set points”) apropriados, e o segundo modelo sendo responsável pelo cálculo de correções a serem impostas às variáveis controladas, visando obter condições comparáveis às obtidas com o controle difuso apresentado neste trabalho.

Esta arquitetura é esquematizada na Figura 62, na qual m_g , m_s , $\dot{m}_g$ e $\dot{m}_s$ representam respectivamente as vazões de gás e sólidos e suas correções, P_i ($i = 1, 2, \dots, M$) denota a pressão estática medida ao longo da linha de transporte, d é o valor de referência e K_p , K_i e K_d são respectivamente os ganhos proporcional, integral e derivativo.

Figura 62: Arquitetura interna do controlador neural proposto.

REFERÊNCIAS BIBLIOGRÁFICAS

- ALVAREZ, E.; RIVEROL, C.; NAVAZA, J.M. (1999). Control of chemical processes using neural networks.: implementation in a plant for xylose production. *ISA transactions*, v. 38, p. 375-382.
- AMARI, S.Z. (1990). Mathematical foundations of neural computing. *IEE Proceedings*, v. 78, n. 09, p. 1443-1463.
- ANNUNZIATO, M.; PIZZUTI, S. (1999). Fuzzy fusion between fluidodynamic and neural models for monitoring multiphase flows. *International journal of approximate reasoning*, v. 22, p. 53-71.
- ASME MFC - AMERICAN SOCIETY OF MECHANICAL ENGINEERS (1990). *Measurement of fluid flow in pipes using orifice, nozzle, and venturi*. New york. (ASME MFC-3M-1989)
- BAI, D.; SHIBUYA, E.; NAKAGAWA, N.; KATO, K. (1996). Characterization of gas fluidization regimes using pressure fluctuations. *Powder technology*, v. 87, p. 105-111.
- BANARSE, D.S.; FRANCE, I.; DULLER, A.W.G. (2000). Analysis and application of a self-organising image recognition neural network. *Advances in engineering software*, v. 31, p. 937-944.
- BARBOSA, P.R. (2002). *Economia de energia em transportadores pneumáticos de sólidos*. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2002.

- BARBOSA, P.R.; SELEGHIM JR, P. (2003). Improving the power consumption in pneumatic conveying systems by adaptive control of the flow regime. *Journal of the Brazilian society of mechanical sciences and engineering*. v. XXV, n. 4, p. 373-377.
- BARNEA, D.; SHOHAM, O.; TAITEL, Y. (1980). Flow pattern characterization in two phase flow by electrical conductance probe. *International journal of multiphase flow*, v. 6, n.5a, p. 387-397.
- BENNE, M. et al. (2000). Artificial neural networks for modeling and predictive control of an industrial evaporation process. *Journal of food engineering*, v. 46, p. 227-234.
- BI, H.T.; ELLIS, N.; ABBA, I.A.; GRACE, J.R. (2000). A state-of-the-art review of gas-solid turbulent fluidization. *Chemical engineering science*, v. 55, p. 4789-4825.
- BI, H.T.; GRACE, J.R. (1996). Regime transitions: analogy between gas-liquid co-current upward flow and gas-solids upward transport. *International journal of multiphase flow*, v. 22, p. 1-19.
- CHEN, F.C. (1990). Back-propagation neural network for nonlinear self-tuning adaptive control. *IEEE control systems magazine*, v.10, p. 44-48.
- CHEN, Z.; ZHENG, C.; FENG, Y. (1995). Distributions of flow regimes and phase holdups in three-phase fluidized beds. *Chemical engineering science*, v. 50, n. 13, p. 2153-2159.
- CRIVELARO, K.C.O.; SELEGHIM JR, P.; HERVIEU, E. (2002). Detection of horizontal two-phase flow patterns through a neural network model. *Journal of the Brazilian society of mechanical sciences*. v. XXIV, n. 1, p. 70-75.
- DUTTA, R.; KASHWANB, K.R; BHUYANB, M.; HINESA, E.L.; GARDNER, J.W. (2003). Electronic nose based tea quality standardization. *Neural Networks*, v. 16, p. 847-853.

- FRANZEN, A.; PLUSCHKELL, W. (1994). Application of fuzzy sets and neural network theory to the numerical pattern recognition of bubble flow and jet flow. *Steel research*, n. 11, v. 65, p.479-484.
- GABOR, A.J. (1998). Seizure detection using a self-organizing neural network: validation and comparison with other detection strategies. *Electroencephalography and clinical neurophysiology*, v. 107, p. 27-32.
- GRANGER, E.; SAVARIA, Y.; LAVOIE, P.; CANTIN, M. (1998). A comparison of self-organizing neural networks for fast clustering of radar pulses. *Signal processing*, v. 64, p. 249-269.
- GREAVES, A.J.; GASTEIGER, J. (2001). The use of self-organizing neural networks in dye design. *Dyes and pigments*, v. 49, p. 51-63.
- GROSSBERG, S. (1976). Adaptive pattern classification and universal recoding. *Biological Cybernetics*, v.23, pp. 121-134.
- GYENIS, J.; ULBERT, Zs.; SZÉPVÖLGYI, J.; TSUJI, Y. (1999). Discrete particle simulation of flow regimes in bulk solids mixing and conveying. *Powder technology*, v. 104, p. 248-257.
- HAGAN, M.T.; DEMUTH, H.B.; BEALE, M. (1996). *Neural network design*. Boston, PWS publishing company.
- HAYKIN, S. (1994). *Neural Networks: a comprehensive foundation*. New Jersey, Prentice hall.
- HEEB, D.O. (1949). *The organization of behaviour*. New York, Wiley.
- HERBRETEAU, C.; BOUARD, R. (2000). Experimental study of parameters which influence the energy minimum in horizontal gas-solid conveying. *Powder Technology*, v. 112, p. 213-220.
- HOPFIELD, J.J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the national academy of science*, v. 79, p. 2554-2558.

- HUBBARD, M.G.; DUKLER, A.E. (1966). The characterization of flow regimes for horizontal two-phase flow. *Proceedings of the heat transfer and fluid mechanics*, Stanford university press.
- ILG, W.; BERNIS, K.; MÜHLFRIEDEL, T.H.; DILLMANN, R. (1997). Hybrid learning concepts based on self-organizing neural networks for adaptive control of walking machines. *Robotics and autonomous systems*, v. 22, p. 317-327.
- JAWORSKI, A.J.; DYAKOWSKI, T. (2001). Application of electrical capacitance tomography for measurement of gas-solids flow characteristics in a pneumatic conveying system. *Measurement science and technology*, v. 12, p. 1109-1119.
- KALMAN, H. (2000). Attrition of powders and granules at various bends during pneumatic conveying. *Powder technology*, v. 112, p. 244-250.
- KICKERT, W.J.M.; van NAUTA LEMKE, H.R. (1976). Application of a fuzzy controller in a warmer water plant. *Automatica*, v. 12, p. 301-308.
- KLEIN, F.L.; SELEGHIM JR, P.; HERVIEU, E. (2004). Time-frequency analysis of intermittent two-phase flows in horizontal piping. Artigo aceito para publicação no *Journal of the Brazilian Society of Mechanical Sciences*.
- KOHONEN, T. (2001). *Self-organizing maps*. Berlin, Springer-verlag.
- KOWALSKI, C.T.; ORLOWSKA-KOWALSKA, T. (2003). Neural networks application for induction motor faults diagnosis. *Mathematics and computers in simulation*, v. 63, p. 435-448.
- KUSCHEWSKI, J.G.; HUI, S.; ZAK, S.H. (1993). Application of feed-forward neural networks to dynamical system identification and control. *IEEE Transactions on control systems technology*, v. 01, n.01, p. 37-49.
- KWAUK, M.; LI, J. (1996). Fluidization regimes. *Powder technology*, v. 87, p. 193-202.

- LECH, M. (2001). Mass flow rate measurement in vertical pneumatic conveying of solid. *Powder technology*, v.114, p. 55-58.
- LEE, C.C. (1990). Fuzzy logic in control systems: fuzzy logic controller – Part I and II. *IEEE Transactions on Systems, Man and Cybernetics*, n. 20, v. 2, p. 404-435.
- LEHNER, P.; WIRTH, K.E. (1999). Characterization of the flow pattern in a downer reactor. *Chemical engineering science*, v. 54, p. 5471-5483.
- LETZEL, H.M.; SCHOUTEN, J.C.; KRISHNA, R.; van den BLEEK, C.M. (1997). Characterization of regimes and regime transitions in bubble columns by chaos analysis of pressure signals. *Chemical engineering science*, v. 52, n. 24, p. 4447-4459.
- LEVY, A.; MASON, D.J. (1998). The effect of a bend on the particle cross-section concentration and segregation in pneumatic conveying systems. *Powder technology*, v. 98, p. 95-103.
- LI, J.; KUIPERS, J.A.M. (2002). Effect of pressure on gas–solid flow behavior in dense gas-fluidized beds: a discrete particle simulation study. *Powder technology*, v. 127, p. 173-184.
- MAILACHALAM, B.; SRIKANTHAN, T. (2002). Area–time issues in the VLSI implementation of self organizing map neural networks. *Microprocessors and Microsystems*, v. 26, p. 399–406.
- MAMDANI, E.H. (1974). Application of fuzzy algorithm for control of simple dynamic plant, *Proceedings of the IEEE*, v. 121, n. 12, p. 1585-1888.
- MAMDANI, E.H.; PROCYC, T.; BAAKLINI, N. (1976). Application of fuzzy logic to controller design based on linguistic protocol. In: MAMDANI, E.H. ; GAINES, B.R. (eds) *Discrete systems and fuzzy reasoning*. Queen Mary College, University of London, p. 125-149.
- MARCUS, R.D.; LEUNG, L.S.; KLIZING, G.E.; RIZK, F. (1990) *Pneumatic conveying of solids*. London, Chapman and hall.

- MARTINS, F.G.; COELHO, M.A.N. (2000). Application of feedforward artificial neural networks to improve process control of PID-based control algorithms, *Computers & chemical engineering*, v. 24, p. 853-858.
- MARQUES, F.D. (2000). *SEM 5772 – Tópicos em métodos não convencionais para controle de sistemas dinâmicos*. Escola de Engenharia de São Carlos – USP, Notas de aula.
- MATSUI, G. (1984). Indication of flow regimes in vertical gas-liquid two-phase flow using differential pressure fluctuation. *International journal of multiphase flow*, v. 10, n. 6, p. 711-720.
- MILANIC, S. et al. (1997). Applying artificial neural network models to control a time variant chemical plant. *Computers & chemical engineering*, v. 21, p. S637-S642.
- MISHIMA, K.; ISHII, M. (1984). Flow regime transition criteria for upward two-phase flow in vertical tubes. *International journal of heat and mass transfer*, v. 27, n.5, p. 723-737.
- MOLERUS, O. (1996). Overview: Pneumatic transport of solids. *Powder Technology*, v. 88, p. 309-321.
- MOLODTSOF, Y. (2003). Theoretical analysis of the flow regimes and their characteristics in vertically flowing gas–solids suspensions. *Chemical engineering journal*, v. 96, p. 133-143.
- MONAZAM, E.R.; SHADLE, L.J. (2004). A transient method for characterizing flow regimes in a circulating fluid bed. *Powder technology*, v. 139, p. 89-97.
- MOSCINSKI, J.; OGONOWSKI, Z. (1995). *Advanced control with matlab and simulink*. London, Ellis Horwood.
- MOSHOU, D.; RAMON, H. (2003). Vibration control using self-organizing look-up tables. *Journal of sound and vibration*, v. 266, p. 601–612.

- MOSHOU, D.; WAHLEN, S.; STRASSER, R.; SCHENK, A.; RAMON, H. (2003). Apple mealiness detection using fluorescence and self-organising maps. *Computers and Electronics in Agriculture*, v. 40, p. 103-114.
- NAGAMINE, R.K. (2001). *Lógica difusa para controle não convencional de uma viga inteligente*. Dissertação (Mestrado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, São Carlos. 2001.
- NEUFFER, D. et al. (1999). Control of pneumatic conveying using ECT. In: WORLD CONGRESS ON INDUSTRIAL PROCESS TOMOGRAPHY, 1., Buxton, 1999. Anais, p. 71-76.
- NEUROTH, M. et al. (2000). Improved modelling and control of oil and gás transport facility operations using artificial intelligence. *Knowledge-based systems*, v. 13, p. 81-92.
- NGUYEN, D.H.; WIDROW, B. (1990). Neural networks for self-learning control systems. *IEEE control systems magazine*, v. 10, p. 18-23.
- ORILLE, A.L.; SOWILAM, G.M.A. (1999). Application of neural networks for direct torque control. *Computers & Industrial Engineering*, v.37, p. 391-394
- OSTROWSKI, K.L.; LUKE, S.P.; BENNETT, M. A.; WILLIAMS, R.A. (2000). Application of capacitance electrical tomography for on-line and off-line analysis of flow pattern in horizontal pipeline of pneumatic conveyer. *Chemical engineering journal*, v. 77, p. 43-50.
- OSTROWSKI, K.L.; LUKE, S.P.; WILLIAMS, R.A. (1997). Simulation of the performance of electrical capacitance tomography for measurement of dense phase pneumatic conveying. *Chemical engineering journal*, v. 68, p. 197-205.
- PAN, R. (1999). Material properties and flow modes in pneumatic conveying. *Powder technology*, v. 104, p. 157-163.
- PAPPIS, C.P.; MAMDANI, E.H. (1977). Fuzzy logic control for a traffic junction. *IEEE Transactions on Systems, Man and Cybernetics*, v. 10, p. 707-717.

- PEDRYCZ, W. (1993). *Fuzzy control and fuzzy systems*. England, Research studies press ltd.
- POLANSKI, J. (2003). Self-organizing neural networks for pharmacophore mapping. *Advanced drug delivery reviews*, v. 55, p. 1149–1162.
- RAMIREZ-BELTRAN, N.D.; JACKSON, H. (1999). Application of neural networks to chemical process control. *Computers & Industrial Engineering*, v.37, p. 387-390.
- RAUTIAINEN, A. et al. (1999). An experimental study of vertical pneumatic conveying. *Powder technology*, v. 104, p. 139-150.
- REIBNEGGER, G.; WACHTER, H. (1996). Self-organizing neural networks - an alternative way of cluster analysis in clinical chemistry. *Clinica Chimica Acta*, v. 248, p. 91-98.
- REPPENHAGEN, J.; SCHETZSCHEN, A.; WERTHER, J. (2000). Find the optimum cyclone size with respect to the fines in pneumatic conveying systems. *Powder technology*, v. 112, p. 251-255.
- ROSENBLATT, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological review*, v. 65, p. 386-408.
- ROSS, T. J. (1995). *Fuzzy logic with engineering applications*. McGraw-Hill International edition, New York.
- RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. (1986). Learning representations of back-propagation errors. *Nature*, v. 323, p. 533-536.
- SAVAGE, B.S.; PFEFFER, R.; ZHAO, Z.M. (1996). Solids transport, separation and classification. *Powder technology*, v. 88, p. 323-333.
- SCHALLERT, R.; LEVY, E. (2000). Effect of a combination of two elbows on particle roping in pneumatic conveying. *Powder technology*, v. 107, p. 226-233.

- SEKOGUCHI, K.; INOUE, K.; IMASAKA, T. (1987). Void signal analysis and gas-liquid two-phase flow regime determination by a statistical pattern recognition method. *JSME International journal*, v. 30, n. 266, p. 1266-1273.
- SERRANO-CINCA, C. (1996). Self organizing neural networks for financial diagnosis. *Decision support systems*, v. 17, p. 227- 238.
- SIRA-RAMIREZ, H.J.; ZAK, S.H. (1991). The adaptation of perceptrons with application to inverse dynamic identification of unknown dynamic systems. *IEEE transactions on systems, man and cybernetics*, v. 21, p. 634-643.
- SRIVASTAVA, L.; SINGH, S.N.; SHARMA, J. (2003). Parallel self-organising hierarchical neural network based estimation of degree of voltage insecurity. *Computers and electrical engineering*, v. 29, p. 589–602.
- SUKHASWAMI, M.B.; PUJARI, A.K. (1996). Restoration of geometrically aberrated images using a self-organising neural network. *Pattern recognition letters*, v. 17, p. 1-10.
- TONG, R.M.; BECK, M.B.; LATTEN, A. (1980). *Fuzzy control of the activated sludge wastewater treatment process*, *Automatica*, v. 16, p. 695-701.
- van AMERONGEN, J.; van NAUTE LEMKE, H.R.; van DER VEEN, J.C.T. (1977). An autopilot for ships designed with fuzzy sets. In: 5th. IFAC/IFIP INTERNATIONAL CONFERENCE ON DIGITAL COMPUTER APPLICATIONS TO PROCESS CONTROL, The Hague.
- van NAUTA LEMKE, H.R. ; KICKERT, W.J.M. (1976). Application of a fuzzy controller in a warm water plant. *Automatica*, v. 12, p. 301-308.
- VINCE, M.A.; LAHEY JR, R.T. (1982). On the development of an objective flow regime indicator. *International journal of multiphase flow*, v. 8, n. 2, p. 93-124.
- von der MALSBERG, C. (1973). Self-organization of orientation sensitive cells in the striate cortex. *Kybernetic*, v. 14, p. 85-100.

- WANG, H.; OH, Y.; YOON, E.S. (1998). Strategies for modeling and control of nonlinear chemical processes using neural networks. *Computers & chemical engineering*, v. 22, p. S823-S826.
- WANG, L. (1994). *Adaptive fuzzy systems and control: design and stability analysis*. PTR Prentice Hall, USA.
- WARWICK, K.; IRWIN, G.W.; HUNT, K.J. (1992). *Neural Networks for control and systems*. (IEE control engineering series 46). Peter Peregrinus, Inglaterra.
- WESTENSKOW, D.R. (1997). Fundamentals of feedback control: PID, Fuzzy logic and Neural networks. *Journal of clinical anesthesia*, v. 9, p. 33S-35S.
- WIDROW, B.; LEHR, M.A. (1990). Thirty years of adaptive neural networks: perceptron, madaline, and back-propagation. *Proceedings of the IEEE*, v.78, p. 1415-1442.
- WU, H.; ZHOU, F.; WU, Y. (2001). Intelligent identification system of flow regime of oil-gas-water multiphase flow. *International journal of multiphase flow*, v. 27, p. 459-475.
- WYPYCH, P.W. (1999). Pneumatic conveying of powders over long distances and at large capacities. *Powder technology*, v. 104, p. 278-286.
- XU, L.J.; XU, L.A. (1997). Gas/liquid two phase flow regimes identification by ultrasonic tomography. *Flow measurement and instrumentation*, v. 8, n. 3/4, p. 145-455.
- YAGISHITO, O.; ITOH, O.; SUGENO, M. (1985). Application of fuzzy reasoning to the water purification process. In: SUGENO, M. *Industrial applications of fuzzy control*. Amsterdam, Netherlands.
- YAGER, R.R.; FILEV, D.P. (1994). *Essentials of fuzzy modeling and control*. New York, John Wiley & Sons.
- YAN, Y.; BYRNE, B. (1997). Measurement of solids deposition in pneumatic conveying. *Powder technology*, v. 91, p. 131-139.

- YANG, H.; LEWIS, I.R.; GRIFFITHS, P.R. (1999). Raman spectrometry and neural networks for the classification of wood types. 2. Kohonen self-organizing maps. *Spectrochimica acta part A*, v. 55, p. 2783–2791.
- YILMAZ, A.; LEVY, E.K. (2001). Formation and dispersion of ropes in pneumatic conveying. *Powder technology*, v. 114, p. 168-185.
- ZADEH, L. (1965). Fuzzy sets. *Information and control*, v. 8, p. 338-353.
- ZHANG, S.; GANESAN, R.; XISTRIS, G.D. (1996). Self-organising neural networks for automated machinery monitoring systems. *Mechanical systems and signal processing*, v. 10, n. 5, p. 517-532.
- ZIJERVELD, R.C.; JOHNSON, F.; MARZOCCHELLA, A.; SCHOUTEN, J.C.; van den BLEEK, C.M. (1998). Fluidization regimes and transitions from fixed bed to dilute transport flow. *Powder technology*, v. 95, p. 185-204.
- ZULKIFLI, A.H.; MEERAN, S. (1999). Decomposition of interacting features using a Kohonen self-organizing feature map neural network. *Engineering applications of artificial intelligence*, v. 12, p. 59-78.

APÊNDICE A – Simulação numérica do injetor de sólidos

Simulação numérica do injetor de sólidos

Uma parte inicial dos estudos feitos neste trabalho foi dedicada à simulação numérica de um dos componentes do circuito de transporte experimental, buscando a melhoria de seu projeto. A conexão do tipo venturi (Figura 63), responsável pela mistura do particulado com a fase gasosa foi construída e simulada no software comercial CFX. O objetivo era analisar, de uma forma qualitativa, os valores de pressão durante o funcionamento do sistema. Mais especificamente, variações na velocidade do ar e geometria do injetor de ar (diâmetro e comprimento, indicados na Figura 65 por “d” e “c” respectivamente) foram consideradas, visando à obtenção de uma zona de baixa pressão na região de descarga do sólido, possibilitando a sucção do particulado em direção a linha de transporte.

Figura 63: Geometria da conexão simulada

Foi considerado um domínio fluídico bifásico, composto pelo ar e por um fluido com propriedades (densidade e viscosidade dinâmica) semelhantes as do particulado utilizado nos testes experimentais, i.e, sementes de *Setaria Italica* com aproximadamente 2,5 mm de diâmetro. Como condições de contorno foram impostas vazões mássicas de ar e sólido e a pressão atmosférica na saída (Pressão de referência = 101,325 kPa). A malha superficial utilizada pode ser visualizada na Figura 64.

Figura 64: Detalhes da malha utilizada na simulação

Foram simulados sete casos, sumarizados na Tabela 09:

Tabela 09: Configurações simuladas do injetor de sólidos.

Caso	Diâmetro do injetor de ar	Comprimento do injetor de ar	Vazão de ar
1	22 mm	34 mm	0,05 kg/s
2	22 mm	34 mm	0,5 kg/s
3	15 mm	34 mm	0,05 kg/s
4	10 mm	34 mm	0,05 kg/s
5	05 mm	34 mm	0,05 kg/s
6	22 mm	58 mm	0,05 kg/s
7	10 mm	34 mm	0,005 kg/s

Com a geometria atual e valores aproximados das vazões de ar (0,05 kg/s) e sólido (0,2 kg/s), o resultado mostrado na Figura 65 foi obtido.

Figura 65: Distribuição de pressão para o caso 1.

Claramente pode ser observado que a distribuição de pressão não está de acordo com o nosso objetivo. Uma primeira modificação foi o aumento da vazão de ar de 0,05 kg/s para 0,5 kg/s, produzindo o resultado mostrado na Figura 66.

Figura 66: Distribuição de pressão para o caso 2.

Este caso mostra que com o aumento substancial da vazão a situação desejada é atingida (criação de uma zona de baixa pressão no ponto de injeção do particulado). No entanto, tal vazão é impraticável, além disso, solucionar o problema simplesmente aumentando a vazão de ar e, conseqüentemente, a velocidade, não parece ser uma

atitude adequada, uma vez que contraria o objetivo principal deste trabalho que busca a redução da potência consumida para o transporte do particulado.

A alternativa, então, foi a modificação da geometria, ou seja, aumentar a velocidade sem alterar a vazão. Isso foi possível com a redução do diâmetro do injetor de ar de 22 milímetros para 15, 10 e 5 milímetros. Esses resultados podem ser vistos nas Figuras 67, 68 e 69.

Figura 67: Distribuição de pressão para o caso 3

Figura 68: Distribuição de pressão para o caso 4

Figura 69: Distribuição de pressão para o caso 5.

Foi simulada ainda, uma alteração no comprimento do injetor de ar, passando de cerca de 34 mm para 58 mm. Porém esta configuração não apresentou modificações significativas na direção de nossos objetivos.

Figura 70: Distribuição de pressão para o caso 6.

Baseado na análise dos casos de redução de diâmetro (Figuras 67, 68 e 69) e na busca de uma velocidade adequada para o gás, foi simulado um último caso (caso 7). Desta vez, a vazão foi reduzida e o diâmetro escolhido foi 10 mm.

Figura 71: Distribuição de pressão para o caso 7.

Desta forma conseguimos encontrar uma geometria melhorada para o equipamento, uma vez que a redução no diâmetro contribuiu para a formação de uma zona de baixa pressão na região de descarga do sólido e, ao mesmo tempo, manteve velocidades adequadas na linha de transporte.

APÊNDICE B – Válvula rotativa

Válvula rotativa

Visando a operação contínua do circuito pneumático experimental do NETeF – EESC – USP foi desenvolvida a válvula rotativa mostrada separadamente na Figura 72:

Figura 72: Válvula rotativa.

Sem a utilização deste equipamento não seria possível o retorno do particulado uma vez que a abertura para a pressão atmosférica causaria um escoamento de ar para dentro do silo dificultando a descarga do particulado. Neste contexto, foi considerado inicialmente o projeto de uma válvula J, para fazer o transporte do particulado de uma região de baixa pressão para uma região de alta pressão. Porém, este tipo de equipamento, que utiliza o próprio peso do particulado para promover o seu movimento, se mostrou impossível de ser construído, pois necessitaria de uma altura extremamente alta (aproximadamente 5 metros). Na seqüência, a válvula mostrada em vista explodida na Figura 73 foi construída.

Figura 73: Vista explodida da válvula rotativa

Este projeto não apresentou um bom resultado devido ao travamento causado pelo acúmulo de particulado na parte interna da válvula. Por fim, foi elaborado o projeto e a construção da válvula de palheta (a mesma válvula anterior, porém o eixo central foi substituído por um sistema de palhetas), que foi instalada no circuito experimental do NETeF, como mostra a Figura 74 e utilizada nos testes deste trabalho.

Figura 74: Válvula rotativa instalada no circuito.

Em detalhes na Figura 74, pode ainda ser observado o redutor, necessário para a rotação adequada da válvula.