



UNICAMP
BIBLIOTECA CENTRAL
SEÇÃO CIRCULANTE

UNIVERSIDADE ESTADUAL DE CAMPINAS
FACULDADE DE ENGENHARIA QUÍMICA

ÁREA DE CONCENTRAÇÃO:

DESENVOLVIMENTO DE PROCESSOS QUÍMICOS

IDENTIFICAÇÃO E CONTROLE DE PROCESSOS NÃO LINEARES UTILIZANDO REDES NEURAIS ARTIFICIAIS

Autor: ADILSON JOSÉ DE ASSIS
Orientador: Prof. Dr. RUBENS MACIEL FILHO

Tese de Doutorado apresentada à Faculdade de Engenharia Química como parte dos requisitos exigidos para a obtenção do título de Doutor em Engenharia Química.

Campinas - São Paulo
Dezembro de 2001

200207315

UNIDADE	BC
N.º CHAMADA	T/UNICAMP
AS 76i	
V.	
T.	47794
PIR	837/02
C	☒
PREC	R\$ 11,00
DATA	14-02-02
N.º CPD	

CM00162934-2

FICHA CATALOGRÁFICA ELABORADA PELA
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

A76i As 76i	Assis, Adilson José de Identificação e controle de processos não lineares utilizando redes neurais artificiais / Adilson José de Assis. -- Campinas, SP: [s.n.], 2001.
	Orientador: Rubens Maciel Filho. Tese (doutorado) - Universidade Estadual de Campinas, Faculdade de Engenharia Química.
	1. Controle de processo - Automação. 2. Controle de processos químicos. 3. Redes neurais (Computação). 4. Identificação de sistemas. 5. Evaporadores. 6. Reatores químicos. I. Maciel Filho, Rubens. II. Universidade Estadual de Campinas. Faculdade de Engenharia Química. III. Título.

Tese de Doutorado defendida por ADILSON JOSÉ DE ASSIS e aprovada em 13 de Dezembro de 2001 pela banca examinadora constituída pelos doutores:



Prof. Dr. Rubens Maciel Filho

Orientador




Prof. Dr. Roberto de Campos Giordano

UFSCar (titular)




Prof. Dr. Humberto Molinar Henrique

UFU (titular)



Profa. Dra. Maria Regina Wolf Maciel


FEQ/UNICAMP (titular)



Dr. Eduardo Coselli Vasco de Toledo

Pós-doutorando FAPESP (titular)

Este exemplar corresponde à versão final da Tese de Doutorado em Engenharia
Química defendida por Adilson José de Assis.

A handwritten signature in black ink, reading "Rub Maciel Filho". The signature is fluid and cursive, with the first name "Rub" being particularly prominent.

Prof. Dr. Rubens Maciel Filho

DEDICATÓRIA

Há um grande sentido na vida. Descobri-lo, eis o objetivo de viver!

Assim sendo, dedico este despretensioso trabalho a todos aqueles que procuram um objetivo na vida, desejando-lhes possam encontrá-lo no trabalho digno e honesto, no auxílio ao próximo, na auto-realização e na prática do amor para com todos e tudo.

Homenagem a todos os homens e mulheres iluminados que já viveram neste planeta, conhecidos ou anônimos, mas que deixaram suas valiosas mensagens para a posterioridade!

Todas as nossas realizações do hoje se baseiam e se sustentam no trabalho de muitos que já passaram.

AGRADECIMENTOS

Os meus mais sinceros agradecimentos a todos aqueles que contribuíram de uma forma ou de outra para que a realização deste trabalho fosse possível.

Particularmente:

*Gratidão ao **Prof. Rubens Maciel Filho** pela amizade, confiança, paciência e orientação.*

Ao Centro de Engenharias e Ciências Exatas da Universidade Estadual do Oeste do Paraná (UNIOESTE) pela liberação durante o ano de 2001, que tornou possível a conclusão deste trabalho.

*Especial deferência à minha **família**, principalmente pais e irmãs, que sempre estiveram solidários comigo nesta longa caminhada pelas fascinantes trilhas da instrução e do conhecimento.*

Infinita gratidão a todos os MESTRES que nos apontam o rumo a tomar e nos apoiam durante a jornada.

*"Senhor!
Ajuda-me a transitar:
da treva para a luz;
da mentira para a verdade;
e da morte para a imortalidade."
(Upanishads)*

*"Fé inabalável só o é a que pode encarar frente a frente a razão, em
todas as épocas da Humanidade."*

Hippolyte Léon Denizard Rivail, pedagogo francês do Séc. XIX

*"Somente um firme esforço pode conferir a vitória. As coisas que
são obtidas sem esforço ou com esforço reduzido são destituídas de
valor e não merecem regozijo."*

Sathya Sai Baba, homem santo da Índia

RESUMO

IDENTIFICAÇÃO E CONTROLE DE PROCESSOS NÃO LINEARES UTILIZANDO REDES NEURAIS ARTIFICIAIS

Adilson J. de ASSIS

DPQ - FEQ - UNICAMP, dezembro de 2001

Considerando que a maioria dos processos industriais de interesse da Engenharia Química apresentam certo grau de não linearidade inerente ou introduzido por sistemas de controle automático, surge a importante necessidade de se investigar o desempenho de novas técnicas advindas da inteligência artificial, cujo interesse aqui está nas redes neurais artificiais, capazes de lidar com não linearidades de modo direto.

Realizou-se neste trabalho uma ampla revisão bibliográfica referente à identificação e controle de sistemas não lineares. As várias possibilidades de identificação de sistemas dinâmicos utilizando modelos empíricos paramétricos foram apresentadas segundo uma visão unificada, com ênfase nos métodos baseados em redes neurais artificiais. Revisou-se também de modo amplo as principais técnicas de controle desenvolvidas para processos não lineares assim como as principais aplicações reportadas na literatura no âmbito da Engenharia Química.

Posteriormente, utilizando-se de dois processos característicos da Engenharia Química, a saber, (1) dois reatores tanques conectados em série, nos quais ocorrem uma reação exotérmica, e com troca térmica; (2) evaporador de duplo efeito; foram discutidas várias possibilidades de identificação e controle utilizando redes neurais, em diversos níveis. Os resultados, obtidos por simulação computacional, mostram o potencial de utilização das redes neurais (na forma NNARX e NNSSIF), especialmente nas técnicas de controle preditivo, onde os melhores resultados foram obtidos. O primeiro sistema considerado possui dinâmica complexa e uma entrada e uma saída apenas (SISO), sendo que o segundo sistema possui múltiplas entradas e saídas (MIMO).

Unindo técnicas advindas da inteligência artificial, como as redes neurais artificiais, métodos clássicos de identificação e a moderna teoria de controle, mostrou-se como estas metodologias podem ser utilizadas com sucesso na busca de melhores desempenhos dos processos químicos sob a ação do controle automático.

PALAVRAS-CHAVE: Redes Neurais Artificiais; Sistemas Não Lineares; Identificação; Controle Automático; Reatores Químicos; Evaporadores.

ABSTRACT

IDENTIFICATION AND CONTROL OF NON-LINEAR PROCESSES USING ARTIFICIAL NEURAL NETWORKS

Adilson J. de ASSIS

DPQ - FEQ - UNICAMP, dezembro de 2001

Considering that most of the industrial processes of interest to Chemical Engineering present a certain degree of inherent non-linearity or one introduced by systems of automatic control, an important necessity of inquiring about the performance the new techniques derived from artificial intelligence, whose interest here is in the artificial neural networks, capable of dealing with non-linearity in a straightforward way.

It was made in this work a thorough bibliographical review related to the identification and control of non-linear systems. The various possibilities of identification of dynamic systems using parametric empirical models were presented according to a unifying view, with emphasis in the methods based on artificial neural networks. The main control techniques developed for non-linear processes as well as the main uses reported in literature on the Chemical Engineering field were also thoroughly reviewed.

Afterwards, making use of two processes typical of the Chemical Engineering, (1) two tanks reactors connected in series, in which a exothermal reaction occur, with thermal exchange; (2) double effect evaporator; various possibilities of identification and control using neural networks were discussed, in several levels. The results, obtained through computer simulation, show the potential usage of neural networks (in the form NNARX and NNSSIF), especially in the techniques of predictive control, where the best results were obtained. The first system taken into account has complex dynamics and Single Input, Single Output (SISO), whereas the second system has Multiple Input, Multiple Output (MIMO).

Uniting techniques derived from artificial intelligence, such as artificial neural networks, classic methods of identification and the modern theory of control, it was shown that these methodologies can be successfully used in the search for better performances of chemical processes under the action of automatic control.

KEY WORDS: Artificial Neural Networks; Nonlinear Systems; Identification; Automatic Control; Chemical Reactors; Evaporators.

SUMÁRIO

RESUMO	XIII
ABSTRACT	XV
SUMÁRIO	XVII
LISTA DE FIGURAS	XX
LISTA DE TABELAS.....	XXV
NOMENCLATURA (TERMINOLOGIA, GLOSSÁRIO).....	XXVII
1 INTRODUÇÃO.....	01
2 IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES.....	7
2.1 INTRODUÇÃO	9
2.2 ESTRUTURAS CAIXA-PRETA NÃO LINEARES	12
2.3 IDENTIFICAÇÃO DE SISTEMAS LINEARES	14
2.3.1 REVISÃO DOS MODELOS CAIXA-PRETA LINEARES	14
2.3.2 ESTIMATIVA DOS PARÂMETROS DO MODELO LINEAR	16
2.4 IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES – VISÃO UNIFICADA	18
2.4.1 ESTRUTURAS DE MODELOS PARA IDENTIFICAÇÃO NÃO LINEAR.....	18
2.4.2 POSSIBILIDADES DE MAPEAMENTO NÃO LINEAR	19
2.4.3 ESTIMATIVA E PROPRIEDADES DO MODELO	24
2.4.4 ALGORITMOS DE ESTIMATIVA DOS PARÂMETROS	27
2.5 IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES UTILIZANDO REDES NEURAIS	31
2.5.1 IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS.....	31
2.5.2 PROCEDIMENTO E MODELOS DE IDENTIFICAÇÃO.....	33
2.5.3 SELEÇÃO DA ESTRUTURA DO MODELO	38
2.5.4 MODELOS NEURAIS HÍBRIDOS.....	43
2.5.5 SIMPLIFICAÇÃO E CRITÉRIOS DE VALIDAÇÃO DO MODELO IDENTIFICADO.....	44
2.6 CONCLUSÕES	47
3 CONTROLE NÃO LINEAR DE PROCESSOS QUÍMICOS.....	49
3.1 INTRODUÇÃO	51
3.2 CARACTERÍSTICAS E MODELOS DOS PROCESSOS NÃO LINEARES.....	53
3.3 ESTRATÉGIAS DE CONTROLE PARA SISTEMAS NÃO LINEARES.....	57
3.3.1 CONTROLE LINEAR.....	57

3.3.2	<i>ESTRATÉGIAS ESPECIAIS E "AD HOC"</i>	62
3.3.3	<i>CONTROLE COM MODELO INVERSO DO PROCESSO</i>	63
3.3.4	<i>GEOMETRIA DIFERENCIAL</i>	69
3.3.5	<i>SÍNTESE DE SISTEMAS DE REFERÊNCIA</i>	75
3.3.6	<i>CONTROLE PREDITIVO BASEADO EM MODELO</i>	77
3.3.7	<i>CONTROLE ADAPTATIVO</i>	84
3.3.8	<i>CONTROLE NEURAL-NEBULOSO</i>	85
3.4	CONCLUSÕES	87
4	ESTUDO DE CASO: CSTRS EM SÉRIE	89
4.1	INTRODUÇÃO	91
4.2	DESCRIÇÃO DO PROCESSO E MODELO MATEMÁTICO	91
4.3	DINÂMICA DO PROCESSO EM MALHA ABERTA	93
4.4	IDENTIFICAÇÃO DO PROCESSO	97
4.4.1	<i>AJUSTE DE UM MODELO LINEAR</i>	99
4.4.2	<i>IDENTIFICAÇÃO UTILIZANDO REDES NEURAIS NNARMAX</i>	101
4.4.3	<i>IDENTIFICAÇÃO DA DINÂMICA INVERSA DO PROCESSO</i>	107
4.4.4	<i>IDENTIFICAÇÃO UTILIZANDO REDES NEURAIS ESTÁTICAS</i>	108
4.5	CONTROLE DO PROCESSO UTILIZANDO REDES NEURAIS	112
4.5.1	<i>CONTROLE COM O CONTROLADOR CLÁSSICO PID</i>	112
4.5.2	<i>CONTROLE COM MODELOS INVERSOS</i>	114
4.5.3	<i>CONTROLE NÃO LINEAR</i>	116
4.5.4	<i>CONTROLE POR LINEARIZAÇÃO INSTANTÂNEA</i>	117
4.5.5	<i>CONTROLE PREDITIVO NÃO LINEAR (NPC)</i>	119
4.5.6	<i>AValiação dos controladores segundo critérios de desempenho</i>	121
4.6	CONCLUSÕES	123
5	ESTUDO DE CASO: EVAPORADOR DE DUPLO EFEITO	125
5.1	INTRODUÇÃO	127
5.2	MODELAGEM MATEMÁTICA E CONTROLE AUTOMÁTICO DE EVAPORADORES: REVISÃO BIBLIOGRÁFICA	129
5.3	MODELO DINÂMICO DE EVAPORADOR DE DUPLO EFEITO	135
5.3.1	<i>Balanço de massa global</i>	136
5.3.2	<i>Balanço de massa do soluto</i>	136
5.3.3	<i>Balanço de energia</i>	136
5.3.4	<i>Balanço material no vapor</i>	137
5.3.5	<i>Equações de Estado</i>	137

5.3.6	<i>Relação da Pressão de Vapor</i>	138
5.3.7	<i>Relação do volume</i>	138
5.3.8	<i>Relação Termodinâmica</i>	138
5.3.9	<i>O Modelo de NEWELL e FISHER</i>	138
5.4	DINÂMICA DO SISTEMA EM MALHA ABERTA	143
5.5	IDENTIFICAÇÃO	145
5.6	CONTROLE PID	158
5.7	CONTROLE PREDITIVO BASEADO EM MODELO LINEAR	161
5.8	CONTROLE PREDITIVO UTILIZANDO REDES NEURAIS ARTIFICIAIS	164
5.9	CONCLUSÕES	166
6	CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS	167
6.1	CONCLUSÕES	169
6.2	SUGESTÕES PARA TRABALHOS FUTUROS	171
	REFERÊNCIAS BIBLIOGRÁFICAS E BIBLIOGRAFIA	173
	ANEXOS	189

Lista de Figuras

Figura 2-1 – Método de identificação em série-paralelo ou em paralelo. (z^{-1} é o operador deslocamento a ré)	35
Figura 2-2 – (a) modelo de identificação paralela. (b) modelo de identificação série-paralelo.	37
Figura 2-3 – Identificação de plantas não lineares utilizando redes neurais (série-paralelo).	38
Figura 2-4 – Modelo híbrido com rede neural.	44
Figura 3-1 – Linearização instantânea aplicada no projeto de sistemas de controle.	60
Figura 3-2 – Controlador RST.	61
Figura 3-3 – Estrutura do Controle com Modelo Interno (IMC).	63
Figura 3-4 – Controle por modelo inverso utilizando redes neurais.	64
Figura 3-5 – Controle inverso direto utilizando RNAs. Geralmente há falta de robustez do controlador nesta configuração.	66
Figura 3-6 – Diagrama do princípio do treinamento especializado.	67
Figura 3-7 - Esquema feedforward para otimização de um sistema de controle existente.	68
Figura 3-8 – Estrutura do controle de linearização global.	71
Figura 3-9 – Linearização por retroalimentação discreta, utilizando RNAs.	73
Figura 3-10 – Estrutura do controlador NLMPC.	81
Figura 3-11 – Controle não linear por otimização (esquema geral).	83
Figura 4-1 - Esquema dos reatores tanques com mistura perfeita.	91
Figura 4-2 – Resposta em malha aberta para perturbações degrau na vazão de refrigerante, q_c .	94
Figura 4-3 - Multiplicidade de estados estacionários (calor gerado - sigmóide e retirado - reta). $[T] = K$, $[Q] = J/min$	96
Figura 4-4 - Relação entre T_1 e T_2 no estado estacionário. $[T] = K$	97
Figura 4-5 – Dados de entrada (a) e saída (b) utilizados na identificação do sistema. Conjunto de treinamento e teste, respectivamente.	98
Figura 4-6 - Influência da ordem do regressor no índice de avaliação. (bidimensional). x: saídas; y: entradas; z: índice de avaliação.	99
Figura 4-7 – Influência da ordem do regressor no índice de avaliação. Eixo x: número de entradas/saídas passadas; Eixo y: ordem do índice de avaliação.	99
Figura 4-8 – Identificação do sistema utilizando um modelo linear ARX	100
Figura 4-9 – Funções de correlação dos resíduos (a) e de correlação cruzada entre a entrada e os resíduos (b) para o modelo linear ajustado, em função do atraso.	101

Figura 4-10 – Arquitetura da rede neural utilizada na identificação (yhat: predição da rede.) Estrutura [3,3,1].	102
Figura 4-11 – Influência do número de saídas y e entradas u alimentadas na rede neural. (o : na; — : nb)	102
Figura 4-12 - Influência do número de neurônios da camada interna e número de iteração no treinamento sobre o NSSE em um conjunto teste, em função do número de entradas consideradas.	103
Figura 4-13 – NSSE no treinamento da rede NNARX em função do n°. de iterações.	103
Figura 4-14 – Predição um passo a frente de C_{A2} utilizando uma rede neural na forma NNARX (a) Dados "reais" e preditos; (b) erro predito.	104
Figura 4-15 - Funções de autocorrelação do erro predito e coeficiente de correlação cruzada entre a entrada e o erro predito para o modelo neural NNARX (a) e NNOE (b).	105
Figura 4-16 - Histograma do erro predito e coeficientes linearizados da rede neural ajustada. (a) modelo NNARX; (b) modelo NNOE.	105
Figura 4-17 – Predição pelo modelo NNARX 250 passos à frente e comparação com a saída "real" do processo.	106
Figura 4-18 – Efeito da poda (prunning) sobre os índices de avaliação da rede.	107
Figura 4-19 – Arquitetura da rede neural utilizada na identificação da dinâmica inversa do processo a ser controlado.	108
Figura 4-20 – Identificação da dinâmica inversa do processo (entrada u(t) "real" e predita pela rede neural)	109
Figura 4-21 – Identificação do sistema em "malha aberta" (Concentração e temperatura do primeiro reator; + processo "real"; - rede neural).	111
Figura 4-22 - Identificação do sistema em "malha fechada" (Concentração e temperatura do primeiro reator).	111
Figura 4-23 - Identificação do sistema em "malha fechada" (Concentração e temperatura do segundo reator).	112
Figura 4-24 – Desempenho do controlador PID (problema regulatório e supervisório).	113
Figura 4-25 - Desempenho do controlador inverso direto (problema regulatório e supervisório)	114
Figura 4-26 - Desempenho do controlador inverso com modelo interno (IMC), com filtro (problema regulatório e supervisório)	115
Figura 4-27 - Desempenho do controlador inverso com modelo interno (IMC), sem filtro (problema regulatório e supervisório)	115
Figura 4-28 - Desempenho do controlador linearizante por retroalimentação (problema regulatório e supervisório)	117
Figura 4-29 - Desempenho do controlador linear por alocação dos pólos, com	118

todos os zeros cancelados (problema regulatório e supervisório)	
Figura 4-30 - Desempenho do controlador linear por alocação dos pólos, sem cancelar os zeros (problema regulatório e supervisório)	119
Figura 4-31 - Desempenho do controlador linear preditivo (GPC) aproximado (problema regulatório e supervisório)	120
Figura 4-32 - Desempenho do controlador preditivo não linear (problema supervisório)	121
Figura 4-33 - Desempenho do controlador preditivo não linear (problema regulatório e supervisório)	121
Figura 5-1 – Diagrama esquemático de um evaporador contínuo.	136
Figura 5-2 - Diagrama esquemático de um evaporador de duplo efeito, em escala piloto, considerado por NEWELL e FISHER (1972).	139
Figura 5-3 – Resposta em malha aberta de C2 para perturbações degrau em Sf (comparação do modelo linear e não linear).	145
Figura 5-4 – Resposta em malha aberta para uma perturbação de +10% em Sf.	145
Figura 5-5 - Resposta em malha aberta para perturbações de $\pm 1\%$ em B1.	145
Figura 5-6 – Resposta em malha aberta e determinação gráfica dos parâmetros de um modelo empírico de 1a ordem mais tempo morto.	146
Figura 5-7 – Simulação no Matlab/Simulink do modelo de 1a ordem identificado.	147
Figura 5-8 – Sequência de dados de entrada escalonados utilizados na identificação (conjunto de treinamento e teste).	148
Figura 5-9 - Sequência de dados de saída escalonados utilizados na identificação (conjunto de treinamento e teste).	148
Figura 5-10 – Comparação do diagrama de Bode dos dados de treinamento e teste (estimativa do espectro).	149
Figura 5-11 – Comparação entre a saída "real/medida" y_3 e as previstas pelos modelos lineares.	150
Figura 5-12 – Dados "medidos" de y_3 e predição da saída 5 intervalos à frente.	150
Figura 5-13 - Dados "medidos" de y_1 e predição da saída 5 intervalos à frente.	150
Figura 5-14 – Resposta y_3 a uma perturbação degrau em u_1 a partir dos modelos lineares.	151
Figura 5-15 – Pólos (x) e zeros (o) dos modelos identificados.	151
Figura 5-16 – Diagrama de Bode da resposta y_3 e a entrada u_1 a partir dos modelos lineares.	151
Figura 5-17 – Resposta transiente de todas as saídas para uma perturbação degrau em todas as entradas para o modelo ARX 310.	152
Figura 5-18 – Modelo neural não linear NNARX considerado na identificação.	153
Figura 5-19 – Critério de ajuste na etapa de treinamento em função do número de iterações.	153

Figura 5-20 – (a) Saída "medida" y_1 () e predição um passo a frente (--) utilizando o modelo neural NNARX; (b) erro predito	153
Figura 5-21 – Saída "medida" y_2 e predição um passo a frente utilizando o modelo neural NNARX.	154
Figura 5-22 - Saída "medida" y_3 e predição um passo a frente utilizando o modelo neural NNARX.	154
Figura 5-23 – Coeficientes de autocorrelação para o erro predito (NNARX). Saída 1.	154
Figura 5-24 - Coeficientes de autocorrelação para o erro predito (NNARX). Saída 2.	154
Figura 5-25 – Coeficientes de autocorrelação para o erro predito (NNARX). Saída 3.	154
Figura 5-26 – Histograma dos erros preditos e parâmetros linearizados da rede (NNARX).	154
Figura 5-27 – Modelo neural não linear NNSSIF.	155
Figura 5-28 – Saída "medida" y_1 e predição um passo a frente utilizando o modelo neural NNSSIF.	156
Figura 5-29 - Saída "medida" y_2 e predição um passo a frente utilizando o modelo neural NNSSIF.	156
Figura 5-30 – Saída "medida" y_3 e predição um passo a frente utilizando o modelo neural NNSSIF.	156
Figura 5-31 - Coeficientes de autocorrelação para o erro predito (NNARX). Saída 1.	156
Figura 5-32 – Coeficientes de autocorrelação para o erro predito (NNARX). Saída 2.	157
Figura 5-33 - Coeficientes de autocorrelação para o erro predito (NNARX). Saída 3.	157
Figura 5-34 – Histograma dos erros preditos (NNSSIF).	157
Figura 5-35 – Parâmetros linearizados da rede (NNSSIF).	157
Figura 5-36 – Implementação das malhas de controle PI utilizando o Matlab/Simulink.	159
Figura 5-37 – Desempenho dos controladores PI (mudança de set point em C2) – variáveis controladas (saídas).	160
Figura 5-38 – Desempenho dos controladores PI (mudança de set point em C2) – variáveis manipuladas (entradas).	160
Figura 5-39 – Desempenho dos controladores PI (perturbação degrau em F e Cf) – variáveis controladas (saídas).	160
Figura 5-40 – Desempenho dos controladores PI (perturbação degrau em F e Cf)– variáveis manipuladas (entradas).	160

Figura 5-41 – Desempenho dos controladores PI (perturbação degrau com ruído em F e Cf) – variáveis controladas (saídas).	161
Figura 5-42 – Desempenho dos controladores PI (perturbação degrau com ruído em F e Cf) – variáveis manipuladas (entradas).	161
Figura 5-43 – Desempenho do controlador preditivo (mudança de set point em C2) – Sistema linear.	162
Figura 5-44 – Desempenho do controlador preditivo (perturbação degrau em F e Cf) – Sistema linear.	162
Figura 5-45 – Desempenho do controlador preditivo (mudança de set point em C2) – Sistema não linear.	163
Figura 5-46 – Desempenho do controlador preditivo (perturbação degrau em F e Cf) – Sistema não linear.	163
Figura 5-47 - Desempenho do controlador preditivo (mudança de set point em C2 para 2) – Sistema não linear.	164
Figura 5-48 – Desempenho do controlador preditivo-NNSSIF (mudança de set point em C2) – Sistema não linear.	165
Figura 5-49 – Desempenho do controlador preditivo-NNSSIF (perturbação degrau em F e Cf) – Sistema não linear.	165

Lista de Tabelas

Tabela 4-1 – Condições nominais de operação dos CSTRs.	93
Tabela 4-2 – Combinação das variáveis utilizadas na identificação.	110
Tabela 4-3 – Critério de desempenho dos controladores utilizados.	122
Tabela 5-1 – Parâmetros do modelo do evaporador de duplo efeito.	142
Tabela 5-2 – Ganhos estáticos para perturbações degrau no evaporador.	144
Tabela 5-3 – Parâmetros do dos controladores PI.	160

Nomenclatura

$u(t)$ – entradas de um sistema no tempo t

$y(t)$ – saídas de um sistema no tempo t

$g(\dots)$ – função não linear

$v(t)$ – ruído do modelo empírico

$e(t)$ – erro (diferença entre um valor estimado e sua medida correspondente)

W – pesos das redes neurais artificiais

$A(q), B(q), C(q), F(q), D(q)$ – polinômios em q do modelo empírico

q, z^{-1} – operador deslocamento a ré

θ - parâmetro do modelo empírico

ϕ - vetor regressor

ANN – *Artificial Neural Network*

RNA – Rede Neural Artificial

TDL – *Tapped Delay Line*

SISO – *Single Input, Single Output* (entrada simples, saída simples)

MIMO – *Multiple Input, Multiple Output* (entrada múltipla, saída múltipla)

ARX – *AutoRegressive with eXogeneous variable*

ARMAX - *AutoRegressive Moving Average with eXogeneous variable*

NNARX – *Neural Network AutoRegressive with eXogeneous variable*

OBS: Todas as demais variáveis, parâmetros e símbolos empregados no texto são definidos ao longo do mesmo, à medida que são utilizados, a fim de facilitar a leitura.

Capítulo 1

INTRODUÇÃO

1. INTRODUÇÃO

A maioria dos processos químicos são caracterizados por apresentar severas não linearidades, como por exemplo, colunas de destilação de alta pureza, reatores de polimerização em batelada, processos bioquímicos, reatores CSTR não-isotérmicos, reatores de leito fixo, sistemas de neutralização de pH, dentre outros. Mesmo que o processo em si seja linear, a presença de um sistema de controle (válvulas de controle, saturação de atuadores, etc.) causa o surgimento de não linearidades.

Tradicionalmente, o controle dos processos não lineares tem sido feito aplicando a teoria de controle linear a um modelo linearizado do processo na etapa de projeto do controlador. A linearização é geralmente feita em torno do estado estacionário de referência e o sistema de controle projetado desta maneira é utilizado no controle do sistema real não linear. Se o processo for operado continuamente no estado estacionário em torno do qual houve a linearização, o modelo linear obtido não difere muito do processo real. Porém, é comum que as condições operacionais do processo mudem com o tempo, dependendo de vários fatores, desde econômicos, qualidade e fonte da matéria prima, desativação de catalisadores, mudanças genéticas em microorganismos, etc. Nas novas condições de operação, o controle existente pode já não ser mais adequado, levando à instabilidades no processo, perda de rendimento, presença de *off sets*, dentre outras características indesejáveis. Tendo em vista tal desempenho, é natural que se tenha pensado em desenvolver uma teoria de controle que levasse em consideração as não linearidades do processo na etapa de projeto do controlador, surgindo assim a *teoria de controle não linear*.

A disponibilidade de um modelo representativo do processo é uma condição fundamental para a teoria de controle linear (controle adaptativo e preditivo) e não linear (controle linearizante por retroalimentação e controle preditivo não linear). Apesar de bem desenvolvidos em muitas áreas, os modelos fenomenológicos, advindos de balanços de massa, energia e quantidade de movimento, apresentam relativa complexidade para serem utilizados em tempo real em estratégias de controle avançadas. Assim sendo, desenvolveram-se diversas metodologias de desenvolvimento de modelos mais simples, e ao mesmo tempo representativos, conhecidas como **identificação de sistemas**. Tais modelos fornecem apenas a relação entre as entradas e as saídas do processo e por isso são ditos como sendo do tipo "caixas pretas", haja vista não informarem acerca dos fenômenos

intrínsecos que ocorrem nos processos. Os modelos do tipo entrada-saída também são muito úteis na representação matemática de processos complexos, para os quais o desenvolvimento de um modelo fenomenológico seria uma tarefa muito complexa ou consumidora de um tempo, portanto, investimento financeiro, apreciável.

Um meio-termo entre os modelos fenomenológicos e os modelos entrada-saída são os modelos chamados de híbridos. Tais modelos procuram conciliar o que se conhece *a priori* de um determinado processo, na descrição fenomenológica, com informações puramente empíricas, ajustadas a partir de dados experimentais. Tal ajuste pode ser feito de vários modos, sendo as redes neurais um dos mais atrativos, dado sua característica em captar não linearidades com relativa facilidade. Neste paradigma de modelagem - a modelagem híbrida, preserva-se o modelo determinístico derivado a partir das equações de balanço, equações de estado, condição de existência de equilíbrio químico e termodinâmico, etc., em uma formulação relativamente simplificada e utiliza-se redes neurais para modelar fenômenos ainda pouco conhecidos do processo ou fenômenos que acontecem de maneira mais ou menos imprevisível, sendo neste último caso uma componente estocástica do modelo.

A aplicação da teoria de controle que leva em consideração um modelo do processo na forma não linear, no âmbito da Engenharia Química, é bem recente e tem se limitado a poucas aplicações a reatores químicos não isotérmicos. Devido à grande diversidade dos processos presentes na Engenharia Química, cada um com características específicas, há uma imensa lacuna na aplicação de teorias de controle avançado a estes processos. Há poucos estudos teóricos referentes à estabilidade e robustez em malha fechada dos mesmos e escassas também são as investigações experimentais.

Tendo como base as considerações feitas acima, percebe-se claramente que há um fértil terreno de estudo no que se refere ao controle de processos químicos. Devido à natureza peculiar destes processos, a teoria de controle que considera modelos não lineares parece ser a mais conveniente quando tem se em mente o projeto de controle para tais processos, auxiliada por recentes desenvolvimentos na área de inteligência artificial, principalmente das redes neurais. Ademais, as redes neurais podem ser acopladas aos modelos determinísticos na chamada modelagem híbrida, provendo assim uma sistemática de modelagem na qual se possa estabelecer um forte compromisso entre representatividade do modelo e tempo computacional hábil, sem perda considerável de generalidade. Esta

metodologia, além de útil no controle, tem mostrado alta potencialidade na inferenciação de variáveis de estado e no desenvolvimento dos *soft sensors*, principalmente na aplicação aos processos biotecnológicos.

Três objetivos principais nortearam o desenvolvimento do presente trabalho:

- (1) sistematizar através de ampla revisão bibliográfica os métodos de identificação utilizando modelos empíricos paramétricos desenvolvidos para sistemas não lineares, com ênfase nas redes neurais artificiais (RNAs);
- (2) apresentar as principais estratégias de controle capazes de lidar com processos não lineares e que utilizam em sua formulação modelos empíricos do processo, com ênfase nas técnicas de controle preditivo baseado em modelo;
- (3) realizar a aplicação das técnicas de identificação e controle apresentadas em dois casos-estudo representativos da Engenharia Química e que apresentam certo de grau de complexidade em suas dinâmicas.

O procedimento de investigação utilizado foi a simulação computacional utilizando um modelo fenomenológico dos processos considerados na obtenção da resposta dinâmica dos sistemas. Todas as simulações foram realizadas utilizando o *software* Matlab™. Optou-se por realizar as investigações apenas por simulação computacional para se permitir um maior aprofundamento nas teorias envolvidas, deixando para futuros trabalhos a investigação experimental das técnicas envolvidas e a comprovação (ou não) dos resultados obtidos.

Ressalta-se o procedimento inédito utilizado neste trabalho que é a aplicação aos processos químicos de um modelo linear “extraído”, em cada intervalo de amostragem, a partir do modelo neural previamente identificado. Esta estratégia garante uma constante atualização do modelo utilizado pelo controlador, que pode ser tanto na forma polinomial quanto na forma espaço de estados e evita a estimativa recursiva de parâmetros em modelos lineares, que é o procedimento normalmente utilizado quando se deseja atualizar periodicamente modelos de identificação. A estimativa recursiva tem a grande desvantagem da falta de garantia quanto a estabilidade do estimador, sendo comum a não convergência dos parâmetros.

Os capítulos que se seguem foram organizados do seguinte modo: no **Capítulo 2** serão apresentados os diversos procedimentos disponíveis para identificação de sistemas

não lineares, seguindo uma visão unificada. São igualmente revistos os principais conceitos da teoria de identificação de sistemas lineares. A ênfase será dada às redes neurais artificiais, e apresentam-se também as principais aplicações de identificação, relatadas na literatura, no âmbito da Engenharia Química. No **Capítulo 3** são apresentadas as principais técnicas de controle de sistemas não lineares, com extensa revisão da literatura acerca das investigações por simulação e experimentais que têm sido relatadas. As técnicas consideradas foram: controle clássico; controle com modelo inverso do processo; controle por geometria diferencial; controle adaptativo por alocação de pólos; controle preditivo baseado em modelo e controle neural-nebuloso. No **Capítulo 4** apresenta-se de modo detalhado a identificação e o controle de um sistema reacional constituído de dois reatores tanque agitados, processando reação exotérmica, de primeira ordem e com troca térmica. Este processo é um *benchmarking* nas investigações de controle não linear e apresenta uma dinâmica complexa, com multiplicidade de estados estacionários e altas não linearidades estáticas e dinâmicas. Nas investigações realizadas, considerou-se apenas o caso no qual há uma entrada e uma saída (SISO), sendo que as redes neurais artificiais na forma NNARX foram utilizadas na identificação da dinâmica direta e inversa do processo. Várias estratégias de controle utilizando os modelos neurais foram consideradas, sendo os melhores resultados obtidos para aquelas que utilizam estratégias preditivas. No **Capítulo 5** apresenta-se uma ampla revisão bibliográfica acerca da modelagem, identificação e controle de evaporadores. Posteriormente, considerou-se um evaporador de duplo efeito, em escala piloto, com três entradas e três saídas (MIMO), o qual foi identificado utilizando redes neurais artificiais na forma NNARX e NNSSIF. O controle deste sistema foi efetuado utilizando controle clássico PI e controle preditivo baseado em modelo linear na forma espaço de estados. O modelo linear foi obtido através de linearização utilizando Série de Taylor, a partir do modelo fenomenológico e também a partir do modelo neural. Finalmente, no **Capítulo 6**, são apresentadas as conclusões finais e as sugestões para prosseguimento das investigações tratadas neste trabalho.

Capítulo 2

IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES

2 IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES

2.1 INTRODUÇÃO

A **identificação** de sistemas está relacionada com o problema de se construir um modelo matemático para um sistema dinâmico, baseado em dados observados desse sistema. Trata-se portanto da construção de um **modelo empírico**, contrapondo-se aos **modelos fenomenológicos**, derivados a partir da descrição dos fenômenos envolvidos no processo e em geral advindos de balanços de massa, energia e quantidade de movimento, complementados por relações empíricas (equação de taxas de reação, relações termodinâmicas, correlações, etc.).

A necessidade de se dispor de um modelo matemático que descreva a dinâmica de um processo surge com as estratégias de controle avançado, nas quais esse modelo terá importante papel na ação de controle. Apesar dos modelos fenomenológicos apresentarem uma descrição mais detalhada do processo quando comparado aos modelos empíricos, não raro são constituídos de sistemas de equações matemáticas portando certo grau de complexidade, requerendo relativo esforço e tempo computacional na sua solução, tornando seu emprego em tempo real ainda limitado. Evidentemente, o constante aprimoramento das estruturas de "hardware" dos computadores utilizados como controladores tende a diminuir tal limitação¹.

Além da complexidade do modelo fenomenológico, outro fator que limita de certo modo seu emprego é o seu processo de desenvolvimento para um dado processo. O modelo empírico não exige um entendimento aprofundado desse, tornando a metodologia de desenvolvimento do modelo mais acessível àqueles que não possuem suficiente familiaridade com os fenômenos responsáveis pelos diferentes comportamentos exibidos em um processo real. Além disso, se um modelo empírico atende às necessidades de controle, levando o processo em malha fechada a ter o desempenho requerido, sob o ponto de vista de controle não há necessidade de se modelos mais complexos .

Uma outra vantagem dos modelos empíricos é que se pode especificar explicitamente a complexidade do modelo, permitindo até certo ponto o controle do grau de

¹ Nem todos os controladores são digitais, ou seja, utilizam computadores; entretanto, a ênfase aqui será no controle digital, pois constitui-se na classe de controlador mais comum nas indústrias químicas e correlatas.

complexidade do problema de controle resultante (HENSON E SEBORG, 1997).

Os modelos empíricos podem ser contínuos e discretos; lineares ou não lineares; monovariáveis ou multivariáveis; determinísticos ou estocásticos; invariantes ou variantes no tempo. Ao longo deste capítulo, diferentes modelos empíricos serão apresentados, permitindo uma melhor compreensão dos mesmos e sua utilização nas diferentes estratégias de controle.

O processo de identificação de sistemas é quase uma arte, sendo um processo iterativo, conforme proposto por Ljung (LJUNG, 1987). Segundo esse autor, o procedimento para determinar um modelo de um sistema dinâmico a partir dos dados de entrada-saída de um sistema, envolve três ingredientes básicos:

- os dados de entrada-saída;
- um conjunto de modelos candidatos (a estrutura do modelo);
- um critério de seleção de um modelo particular no conjunto, baseado na informação advinda dos dados (método de identificação).

O processo de identificação consiste então em se repetir as etapas de seleção da estrutura do modelo, cálculo do melhor modelo na estrutura escolhida e avaliar se as propriedades do modelo são satisfatórias. Este ciclo pode ser melhor descrito como sendo:

1. Projetar um experimento e coletar os dados de entrada-saída do processo a ser identificado;
2. Examinar os dados; "polir" os dados de tal forma a remover tendências e pontos discrepantes, selecionar porções úteis dos dados originais e filtrar os dados a fim de se melhorar frequências importantes;
3. Selecionar e definir uma estrutura de modelo – um conjunto de candidatos à descrição do sistema – dentro da qual um modelo será encontrado;
4. Calcular o melhor modelo na estrutura escolhida de acordo com os dados de entrada-saída e um dado critério de ajuste;
5. Examinar as propriedades do modelo obtido;
6. Se o modelo é bom o suficiente, então parar o processo de identificação; caso contrário, retornar à etapa 3 e tentar outro conjunto de modelos. Pode-se tentar

também outro método de estimativa (etapa 4) ou tentar melhorar os dados de entrada-saída (etapa 1 e 2).

Apesar desses itens parecerem óbvios, a correta observância desse procedimento permite o desenvolvimento de uma habilidade no desenvolvimento de modelos empíricos, tornando tal procedimento uma rotina racional e exitosa. Caso contrário, o processo de identificação transforma-se numa tarefa árdua de se encontrar uma agulha perdida em um palheiro, já que há centenas de possíveis modelos candidatos à descrição do processo, com inúmeras possibilidades de estrutura, tornando não raro a identificação um procedimento frustrante e consumidor de grande parcela de tempo. Além disso, um bom conhecimento a respeito do sistema a identificar facilita muito o trabalho.

Importantes questões tais como uso que vai ser feito do modelo resultante, escolha do sinal de entrada (excitação persistente, escolha da amplitude, frequência da variação do sinal, número de dados experimentais, tempo de amostragem, introdução de sinal externo em identificação em malha fechada), polimento e filtragem dos dados, devem ser consideradas de modo conveniente e há ampla literatura relativa a estes itens (LJUNG & SODERSTRÖM, 1983; GOODWIN & SIN, 1984; LJUNG, 1987; LJUNG & GLAD, 1994), e está além dos objetivos deste trabalho tratar com detalhe estes tópicos.

O conhecimento prévio que se dispõe acerca de um processo permite classificar tais processos em três níveis, segundo o modelo que o descreve (SJÖBERG *et al.*, 1995):

- **modelos caixa-branca** ("white-box models"). Este é o caso quando um modelo é perfeitamente conhecido, sendo possível sua elaboração totalmente a partir de conhecimentos prévios e "insight" físico.
- **modelos caixa-cinza** ("gray-box models"). Este é o caso quando há um certo conhecimento físico do processo, mas vários parâmetros permanecem para serem determinados a partir dos dados observados.
- **modelos caixa-preta** ("black-box models"). Nenhum conhecimento físico "a priori" está disponível ou é utilizado, mas a estrutura do modelo escolhida pertence à famílias que são conhecidas por apresentarem boa flexibilidade e foram utilizadas com sucesso no passado.

Como a maioria das estratégias de controle utilizam modelos na forma caixa-preta,

maior ênfase será dada nesta classe, embora os modelos caixa-cinza vêm recebendo muita atenção recentemente, sendo enquadrados nos chamados modelos híbridos, utilizando principalmente redes neurais na descrição das partes desconhecidas do processo (PSICHOGIOS & UNGAR, 1992; ZORZETTO *et al.*, 2000).

O presente capítulo está assim estruturado: inicialmente faz-se uma síntese do procedimento de identificação de sistemas lineares, que é a base para a compreensão da identificação dos sistemas não lineares; em seguida, descreve-se os principais métodos apresentados na literatura para a identificação de sistemas não lineares contínuos e discretos; finalmente é dada uma atenção particular à identificação de sistemas não lineares utilizando redes neurais, já que este será o método enfatizado neste trabalho; nas conclusões são reapresentados de forma resumida os conceitos mais importantes no procedimento de identificação de sistemas não lineares.

2.2 ESTRUTURAS CAIXA-PRETA NÃO LINEARES

A utilização de modelos discretos na identificação de sistemas é mais comum pois os dados experimentais são recolhidos via de regra através de um procedimento de amostragem. O **problema da identificação de sistemas** pode ser posto da seguinte maneira (SJÖBERG *et al.*, 1995):

a partir dos dados de entrada $u(t)$ e saída $y(t)$ observados de um sistema dinâmico

$$u' = [u(1) \quad u(2) \quad \dots \quad u(t)]$$

2 - 1

$$y' = [y(1) \quad y(2) \quad \dots \quad y(t)]$$

2 - 2

procura-se uma relação entre as observações passadas $[u^{t-1}, y^{t-1}]$ e as saídas futuras $y(t)$:

$$y(t) = g(u^{t-1}, y^{t-1}) + v(t)$$

2 - 3

O termo aditivo $v(t)$ envolve o fato de que a próxima saída $y(t)$ não será uma função exata dos dados pretéritos ou passados. Entretanto, o objetivo é ter $v(t)$ pequeno, de tal modo que $g(u^{t-1}, y^{t-1})$ possa ser uma boa predição de $y(t)$ dados os dados pretéritos. O modelo da 2 - 3 descreve sistemas dinâmicos discretos, lineares e não lineares (modelo genérico), e engloba evidentemente sistemas no estado estacionário (ou estáticos), já que são casos particulares dos sistemas dinâmicos.

A primeira questão que surge é: como encontrar a função g na Eq. 2 - 3? Devemos procurá-la dentro de uma família de funções. Para tal, parametriza-se essa família de funções com um vetor de parâmetros θ de dimensão finita²:

$$g(u^{t-1}, y^{t-1}, \theta) \quad 2 - 4$$

Uma vez que a estrutura de parametrização foi escolhida e o conjunto de dados observados coletados $[u^N, y^N]$, a qualidade de θ pode, por exemplo, ser avaliada por meio do ajuste entre o modelo e os dados disponíveis:

$$\sum_{t=1}^N \|y(t) - g(u^{t-1}, y^{t-1}, \theta)\|^2 \quad 2 - 5$$

A norma e a maneira de se encontrar (ou tentar encontrar) o mínimo em θ pode diferir de um procedimento para outro, mas a maioria dos esquemas em identificação de sistemas segue este conceito exposto.

A família de modelos descrita pela Eq. 2 - 4 é bem genérica, e mostra-se útil escrever g como uma concatenação de dois mapeamentos: (1) um que considera o crescente número de observações pretéritas u^t, y^t e as mapeia dentro de um vetor de dimensões finitas $\varphi(t)$ (ou de dimensões fixas) e (2) outro que considera este vetor no espaço das saídas:

$$g(u^{t-1}, y^{t-1}, \theta) = g(\varphi(t), \theta) \quad 2 - 6$$

onde

$$\varphi(t) = \varphi(u^{t-1}, y^{t-1}) \quad 2 - 7$$

Chama-se este vetor de **vetor de regressão** ou **vetor regressor**, e seus componentes serão referidos como regressores. Um caso ainda mais genérico é obtido se a formação do regressor for também parametrizado:

$$\varphi(t) = \varphi(u^{t-1}, y^{t-1}, \eta) \quad 2 - 8$$

o qual pode ser escrito por brevidade como sendo $\varphi(t, \eta)$. Algumas vezes $\eta = \theta$, i.e., o vetor de regressão depende de todos os parâmetros do modelo. Por simplicidade, o argumento extra η é omitido na maioria das vezes, quando não é essencial para a compressão da discussão.

² Isto se constitui usualmente em uma aproximação para g . Na verdade, o principal problema da identificação consiste em como proceder a uma boa parametrização e em como lidar com a mesma.

A escolha do mapeamento não linear na Eq. 2 - 4, foi então decomposto em dois subproblemas para os sistemas dinâmicos:

- (i) como escolher o vetor de regressão $\phi(t)$, a partir dos dados pretéritos de entrada e saída;
- (ii) como escolher o mapeamento não linear $g(\phi)$ a partir do espaço de regressão para o espaço de saída.

Estes dois subproblemas serão o objeto de discussão nas secções que se seguem. Inicialmente revisita o problema de identificação de sistemas lineares, pois o tratamento dado aos sistemas não lineares consiste em uma ampliação a tal procedimento.

2.3 IDENTIFICAÇÃO DE SISTEMAS LINEARES

2.3.1 REVISÃO DOS MODELOS CAIXA-PRETA LINEARES

Para sistemas lineares, o modelo dinâmico mais simples é o modelo resposta a um impulso finito (FIR – "Finite Impulse Response"):

$$\begin{aligned} y(t) &= B(q)u(t) + e(t) \\ &= b_1 u(t-1) + \dots + b_n u(t-n) + e(t) \end{aligned} \quad 2 - 9$$

Onde:

q ... operador deslocamento

$B(q)$... polinômio em q^{-1}

O preditor correspondente $\hat{y}(t|\theta) = B(q)u(t)$ é então baseado no vetor regressor:

$$\phi(t) = [u(t-1) \quad u(t-2) \quad \dots \quad u(t-n)] \quad 2 - 10$$

A medida que n tende ao infinito, pode-se descrever a dinâmica de qualquer sistema linear. Entretanto, o carácter do termo de ruído $e(t)$ não será modelado neste procedimento.

As estruturas paramétricas lineares caixa-preta utilizadas na prática são todas variações de 2 - 9, usando diferentes maneiras de se alocar os "pólos" do sistema e diferentes maneiras de se descrever as características do ruído. Todos estes modelos (paramétricos) podem ser resumidos pela família geral (LJUNG, 1987):

$$A(q)y(t) = \frac{B(q)}{F(q)}u(t-nk) + \frac{C(q)}{D(q)}e(t) \quad 2 - 11$$

onde:

$$A(q) = 1 + a_1 q^{-1} + \dots + a_{na} q^{-na} \quad 2 - 12$$

$$B(q) = b_1 + b_2 q^{-1} + \dots + b_{nb} q^{-nb+1} \quad 2 - 13$$

$$C(q) = 1 + c_1 q^{-1} + \dots + c_{nc} q^{-nc} \quad 2 - 14$$

$$F(q) = 1 + f_1 q^{-1} + \dots + f_{nf} q^{-nf} \quad 2 - 15$$

$$D(q) = 1 + d_1 q^{-1} + \dots + d_{nd} q^{-nd} \quad 2 - 16$$

$$q^{-1} y(k) = y(k-1) \quad 2 - 17$$

Os casos especiais da Eq. 2 - 11 são conhecidos como:

- modelo Box-Jenkins (BJ): $A = 1$;
- modelo ARMAX (AutoRegressive Moving Average with eXogeneous variable): $F = D = 1$;
- modelo erro-saída OE ("Output Error"): $A = C = D = 1$;
- modelo ARX (AutoRegressive with eXogeneous variable): $F = C = D = 1$

O mesmo tipo de família de modelos pode ser definida para sistemas com um número arbitrário de entradas nu :

$$A(q)y(t) = \frac{B_1(q)}{F_1(q)}u_1(t-nk_1) + \dots + \frac{B_{nu}(q)}{F_{nu}(q)}u_{nu}(t-nk_{nu}) + \frac{C(q)}{D(q)}e(t) \quad 2 - 18$$

O preditor associado à Eq. 2 - 11 pode ser dado na forma regressão "pseudo-linear" como sendo:

$$\hat{y}(t|\theta) = \theta^T \varphi(t, \theta) \quad 2 - 19$$

Os regressores, i.e., os componentes de $\varphi(t, \theta)$, são neste caso geral dados por:

- (i) $u(t-k)$ (associados com o polinômio B);
- (ii) $y(t-k)$ (associados com o polinômio A);
- (iii) $\hat{y}_u(t-k|\theta)$, saídas simuladas a partir de u passados somente (associados

com o polinômio F);

(iv) $\varepsilon(t-k) = y(t-k) - \hat{y}(t-k|\theta)$, erro predito (associado com o polinômio C);

(v) $\varepsilon_u(t-k) = y(t-k) - \hat{y}_u(t-k|\theta)$, erros de simulação (associados com o polinômio D).

Deve-se notar que no caso de $A \neq 1$ "a saída simulada" refere-se à quantidade $A(q)y(t)$.

Um modelo linear na forma espaço de estados na forma de predição

$$\begin{aligned} x(t+1) &= Ax(t) + Bu(t) + K[y(t) - Cx(t)] \\ y(t) &= Cx(t) + e(t) \end{aligned} \quad 2 - 20$$

também pode ser descrito como uma regressão pseudo-linear (Eq. 2 - 11), com o preditor $\hat{y}(t|\theta) = Cx(t)$, e os estados x como sendo os regressores. Notar que cada componente em $x(t)$ é obtido por filtragem linear das entradas e saídas passadas, cujo filtro depende de θ (i.e., das matrizes A, B, C e K):

$$x_i(t) = F_i^u(q, \theta)u(t) + F_i^y(q, \theta)y(t) \quad 2 - 21$$

Se $K = 0$, então $F_i^y(q, \theta) \equiv 0$, e tem-se o modelo na forma erro da saída.

A diferença essencial entre os regressores na forma entrada-saída e espaço de estados descritos anteriormente é que o primeiro contem blocos do mesmo regressor, deslocados no tempo um certo número de passos. Regressores na forma espaço de estados são portanto menos restritos na sua estrutura interna. Isto implica que seja possível obter um modelo mais eficiente com um menor número de regressores usando um modelo na forma espaço de estados. Modelos na forma espaço de estados conectados com redes neurais são também apresentados na literatura.

Para sistemas lineares, as duas classes de modelos mais populares são o somatório de convolução e a equação de diferenças finitas.

2.3.2 ESTIMATIVA DOS PARÂMETROS DO MODELO LINEAR

Os parâmetros de um modelo podem ser determinados via métodos de otimização, sendo um dos mais populares o Método dos Mínimos Quadrados (MMQ). Existem várias alternativas que visam adaptar este método a diversas situações (casos não lineares,

ortogonalização, etc.). Assumindo que um dado conjunto (finito) Z_e^N de pares de regressor – saída (medidos) na forma:

$$Z_e^N = \{(y(t), \varphi(t)) : t = 1, \dots, N\} \quad 2 - 22$$

Z_e^N é chamado de **conjunto de dados de estimação** ("estimation data set"), pois a estimativa dos parâmetros do modelo será realizada a partir do mesmo. A maneira mais comum de estimar θ é minimizar o erro entre a saída do modelo e a saída medida usando Z_e^N , como estabelecido na 2 - 5:

$$\min_{\theta} V_N(\theta, Z_e^N) = \frac{1}{N} \sum_{t=1}^N \|y(t) - g(\varphi(t), \theta)\|^2 \quad 2 - 23$$

Para sistemas lineares é possível escrever $y(t)$ como sendo o modelo de regressão (ÅSTRÖM & WITTENMARK, 1995):

$$y(t) = \varphi^T(t-1)\theta \quad 2 - 24$$

A estimativa dos parâmetros pode ser feita aplicando o método dos mínimos quadrados:

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T Y \quad 2 - 25$$

equação válida para $\Phi^T \Phi$ não singular e que minimiza a seguinte função:

$$V(\theta, t) = \frac{1}{2} \sum_{i=1}^t (y(i) - \varphi^T(i)\theta)^2 \quad 2 - 26$$

onde:

$$\Phi = \begin{pmatrix} \varphi^T(n) \\ \vdots \\ \varphi^T(t-1) \end{pmatrix} \text{ e } Y(t) = (y(1) \quad y(2) \quad \dots \quad y(t))^T$$

Quando $\Phi^T \Phi$ apresenta singularidade (ausência de inversa ou determinante zero), o que é comum quando se trabalha com dados experimentais ou dados obtidos de plantas químicas, há procedimentos específicos para se lidar com tal singularidade, como por exemplo o método OLS (*Orthogonal Least-Squares*) (BILLINGS *et al.*, 1989), e o método SVD (*Singular Value Decomposition*) (STRANG, 1988).

Os parâmetros podem também ser calculados de forma recursiva :

$$\hat{\theta}(t) = \hat{\theta}(t-1) + P(t)\varphi(t-1)\varepsilon(t) \quad 2 - 27$$

$$P(t) = \frac{1}{\lambda} \left(P(t-1) - \frac{P(t-1)\varphi(t-1)\varphi^T(t-1)P(t-1)}{\lambda + \varphi^T(t-1)P(t-1)\varphi(t-1)} \right) \quad 2 - 28$$

onde θ , φ e ε são diferentes expressões de acordo com o método adotado. Uma descrição completa do problema da identificação de sistemas lineares com finalidades de aplicação em controle de processos é encontrada em ÅSTRÖM & WITTENMARK (1995).

2.4 IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES – VISÃO UNIFICADA

2.4.1 ESTRUTURAS DE MODELOS PARA IDENTIFICAÇÃO NÃO LINEAR

Em contraste com a Eq. 2 - 19, válida para sistemas lineares, para o caso de sistemas não lineares tem-se estruturas da forma:

$$\hat{y}(t|\theta) = g(\varphi(t), \theta) \quad 2 - 29$$

onde g é alguma função não linear parametrizada por θ , sendo os componentes de $\varphi(t)$ similar ao regressor descrito anteriormente. Para o caso entrada-saída, os dois primeiros elementos, $u(t-k)$ e $y(t-k)$, são variáveis medidas e não causam problemas. As três remanescentes são todas baseadas nas saídas prévias do modelo caixa-preta $\hat{y}(t-k|\theta)$, de tal forma que se necessita escrever $\varphi(t, \theta)$ ao invés de $\varphi(t)$ na Eq. 2 - 29. A questão que surge é como a saída simulada $\hat{y}_u(t-k|\theta)$ é calculada se o modelo não linear produz saídas preditas $\hat{y}(t-k|\theta)$. A resposta é que a saída do modelo dado pela Eq. 2 - 29 é igual a $\hat{y}_u(t|\theta)$ se todas as saídas medidas $y(t-k)$ nos regressores forem substituídas pela última saída calculada $\hat{y}_u(t-k|\theta)$.

Seguindo a nomenclatura para modelos lineares, é natural nomear os modelos não lineares de modo similar, conforme segue:

- Modelos NFIR, os quais utilizam somente $u(t-k)$ como regressor;
- Modelos NARX, os quais utilizam $u(t-k)$ e $y(t-k)$ como regressores;
- Modelos NOE, os quais utilizam $u(t-k)$ e $\hat{y}_u(t-k|\theta)$ como regressores; neste caso a saída do modelo é também $\hat{y}_u(t|\theta)$;
- Modelos NARMAX, os quais utilizam $u(t-k)$, $y(t-k)$ e $\varepsilon(t-k|\theta)$ como regressores;

- Modelos NBJ, os quais utilizam $u(t-k)$, $\hat{y}(t-k|\theta)$, $\varepsilon(t-k|\theta)$ e $\varepsilon_u(t-k|\theta)$ como regressores; neste caso a saída simulada $\hat{y}_u$ é obtida como a saída dada por Eq. 2 - 29, usando a mesma estrutura, substituindo ε e ε_u por zeros no vetor regressor $\varphi(t, \theta)$;
- Modelos espaço de estados não lineares, os quais utilizam componentes passados de saídas virtuais, i.e., valores de sinais nos nodos internos da rede (modelo) que não correspondem à variável de saída.

As estruturas de modelo NOE, NBJ e NARMAX assim como os modelos na forma espaço de estados não lineares, correspondem às estruturas recorrentes, pois parte do vetor regressor consiste de saídas passadas do próprio modelo. Tal classe de modelos pode apresentar problemas de instabilidade no procedimento de identificação, além do fato de exigirem um esforço maior no cálculo do gradiente na estimativa dos parâmetros (SJÖBERG *et al.*, 1995).

Em NARENDRA & PARTHASARATHY (1990) é sugerido um modelo que utiliza redes neurais da seguinte forma:

$$\hat{y}(t) = f(\theta_1, \varphi_1(t)) + g(\theta_2, \varphi_2(t)) \quad 2 - 30$$

onde $\varphi_1(t)$ consiste de saídas atrasadas e $\varphi_2(t)$ de entradas atrasadas. As funções parametrizadas f e g podem ser escolhidas como sendo lineares ou não lineares utilizando convenientes redes neurais. A principal motivação no desenvolvimento desta estrutura de modelo é que se torna fácil desenvolver controladores a partir do mesmo, como será mostrado no próximo capítulo.

2.4.2 POSSIBILIDADES DE MAPEAMENTO NÃO LINEAR

Há inúmeras possibilidades de escolha para o mapeamento não linear representado por $g(\varphi, \theta)$ para o qual dado qualquer θ em $\mathcal{R}^d$ para $\mathcal{R}^p$. Até este ponto, não importou como o vetor regressor $\varphi = [\varphi_1 \quad \dots \quad \varphi_d]^T$ foi construído. Ele é apenas um vetor que está em $\mathcal{R}^d$.

É natural pensar em uma família de funções parametrizadas como sendo expansões de funções na forma:

$$g(\varphi, \theta) = \sum \alpha_k g_k(\varphi) \quad 2 - 31$$

Nesta equação, g_k são chamadas de *funções de base*, devido ao papel que desempenham na 2 - 31 ser similar àquele de uma base funcional espacial. A escolha de diferentes funções de base, junto com todas as possibilidades de escolha do vetor regressor φ apresentado anteriormente, desempenha o papel de um procedimento unificado para investigação da maioria das estruturas de modelo caixa-preta não lineares conhecidos. Este procedimento unificado foi proposto por SJÖBERG *et al.* (1995).

A questão principal agora é a escolha da função de base g_k . A maioria dos modelos caixa-preta bem conhecidos são compostos de g_k obtida pela parametrização de uma 'função de base geratriz' que genericamente denota-se por $\kappa(x)$. Em tais situações escreve-se de modo genérico:

$$g_k(\varphi) = \kappa(\varphi, \beta_k, \gamma_k) \quad ' = \kappa(\beta_k(\varphi - \gamma_k))' \tag{2 - 32}$$

a última equação é interpretada de modo simbólico e será mais detalhada a seguir. β_k e γ_k denotam parâmetros de diferente natureza. Tipicamente, β_k está relacionado com um escalar e com alguma propriedade direcional de $g_k(\varphi)$, e γ_k é alguma posição ou parâmetro de translação.

Exemplo: se $\kappa(x) = \cos x$, então 2 - 31 e 32 serão a expansão em série de Fourier, com β_k como sendo as frequências e como γ_k sendo as fases.

Duas classes de funções de base simples são consideradas, dependendo de sua natureza:

- *funções de base locais:* são funções tendo seu gradiente limitado em certo intervalo³, ou seja, suas variações ocorrem somente em certo intervalo; um exemplo deste tipo de função é a função *sigmóide*:

$$\kappa(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \tag{2 - 33}$$

- *funções de base globais:* são funções tendo seu gradiente infinitamente espalhado (finito ou não). A série de Fourier é um exemplo de função de base global;

³ Há outras classificações que não são baseadas no gradiente e uma mesma função pode ser classificada como sendo de base local ou de base global, dependendo da classificação adotada.

No caso de dimensões múltiplas ($d > 1$), g_k são funções multivariáveis. Na prática, são frequentemente construídas a partir de funções κ de variável simples. Os três métodos mais comuns de construção de funções de base multivariáveis a partir de funções de base monovariável são:

1. *Produto tensorial*. Dadas d funções de variável simples $g_1(\varphi_1), \dots, g_d(\varphi_d)$ (idênticas ou não), a construção de funções de base multivariáveis por produto tensorial é dado por seus produtos $g_1(\varphi_1)\dots g_d(\varphi_d)$.
2. *Construções radiais*. Para qualquer função κ monovariável, a construção radial de funções de base multivariáveis de $\varphi \in \mathbb{R}^d$, tem a forma:

$$g_k(\varphi) = g_k(\varphi, \beta_k, \gamma_k) = \kappa(\|\varphi - \gamma_k\|_{\beta_k}) \quad 2 - 34$$

onde $\|\bullet\|_{\beta_k}$ denota qualquer norma escolhida dentro do espaço do vetor de regressão φ . A norma pode ser por exemplo uma norma quadrática

$$\|\varphi\|_{\beta_k}^2 = \varphi^T \beta_k \varphi \quad 2 - 35$$

com β_k como uma possível matriz definida positiva, dependente de k , com parâmetros dilatados. Em casos simples β_k pode ser somente versões escalonadas de matriz identidade.

3. *Construções "ridge"*⁴. Seja κ qualquer função monovariável. Então, para qualquer $\beta_k \in \mathbb{R}^d$, $\gamma_k \in \mathbb{R}$, uma função "ridge" é dada por:

$$g_k(\varphi) = g_k(\varphi, \beta_k, \gamma_k) = \kappa(\beta_k^T \varphi + \gamma_k), \quad \gamma_k \in \mathbb{R}^d \quad 2 - 36$$

A função "ridge" é constante para qualquer φ no subespaço $\{\varphi \in \mathbb{R}^d : \beta_k^T \varphi = cte\}$.

Uma vez apresentados as idéias básicas, pode-se estabelecer conexões entre essas idéias e as estruturas comumente encontradas na identificação não linear.

- *Wavelets*. Exemplo de uma função de base local; a função de base geratriz é chamada de *mother wavelet* e denotada por ψ ao invés de κ .

⁴ Ridge: palavra que em inglês significa "crista" (de uma onda do mar, de uma montanha, etc.)

- *Wavelets e Redes Neurais de Base Radial*. A escolha de funções de base locais em combinação com construções radiais no caso multivariável, sem qualquer ortogonalização, é encontrada tanto em *redes wavelets* quanto em redes neurais de base radial.
- *Estimadores "Kernel"*. Outro exemplo bem conhecido do uso de funções de base locais. Uma função "kernel" $\kappa(\cdot)$ é tipicamente uma função na forma de sino, e o estimador "kernel" tem a forma:

$$g(\varphi) = \sum_{k=1}^n \alpha_k \kappa\left(\frac{\varphi - \gamma_k}{h}\right) \quad 2 - 37$$

onde h é um número positivo pequeno e γ_k são pontos dados no espaço do vetor regressor φ .

- *Interpolações (vizinhança próxima)*. Modelos que produzem saídas dependendo de dados estimados na proximidade e modelos de interpolações também podem ser descritos como expansões em funções de base.
- *"Splines B"*. Polinômios contínuos por partes que são funções de base locais. As conexões das partes de polinômios possuem derivadas contínuas até certa ordem, dependendo do grau do polinômio. "Splines" são funções muito úteis, pois exigem pouco esforço computacional e podem ser tão suaves quanto se queira. Por essas razões têm sido extensivamente utilizadas em problemas clássicos de interpolação.
- *Redes neurais sigmoidais*. A combinação do modelo de expansão (2 – 31), com a expansão "ridge" (2 – 36), juntamente com uma função sigmoidal (2 – 33) para função geratriz, fornece as bem conhecidas redes neurais *feedforward* sigmoidais, com uma camada oculta.
- *Hiperplanos dobradiços*. O modelo dos planos dobradiços é relacionado bem de perto com as redes neurais, e corresponde à escolha da função *dobradiça* ao invés da sigmoidal para função de base geratriz κ . A função dobradiça tem a forma de um "livro aberto" e é definida por:

$$h(\varphi) = \pm \max\{\beta^+ \varphi + \gamma^+, \beta^- \varphi + \gamma^-\}$$

onde β^+ e γ^+ são vetores e β^- e γ^- são escalares.

- *Modelos nebulosos ("Fuzzy")*. Os modelos nebulosos também pertencem à estrutura de modelos da classe dada pela Eq. 2 - 31. Neste caso, as funções de base g_k são construídas a partir do conjunto de funções nebulosas e regras inferenciais.

Outras estruturas menos comuns são "Projection pursuit regression", mínimos quadrados parciais, dentre outras.

Até o momento as estruturas de modelos foram vistas como *expansões em funções de base*, apesar de funções de base ajustáveis. Tais estruturas são referidas como sendo *redes* ("networks"), pois uma função de base geratriz κ é repetida um grande número de vezes na expansão. Neste contexto, há dois tipos principais de redes: redes multicamadas *feedforward* e redes recorrentes.

Nas redes multicamadas *feedforward* as saída de uma camada são agrupadas para formar um novo vetor regressor que será alimentado à camada posterior. A camada que possui saídas que não são vistas de modo explícito, mas sim utilizadas como entradas para a camada posterior, é chamada de *camada oculta* ("hidden layer"). O número de camadas ocultas pode variar de acordo com as necessidades de ajuste, aumentando assim a complexidade e possibilidades do mapeamento não linear, tornando, no entanto, mais difícil a etapa de "aprendizado" (ajuste da estrutura proposta ao conjunto regressor de treinamento). A questão de quantas camadas utilizar não é simples de ser respondida. Em tese, com suficiente número de funções de base, uma camada oculta seria suficiente para modelar a maioria dos sistemas práticos, como foi mostrado no trabalho clássico de CYBENKO (1989), citado como referência *sine qua non* quando o assunto é a utilização de estruturas de redes no mapeamento linear e não linear. Outros pesquisadores apresentaram posteriormente resultados semelhantes, validando tal tese, hoje aceita universalmente.

Nas redes recorrentes, outro tipo muito importante de redes, principalmente na identificação de sistemas dinâmicos, alguns dos regressores usados no tempo t são saídas da estrutura de modelo nos instantes de tempo anteriores:

$$\varphi_k(t) = g(\varphi(t-k), \theta) \quad 2 - 38$$

Pode ser também o caso de algum componente $\varphi_j(t)$ do regressor no tempo t ser obtido

como um valor de um nodo interior (não apenas da camada de saída) de um instante de tempo anterior. Esta configuração é mais comum nas redes baseadas em espaço de estados, enquanto que o caso da realimentação a partir da camada de saída é mais comum em redes na forma entrada-saída. Tal regressor dependente do modelo torna a estrutura consideravelmente mais complexa, mas oferece ao mesmo tempo maior flexibilidade de mapeamento.

A (difícil) tarefa de encontrar uma descrição não linear, na forma de caixa-preta, foi reduzida até o momento aos seguintes subproblemas:

1. Selecionar o vetor regressor φ ;
2. Selecionar uma função de base geratriz e escalar κ ;
3. Permitir que a expansão desta função geratriz no espaço do regressor seja tanto do tipo radial (2 - 34) ou quanto do tipo "ridge" (2 - 36), ou possivelmente ser uma função específica multidimensional;
4. Determinar o número de funções de base a ser usado em (2 - 31), assim como o número de camadas ocultas (ou intermediárias);
5. Determinar o valor da dilatação e parâmetros locais β_k e γ_k ;
6. Determinar os parâmetros de coordenação na Eq. 2 - 31.

2.4.3 ESTIMATIVA E PROPRIEDADES DO MODELO

Diversas técnicas diferentes têm sido desenvolvidas para estimativa de modelos. Antes de abordá-las, alguns aspectos básicos e genéricos que afetam as propriedades do modelo serão apresentadas. Tais propriedades possuem importantes implicações tanto na escolha das funções de base, quanto no processo de estimativa utilizado .

Considere o modelo genérico caixa-preta:

$$y(t) \approx g(\varphi(t), \theta) = \sum_{k=1}^n \alpha_k g_k(\varphi(t), \beta_k) \quad 2 - 39$$

no qual os parâmetros γ_k previamente usados foram incluídos em β_k por brevidade na discussão que se segue. Após escolhidas as funções de base g_k , o principal objetivo da estimativa do modelo é a escolha dos parâmetros de tal forma que o ajuste do modelo torne-se razoável. Assumindo que um conjunto finito de pares regressor-saída Z_e^N (medido) seja

dado:

$$Z_e^N = \{(y(t), \varphi(t)) : t = 1, \dots, N\} \quad 2 - 40$$

O conjunto Z_e^N é referido como sendo o *conjunto de dados de estimativa* pois o processo de estimativa dos parâmetros irá se basear no mesmo. Notar que todos ou parte dos parâmetros θ (i.e., α_k, β_k) devem ser estimados a partir do conjunto de dados Z_e^N , dependendo da escolha das funções de base e do método de estimativa. O número real de parâmetros a serem estimados, $\dim \theta$, será denotado por m .

O método mais comum de estimativa de θ será a minimização do erro entre a saída do modelo e a saída medida usando Z_e^N , da seguinte forma:

$$\min_{\theta} V_N(\theta, Z_e^N) = \frac{1}{N} \sum_{t=1}^N \|y(t) - g(\varphi(t), \theta)\|^2 \quad 2 - 41$$

Supor que o dado real possa ser descrito por:

$$y(t) = g_o(\varphi(t)) + e(t) \quad 2 - 42$$

onde g_o é algum "modelo real" desconhecido e $e(t)$ é um ruído branco com variância λ . A estimativa de θ baseado em Z_e^N será denotada por $\hat{\theta}_N$. Deseja-se então que $g_o(\varphi)$ e $g(\varphi(t), \hat{\theta}(t))$ seja tão próximo quanto possível. Esse grau de proximidade é chamado de "qualidade do modelo" e há vários métodos de se avaliar tal qualidade, dependendo da aplicação considerada. Dentre esses métodos, há a medida do ajuste entre qualquer modelo θ dado e o verdadeiro sistema dada por:

$$\bar{V}(\theta) = E\|y(t) - g(\varphi(t), \theta)\|^2 = \lambda + E\|g_o(\varphi(t)) - g(\varphi(t), \theta)\|^2 \quad 2 - 43$$

Na expressão anterior o regressor $\varphi(t)$ é assumido como sendo um processo estacionário. Para a maioria das finalidades práticas e sob condições quase gerais, a medida anterior pode ser interpretada como sendo a média da amostra:

$$\bar{V}(\theta) = \lim_{N \rightarrow \infty} \frac{1}{N} \sum_{t=1}^N \|y(t) - g(\varphi(t), \theta)\|^2 \quad 2 - 44$$

A medida $\bar{V}$ depende das propriedades do regressor. O que denomina um "bom modelo" dependerá de qual seqüência de regressor a que a medida será aplicada. Dentro de uma

estrutura de modelo dada, parametrizada por θ de dimensão m , pode-se definir o melhor modelo de acordo com a qualidade da medida escolhida:

$$\theta_*(m) = \arg \min_{\theta} \bar{V}(\theta) \quad 2 - 45$$

Para medir a qualidade de um dado modelo $\hat{\theta}_N$, deveremos utilizar

$$E\bar{V}(\hat{\theta}_N) = V_*(m) \quad 2 - 46$$

A esperança E é com relação ao modelo $\hat{\theta}_N$. A medida dada por 2 - 46 descreve o ajuste esperado do modelo ao sistema real, quando aplicado a um novo conjunto de dados, com as mesmas propriedades (distribuição) dos regressores φ , chamado de "conjunto de teste" ou "conjunto de validação". Para maiores detalhes acerca da avaliação da qualidade do modelo, incluindo uma discussão acerca das origens e desvantagens do ajuste excessivo (*overfitting*), gerando parâmetros ditos *espúrios*, consultar o Capítulo 16 de LJUNG (1987).

A minimização do número de parâmetros m pode ser feita de modo quase intuitivo através da tentativa de uma seqüência de modelos, com m aumentando, e estimando $V_*(.)$ pelo teste do mesmo aplicado ao conjunto de validação; uma outra alternativa é modificar a perda obtida nos dados de estimativa (essência dos critérios Akaike AIC e FPE). Como este procedimento pode levar a um teste quase infinito de casos, o procedimento mais usual é "oferecer" uma estrutura de modelo com grande número de parâmetros e então tentar decidir quais são realmente importantes – não espúrios – e utilizar somente esses. O número m deste modo quantificará apenas os parâmetros realmente utilizados. Algumas possibilidades para se alcançar este objetivo:

- *Regularização*: Adota-se um critério que penaliza os parâmetros do modelo e então distingue-se aqueles que possuem maior ou menor importância; os parâmetros espúrios são então desconsiderados;
- *Omissão de funções de base*: a escolha dos regressores é feita de modo cuidadoso, guiado pelos dados. Uma variante deste procedimento é o "encolhimento" (*shrinking*), segundo o qual componentes de $\hat{\theta}_N$ que estão abaixo de certo "nível de ruído" são igualados a zero. Excelentes resultados foram encontrados para "wavelets". O método equivalente ao encolhimento em

conexão com as redes neurais é chamado de "poda"⁵ (*prunning*) e tem atraído bastante atenção dos pesquisadores ultimamente (veja o item específico sobre o procedimento de podagem em redes neurais neste capítulo: Simplificação e Critérios de Validação do Modelo Identificado).

2.4.4 ALGORITMOS DE ESTIMATIVA DOS PARÂMETROS

O problema da estimativa dos parâmetros pode ser posto da seguinte forma: Para um dado número n de funções de base g_k escolhidas, como estimar os parâmetros desconhecidos do modelo? Há dois métodos principais considerados na estimativa dos parâmetros do modelo de mapeamento: métodos de otimização e métodos construtivos.

MÉTODOS DE OTIMIZAÇÃO: Dado um critério de avaliação escalar, a estimativa dos parâmetros é definida como sendo a minimização do argumento:

$$\hat{\theta}_N = \arg \min V_N(\theta) \quad 2 - 47$$

A estimativa das funções desconhecidas será então:

$$\hat{g}_N(\varphi) = g(\varphi, \hat{\theta}_N) \quad 2 - 48$$

Algumas vezes utiliza-se uma norma não quadrática, geral, ao invés de 2 - 41:

$$V_N(\theta) = \frac{1}{N} \sum_{t=1}^N \ell(\varepsilon(t), \theta), \quad 2 - 49$$

$$\varepsilon(t, \theta) = y(t) - g(\varphi(t), \theta)$$

onde $\ell(\varepsilon(t), \theta) = -\log f_e(\varepsilon, t; \theta)$ e f_e é uma função densidade de probabilidade PDF (*Probability Density Function*) do ruído $\varepsilon(t)$ (LJUNG, 1987).

A estimativa $\hat{\theta}_N$ é uma estimativa de máxima verossimilhança (*maximum likelihood*) para um ruído específico considerado, o qual depende da escolha da norma. A norma quadrática corresponde, por exemplo, à consideração de ruído branco Gaussiano.

Em geral o mínimo de $V_N(\theta)$ deve ser calculado de forma numérica, por impossibilidade de calculá-lo de forma analítica. A busca numérica desse mínimo é realizada por métodos de *otimização não linear*. Há um consenso geral que se deve utilizar o algoritmo de Gauss-Newton com regularização para problemas com mal condicionamento no Hessiano de modo fora de linha (*off line*), a não ser que a aplicação

⁵ De acordo com o Novo Dicionário da Língua Portuguesa Folha/Aurélio (1995) o termo "podadura" é um

exija um método recursivo de estimativa em linha (*on line*), como por exemplo no Controle Adaptativo.

O algoritmo básico de busca, válido para norma quadrática, envolve a busca iterativa do mínimo local na direção descendente a partir do ponto de partida ou atual:

$$\hat{\theta}^{(i+1)} = \hat{\theta}^{(i)} - \mu_i R_i^{-1} \nabla \hat{f}_i \quad 2 - 50$$

onde há três elementos importantes:

- μ_i , tamanho do passo;
- $\nabla \hat{f}_i$, uma estimativa do gradiente $V'_N(\hat{\theta}^{(i)})$;
- R_i , uma matriz que modifica a direção da busca;

A base do método de busca local é o cálculo do gradiente:

$$V'_N(\theta) = \frac{-1}{N} \sum_{t=1}^N [y(t) - g(\varphi(t), \theta)] h(\varphi(t), \theta) \quad 2 - 51$$

onde:

$$h(\varphi(t), \theta) = \frac{\partial}{\partial \theta} g(\varphi(t), \theta) \quad 2 - 52$$

(um vetor $m \times 1$)

No entanto, sabe-se que o método de busca do mínimo somente pelo gradiente é ineficiente, especialmente para problemas mal condicionados próximos do ponto de mínimo. Utiliza-se na prática uma modificação deste, chamada de direção de busca de Newton:

$$R^{-1}(\theta) V'_N(\theta) \quad 2 - 53$$

onde:

$$\begin{aligned} R(\theta) &= V''_N(\theta) \\ &= \frac{1}{N} \sum_{t=1}^N h(\varphi(t), \theta) h^T(\varphi(t), \theta) + \frac{1}{N} \sum_{t=1}^N [y(t) - g(\varphi(t), \theta)] \times \frac{\partial^2}{\partial \theta^2} g(\varphi(t), \theta) \end{aligned} \quad 2 - 54$$

Percebe-se que o método da direção de Newton requer o cálculo da segunda derivada. Também, longe do ponto de mínimo, $R(\theta)$ necessita ser positivo e semi-definido. Existem

vários métodos de cálculo de R_i , tais como:

- **direção do gradiente:**

$$R_i = I \quad 2 - 55$$

- **direção de Gauss-Newton:**

$$R_i = H_i = \frac{1}{N} \sum_{t=1}^N h(\varphi(t), \hat{\theta}^{(i)}) h^T(\varphi(t), \hat{\theta}^{(i)}) \quad 2 - 56$$

- **direção de Levenberg-Marquardt:**

$$R_i = H_i + \delta I \quad 2 - 57$$

- **direção do gradiente conjugado:** a direção é construída a partir de uma sequência de estimativa do gradiente. Este método tem sido usado com sucesso em redes neurais, sendo que o cálculo do Hessiano é feito por uma aproximação, sendo por isso também chamado de *método de quase-Newton*.

A literatura recomenda a utilização do método de busca da direção de Gauss-Newton, sempre que possível. Para problemas mal condicionados, o método de Levenberg-Marquardt é recomendado. De modo ideal, o tamanho do passo μ_i deve ser igual a 1. Na prática, vários valores de passo são testados até que o novo valor do parâmetro estimado forneça um menor valor no critério de ajuste.

No método genérico descrito pela Eq. 2 - 50, a única quantidade que depende da estrutura do modelo é o seu gradiente. Em redes neurais, o método mais comum de calcular o gradiente é o da *retropropagação do erro* ("error back-propagation"). Esse método é bem genérico e pode ser aplicado a estruturas com várias camadas e com diferentes funções geratrizes. Na verdade, ele pode ser aplicado a qualquer modelo na forma de rede e pode ser descrito como sendo a aplicação da regra da cadeia aplicada à expressão descrita pela Eq. 2 - 31, com um inteligente re-uso dos resultados intermediários necessários em vários locais do algoritmo. Para modelos de construção "ridge", descritos anteriormente, onde β_i é um vetor de parâmetros (e.g., redes neurais), a única complicação com o algoritmo é acompanhar todos os índices. β_i pode ser também uma matriz, como no caso dos modelos "wavelets".

Para o caso das redes recorrentes, o cálculo do gradiente é um pouco mais

complexo. O gradiente em um instante de tempo depende não somente do vetor regressor, mas também do gradiente do intervalo de tempo anterior.

O método de minimização do critério dado pela Eq. 2 - 41, estabelece que as iterações devem prosseguir até que não haja mais mudanças significativas nos parâmetros. Entretanto, quando se apresenta o modelo estimado ao conjunto de teste, em geral se verifica que após determinada iteração, o erro em relação ao teste começa a aumentar, apesar do erro de treinamento diminuir. Este fenômeno é chamado de "*overtraining*". Isto ocorre porque os parâmetros que possuem uma importância mais significativa sobre o modelo são ajustados mais rapidamente no início, sendo uma consequência do cálculo do gradiente. Quando estes já não estão sendo modificados de modo significativo, os parâmetros que são menos importantes passam a ser ajustados de modo significativo. Isto quer dizer que o modelo final possuirá "maior número de parâmetros" (ou menor parâmetro de regularização), ou uma maior estrutura de modelo. Assim, o conceito de "*overtraining*" é equivalente ao de "*overfitting*", descrito anteriormente.

Para se evitar que a estimativa resulte na localização de um mínimo local existem algumas estratégias descritas na literatura, chamadas de métodos de busca global, sendo as mais importantes: busca aleatória, reinício aleatório, "*simulated annealing*" e algoritmos genéticos.

MÉTODOS CONSTRUTIVOS. Na estrutura genérica de modelo descrita aqui (2 - 39) o vetor total de parâmetros θ é composto de duas partes diferentes: o parâmetro de coordenadas α_k de um lado e os parâmetros de dilatação e localização (β_k, γ_k) de outro lado. Se os parâmetros (β_k, γ_k) forem fixados, a minimização da Eq. 2 - 41 se transforma no problema linear dos quadrados mínimos. Neste caso há uma solução exata e não há iteração, posto que os valores de (β_k, γ_k) foram escolhidos de maneira eficiente. Entretanto, este procedimento é possível somente com um certo grupo de funções de base acompanhadas naturalmente dos parâmetros (β_k, γ_k) . Por exemplo, "*wavelets*" são muito apropriadas para aplicar tal método. Na verdade, mesmo em tal situação, a escolha de (β_k, γ_k) é freqüentemente influenciada (parcialmente) pelos dados observados. A escolha dos parâmetros (β_k, γ_k) a partir de um conjunto finito, que depende da escolha das funções de base e de conhecimento prévio da aplicação, baseada na observação dos dados é chamada de *método construtivo*. "*Wavelets*" constituem-se em uma classe muito interessante de

funções devido às suas propriedades especiais. Através da utilização das técnicas de encolhimento (*shrinking techniques*) tornam-se poderosos estimadores não lineares. No entanto, na prática são aplicáveis a problemas com pequeno número de regressores e dados razoavelmente distribuídos.

O conhecimento prévio que se possui acerca de um sistema a ser identificado pode ser incorporado de modo qualitativo no problema de identificação através da lógica nebulosa ("fuzzy logic"), resultando nos modelos nebulosos, que por sua vez podem ser acoplados com as informações quantitativas representadas em uma rede neural, por exemplo, resultando em modelos quali e quantitativos (e.g., "neurofuzzy"). Uma descrição deste procedimento está além dos objetivos deste trabalho e podem ser encontrados em referências tais como: SJÖBERG *et al.*, 1995 (esta referência traz também em suas conclusões várias recomendações práticas indispensáveis àqueles que desejam reduzir as possibilidades de frustração no processo de identificação de sistemas não lineares);

2.5 IDENTIFICAÇÃO DE SISTEMAS NÃO LINEARES UTILIZANDO REDES NEURAIS

2.5.1 IDENTIFICAÇÃO DE SISTEMAS DINÂMICOS

Após apresentar os conceitos e idéias básicas do procedimento de identificação de sistemas não lineares segundo uma visão unificada, apresentaremos em maiores detalhes o caso específico de identificação de sistemas utilizando redes neurais artificiais. O interesse aqui é na *identificação de sistemas dinâmicos*, tendo em vista a posterior utilização dos modelos identificados nas estratégias de controle que serão examinadas posteriormente.

Segundo BAUGHMAN e LIU (1995) a primeira aplicação reportada na literatura das redes neurais em Engenharia Química se deu em 1988 com o trabalho do professor David M. Himmelblau da Universidade do Texas em Austin, em co-autoria com seu aluno Josiah C. Hoskins. Nesse trabalho, foram aplicadas redes neurais no diagnóstico de falhas em um reator químico. Desde então, o número de aplicações desta técnica em Engenharia Química aumentou significativamente, principalmente na área de identificação e controle de processos. Embora a maioria dos estudos realizados até o momento concentram-se em investigações computacionais, muitas aplicações práticas começam a serem reportadas na literatura, mesmo a maioria em processos em pequena escala, sendo senso comum entre os investigadores da área que ainda há muito a ser feito em termos de simulações a fim de se consolidar a técnica antes que seja aplicada de modo generalizado na prática. A simulação

permite uma investigação rápida, segura, econômica e se o modelo dinâmico para simulação do processo for validado com confiabilidade, os resultados se aproximam muito daqueles obtidos em uma planta real. Embora o objetivo final seja a aplicação no processo real, a etapa de investigação por simulação torna o tempo de efetivação da técnica muito mais rápido, corrigindo procedimentos, induzindo o desenvolvimento teórico em certos pontos, dentre outros aspectos.

A identificação de sistemas (principalmente sistemas não lineares) utilizando redes neurais tem sido um dos assuntos mais explorados na literatura relativa à identificação de modelos nos últimos anos (com propósitos de controle ou não), com aplicações em praticamente todas as áreas do conhecimento humano que utilizam modelos matemáticos. Especificamente, a identificação de processos utilizando redes neurais começou a ser explorada com o trabalho de POLLARD *et al.* (1992).

Acredita-se que o largo emprego desta técnica só foi possível devido à certas características peculiares das redes neurais, tais como:

- potencial para modelar dinâmicas complexas como aquelas geralmente apresentadas pelos sistemas não lineares;
- as redes neurais podem ser treinadas facilmente (quando comparado com outras técnicas) utilizando dados históricos do processo em estudo;
- são facilmente aplicáveis à sistemas multivariáveis;
- possuem a habilidade de inferir regras gerais e extrair padrões típicos a partir de exemplos específicos e reconhecer o mapeamento entrada-saída a partir de dados de campo multi-dimensionais e complexos.

Tendo em vista a posterior aplicação do modelo identificado utilizando redes neurais em uma estratégia de controle avançado, o interesse aqui está na identificação de sistemas dinâmicos, ou seja, como a(s) saída(s) do sistema depende(m) da(s) entrada(s) e do tempo. Existem três procedimentos distintos para se identificar um sistema dinâmico utilizando redes neurais:

1. utilizando redes neurais cujos **neurônios** possuem **características dinâmicas**, em arquiteturas recorrentes onde os neurônios são interligados à frente e à ré de modo arbitrário e o conceito de camada tende a desaparecer (HUNT *et al.*, 1992); o exemplo

mais conhecido de redes dinâmicas são as redes de Hopfield; a dinâmica do processo é capturada por uma operação de diferenciação nos neurônios e a rede (ou o modelo) deve ser integrada ao longo do tempo para se obterem as saídas da mesma; o treinamento equivale a uma estimativa de parâmetros em um sistema de equações diferenciais ordinárias não lineares tornando esta etapa uma das mais cruciais neste tipo de arquitetura e que tem limitado sua aplicação; a vantagem desta arquitetura é o tamanho reduzido da rede necessária para capturar a dinâmica de sistemas complexos; seu emprego tem sido muito reduzido na área de identificação de sistemas dinâmicos (YOU e NIKOLAOU, 1993; SHAW *et al.*, 1997).

2. utilizando redes neurais com neurônios estáticos representando uma aproximação discreta do sistema dinâmico na forma de um modelo ARMAX, neste caso conhecido como modelo NARMAX (CHENG *et al.*, 1995); este procedimento será objeto de maiores detalhes nos itens que se seguem.
3. utilizando redes neurais com neurônios estáticos que estimam a derivada do modelo dinâmico de um sistema em relação ao tempo e por integração numérica calcula-se $y(t+1)$ a partir de $y(t)$ conhecido (THE MATHWORKS, 1998; HENRIQUE *et al.*, 2000).

Um dos maiores desafios no campo da identificação de sistemas é a capacidade dos procedimentos de identificação lidarem com processos que possuem parâmetros que variam no tempo. Quando o sistema em estudo é linear, a identificação pode ser realizada de modo recursivo, como já mostrado anteriormente, permitindo que o modelo seja constante ou periodicamente atualizado, encontrando aplicação direta nas técnicas de controle adaptativo. Entretanto, para sistema não lineares a tarefa de identificação em linha está longe de ser completada, mas já se mostrou que é possível realizá-la utilizando redes neurais em conjunto com técnicas recursivas (NIKRAVESH *et al.*, 1996).

2.5.2 PROCEDIMENTO E MODELOS DE IDENTIFICAÇÃO

NARENDRA e PARTHASARATHY (1990) propuseram uma metodologia de identificação de sistemas não lineares baseada em quatro classes de modelos, para processos com uma entrada e uma saída (SISO). O procedimento não perde a generalidade pois pode ser facilmente estendido para processos com múltiplas entradas e múltiplas saídas (MIMO), ou variantes destes dois casos limites. Os autores citam que tais modelos foram

motivados por aqueles que têm sido utilizados na literatura de sistemas adaptativos para identificação e controle de sistemas lineares e podem ser considerados uma generalização dos mesmos. Vale a pena ressaltar que o procedimento de partir de algo conhecido, bem estabelecido, para uma problemática mais generalizante, tem-se mostrado um bom procedimento na área de controle automático de processos e deve ser utilizado sempre que possível. Assim, por analogia, caminha-se dentro de seguros limites conhecidos, ampliando resultados e conclusões para novos casos.

Os quatro modelos citados anteriormente, para processos discretos no tempo (ou amostrados), podem ser descritos pelas seguintes equações diferenças não lineares:

MODELO I:

$$y_p(k+1) = \sum_{i=0}^{n-1} \alpha_i y_p(k-i) + g[u(k), u(k-1), \dots, u(k-m+1)] \quad 2 - 58$$

MODELO II:

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1)] + \sum_{i=0}^{m-1} \beta_i u(k-i) \quad 2 - 59$$

MODELO III:

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1)] + g[u(k), u(k-1), \dots, u(k-m+1)] \quad 2 - 60$$

MODELO IV:

$$y_p(k+1) = f[y_p(k), y_p(k-1), \dots, y_p(k-n+1); u(k), u(k-1), \dots, u(k-m+1)] \quad 2 - 61$$

onde $[u(k), y_p(k)]$ representam o par entrada-saída do processo SISO no tempo k , e $m \leq n$. As funções f e g são assumidas como sendo diferenciáveis em seus argumentos. Em todos os quatro modelos a saída da planta no tempo $k+1$ depende tanto de seus n valores passados da saída $y_p(k-i)$ ($i=0,1,\dots,n-1$) quanto dos m valores passados da entrada $u(k-j)$ ($j=0,1,\dots,m-1$). A dependência dos valores passados da saída é linear no Modelo I, enquanto que no Modelo II a dependência dos valores passados da entrada é assumida como sendo linear. No Modelo III assume-se uma separação no mapeamento não linear. O Modelo IV é o mais genérico e engloba todos os demais. Embora o Modelo IV seja suficiente para representar qualquer sistema não linear, em casos particulares a

utilização dos Modelos I-III pode-se revelar como melhor alternativa, visto que são mais facilmente manipuláveis de modo analítico. Além desse fato, o Modelo III é necessário em certa estratégia de controle não linear, daí seu interesse aqui.

Tendo em consideração os Modelos I-IV descritos anteriormente, redes neurais artificiais podem ser utilizadas para modelarem as funções não lineares f e g . Além disto, o mapeamento entrada-saída a ser representado por tais modelos necessita possuir saídas finitas ("bounded outputs"), conseqüentemente com o modelo tendo também esta característica. No caso do Modelo I isto implica que as raízes da equação característica $z^n - \alpha_0 z^{n-1} - \dots - \alpha_{n-2} z - \alpha_{n-1} = 0$ devem estar localizadas no interior do círculo unitário. Nos outros três casos não há tal equação algébrica simples. Percebe-se que o estudo das propriedades de estabilidade de redes recorrentes contendo redes multicamadas representa uma importante área a ser considerada para pesquisas.

O procedimento de identificação consiste no ajuste dos parâmetros da rede neural no modelo usando um método conveniente, baseado no erro entre a saída da planta e do modelo. No entanto, algumas precauções necessitam ser tomadas a fim de se garantir o sucesso (ou pelo menos maximizar a possibilidade) do procedimento de convergência dos parâmetros do modelo de identificação aos seus valores desejados.

Em geral, os parâmetros de um modelo dinâmico, independente da forma de sua representação matemática, podem ser estimados através de dois procedimentos diferentes: identificação em série-paralelo e identificação em paralelo.




Figura 2 - 1 – Método de identificação em série-paralelo ou em paralelo. (z^{-1} é o operador deslocamento a ré)

A Fig. 2-1 ilustra esse dois procedimentos de identificação.

No caso em que o pivô conecta com "sp", a saída do processo é alimentada diretamente no modelo de predição durante a identificação (treinamento no jargão utilizado em redes neurais). Esse método é conhecido como *método de identificação série-paralelo*, pois o modelo está em paralelo e ao mesmo tempo em série com o processo. Em contrapartida, quando o pivô está conectado com "p", a saída do processo não é alimentada no modelo para a predição de tal saída por parte do modelo. Nesse caso, o modelo está completamente em paralelo com a planta e tem-se o *método de identificação em paralelo*.

Os exemplos que se seguem ilustram melhor os procedimentos de identificação (NARENDRA e PARTHASARATHY, 1990):

1. *Modelo de identificação em Paralelo*. A Fig. 2 - 2(a) mostra uma planta a qual pode ser representada pelo Modelo I (Eq. 2 - 58), com $n = 2$ e $m = 1$. Para identificar a planta, pode-se assumir a estrutura do modelo de identificação mostrado na Fig. 2-2(a) e descrito pela equação:

$$\hat{y}(k+1) = \hat{\alpha}_0 \hat{y}_p(k) + \hat{\alpha}_1 \hat{y}_p(k-1) + N[u(k)] \quad 2 - 62$$

A identificação envolve a estimativa dos parâmetros $\hat{\alpha}_i$ e dos parâmetros da rede neural (pesos e tendências – "bias") utilizando retropropagação do erro (ou outro método conveniente), levando em conta o erro $e(k)$ entre a saída do modelo $\hat{y}_p(k)$ e a saída real $y_p(k)$. A estabilidade do modelo de identificação não pode ser garantida nem provada pois saídas da rede neural são retroalimentadas no modelo e, portanto, a convergência do processo de identificação não pode ser demonstrada.

Modelo de identificação em Série-Paralelo. Em contraste com o modelo em paralelo, o modelo em série-paralelo descrito anteriormente a saída da planta é que é utilizada na retroalimentação no modelo de identificação, como mostrado na Fig. 2-2(b). Isto implica em um modelo na forma:

$$\hat{y}_p(k+1) = \hat{\alpha}_0 y_p(k) + \hat{\alpha}_1 y_p(k-1) + N[u(k)] \quad 2 - 63$$




Figura 2 - 2 – (a) modelo de identificação paralela. (b) modelo de identificação série-paralelo.

Para o caso mais genérico representado pelo Modelo IV, o processo de identificação pode ser esquematizado como mostrado na Fig. 2-3. TDL ("Tapped Delay Line") nessa figura significa um vetor que possui como saída, entradas deslocadas no tempo.

Os valores passados da entrada e da saída da planta formam o vetor de entrada para a rede neural cuja saída $\hat{y}_p(k)$ corresponde à estimativa da saída da planta em qualquer instante de tempo k . Desde que a planta seja estável (estabilidade BIBO), todos os sinais utilizados no procedimento de identificação são finitos. Ademais, como não há laço de retropropagação no modelo, retropropagação estática pode ser utilizada para ajustar os pesos da rede, método este que requer menos esforço computacional do que a

retropropagação dinâmica.




Figura 2 - 3 – Identificação de plantas não lineares utilizando redes neurais (série-paralelo).

Além dos modelos discretos apresentados anteriormente, há também modelos contínuos para representar sistemas dinâmicos, na forma de equações diferenciais.

$$\begin{aligned} \frac{dx(t)}{dt} &\stackrel{\Delta}{=} \dot{x}(t) = \Phi[x(t), u(t)] & t \in \mathfrak{R}^+ \\ y(t) &= \Psi[x(t)] \end{aligned} \quad 2 - 64$$

onde $x(t) \stackrel{\Delta}{=} [x_1(t), x_2(t), \dots, x_n(t)]^T$, $u(t) \stackrel{\Delta}{=} [u_1(t), u_2(t), \dots, u_p(t)]^T$ e

$y(t) \stackrel{\Delta}{=} [y_1(t), y_2(t), \dots, y_m(t)]^T$ representam p entradas, m saídas de ordem n do sistema. A Eq. 2 - 64 é uma representação na forma *espaço entrada-saída* ("input-state-output"). Para o caso de sistemas discretos (ou amostrados) a forma matemática contínua anterior ganha o formato de equações diferenças na forma espaço de estados:

$$\begin{aligned} x(k+1) &= \Phi[x(k), u(k)] \\ y(k) &= \Psi[x(k)] \end{aligned} \quad 2 - 65$$

onde $u(\cdot)$, $x(\cdot)$ e $y(\cdot)$ são seqüências temporais discretas.

A proximidade da representação de um sistema não linear como o da 2 - 64 com os modelos fenomenológicos é evidente, dispensando um tratamento mais detalhado daqueles, por serem de maior familiaridade. Ademais, como o interesse aqui é o controle automático utilizando computador digital, a ênfase será nos modelos discretos, embora a

maioria dos processos químicos tenham característica contínua. Entretanto, parte da teoria do controle não linear está desenvolvida somente para sistemas contínuos. A partir desta constatação, há duas possibilidades:

- (1) desenvolvimento de uma teoria de controle não linear completa para sistemas discretos ou amostrados;
- (2) maior investigação acerca dos controladores contínuos.

A segunda alternativa encontra eco no campo das redes neurais, haja vista o grande interesse no desenvolvimento de "hardware" que implemente as estruturas conectivas das redes de modo analógico, aumentando imensamente a velocidade de processamento destes modelos "físicos" ou "palpáveis", contrapondo aos algoritmos matemáticos utilizados nas implementações computacionais digitais.

2.5.3 SELEÇÃO DA ESTRUTURA DO MODELO

Assumindo que um conjunto de dados experimentais que descreve o sistema a ser identificado em toda a região de operação de acordo com uma frequência adequada na forma

$$Z^N = \{[u(t), y(t)] \mid t = 1, \dots, N\} \quad 2 - 66$$

está disponível, o próximo passo é a seleção de uma estrutura de modelo. Esta é uma das etapas mais cruciais na identificação de sistemas não lineares, utilizando redes neurais ou qualquer outra estratégia. Além de ser necessário escolher o conjunto de regressores, necessita-se também definir a arquitetura da rede. A recomendação é selecionar o regressor inspirando-se na identificação de sistemas lineares e então determinar a melhor arquitetura possível da rede neural a partir do regressor selecionado.

As estruturas mais comuns encontradas na literatura são:

NNARX

Vetor regressor:

$$\varphi(t) = [y(t-1), \dots, y(t-n_a), u(t-n_k), \dots, u(t-n_b-n_k+1)]^T \quad 2 - 67$$

Preditor:

$$\hat{y}(t|\theta) = \hat{y}(t|t-1, \theta) = g(\varphi(t), \theta) \quad 2 - 68$$

NNOE

Vetor regressor:

$$\varphi(t) = [\hat{y}(t-1|\theta), \dots, \hat{y}(t-n_a|\theta), u(t-n_k), \dots, u(t-n_b-n_k+1)]^T \quad 2 - 69$$

Preditor:

$$\hat{y}(t|\theta) = g(\varphi(t), \theta) \quad 2 - 70$$

NNARMAX1

Vetor regressor:

$$\varphi(t) = [y(t-1), \dots, y(t-n_a), u(t-n_k), \dots, u(t-n_b-n_k+1), \varepsilon(t-1), \dots, \varepsilon(t-n_c)]^T = \begin{bmatrix} \varphi_l^T(t), \varepsilon(t-1), \dots, \varepsilon(t-n_c) \end{bmatrix}^T \quad 2 - 71$$

onde $\varepsilon(t)$ é o erro de predição: $\varepsilon(t) = y(t) - \hat{y}(t|\theta)$

Preditor:

$$\hat{y}(t|\theta) = g(\varphi_l(t), \theta) + C(q^{-1})\varepsilon(t) \quad 2 - 72$$

onde C é um polinômio no operador deslocamento a ré:

$$C(q^{-1}) = 1 + c_1 q^{-1} + \dots + c_n q^{-n_C}$$

NNARMAX2

Vetor regressor:

$$\varphi(t) = [y(t-1), \dots, y(t-n_a), u(t-n_k), \dots, u(t-n_b-n_k+1), \varepsilon(t-1), \dots, \varepsilon(t-n_c)]^T \quad 2 - 73$$

Preditor:

$$\hat{y}(t|\theta) = g(\varphi(t), \theta)$$

NNSSIF (State Space Innovations Form)

Vetor regressor:

$$\varphi(t) = [\hat{x}^T(t|\theta) \quad u^T(t) \quad \varepsilon^T(t|\theta)]^T \quad 2 - 74$$

Preditor:

$$\begin{aligned} \hat{x}(t+1|\theta) &= g(\varphi(t), \theta) \\ \hat{y}(t|\theta) &= C(\theta)\hat{x}(t|\theta) \end{aligned} \quad 2 - 75$$

Somente o modelo NNARX possui um preditor sem realimentação. Todos os outros tipos de modelos possuem realimentação através da escolha do regressor, o que em terminologia de redes neurais significa que a rede se torna recorrente: entradas futuras da rede irão depender das saídas presentes e atuais da rede. Como já citado anteriormente, isto pode levar à instabilidade em certas regiões de operação e até o momento não há uma abordagem teórica acerca da estabilidade do preditor. O modelo NNARMAX1 foi construído para se evitar tal problema pelo uso de um filtro linear MA ("Moving Average") com o propósito de filtrar resíduos passados. A regra heurística básica é utilizar o modelo NNARX sempre que possível!

Após selecionar a estrutura do modelo, o próximo passo é a escolha do número de sinais passados a serem utilizados como regressores (número de entradas, número de saídas e atraso do tempo associado com o processo), i.e., escolher a **ordem do modelo**. Na ausência de ruídos ou quando estes forem pequenos (situação na qual as funções do tipo *nnarx* sempre são recomendáveis), existem dois métodos utilizados para determinar a ordem do modelo (BOMBERGER e SEBORG, 1998):

1. *Método dos números de Lipschitz*. Método proposto por He e Asada em 1993 baseado na propriedade de continuidade das funções que representam os modelos de entrada-saída, sendo que não depende do uso de qualquer método de aproximação ou estrutura de modelo em particular. Foi desenvolvido para sistemas determinísticos, porém pode ser também aplicado a sistemas com baixo nível de ruídos.
2. *Método da falsa vizinhança mais próxima ("false nearest neighbors")*. Método desenvolvido para determinação da dimensão mínima associada, o número de observações deslocadas no tempo necessárias para modelar o comportamento dinâmico do sistema, para sistemas caóticos. Baseia-se no "desdobramento" do espaço de dados até que o número de falsos vizinhos mais próximos, dados que aparecem próximos a outros somente porque a dimensão do espaço de dados é muito pequena, tende a zero.

Entretanto, estas metodologias nem sempre são concordantes e nem seus resultados totalmente conclusivos. Porém, pode-se obter resultados bem razoáveis utilizando-as, para muitos casos. Não se pode perder de vista que **sempre** é melhor ter suficiente "insight" físico acerca do sistema a ser modelado a fim de se escolher a ordem do modelo de modo conveniente.

Do ponto de vista de aplicação em controle de processos, a identificação de sistemas não lineares atende a dois propósitos específicos (HUNT *et al.*, 1992): a modelagem preditiva (ou à frente – "forward") e a modelagem inversa. Estes dois casos serão detalhados em seguida.

1. *Modelagem preditiva.* É o procedimento de treinar uma rede neural para representar o comportamento à frente de um sistema (um ou mais passos à frente), tendo portanto o modelo uma característica preditiva. Constitui-se na metodologia apresentada anteriormente, onde o modelo a ser estimado é colocado em série ou em série-paralelo com o processo a ser identificado. A estimativa dá-se pelo clássico método de aprendizado supervisionado no qual o "professor" (i.e., o sistema) provê os valores alvo (i.e., as saídas) diretamente ao aprendiz (i.e., o modelo).
2. *Modelagem inversa.* O objetivo aqui é encontrar um modelo que identifique o sistema a ser controlado de modo inverso, ou seja, dada a saída requerida do sistema (*set point*), o modelo matemático fornecerá o valor da entrada a ser aplicada no sistema de modo a se obter a saída desejada. Na verdade, a diferença em relação à modelagem preditiva é unicamente na construção do regressor. A identificação (ou o treinamento da rede) pode se dar de modo direto (chamado de *método de treinamento inverso direto*) ou de modo indireto (chamado de *método de treinamento especializado*). No primeiro caso o modelo a ser estimado é colocado em série com o sistema a ser identificado, com as saídas do sistema sendo realimentadas à entrada do modelo. Um sinal de entrada é utilizado para excitar o sistema e este é comparado com a saída da rede, através do erro que é uma diferença entre ambos. O erro é utilizado para ajustar os parâmetros da rede. Assim, a rede (ou modelo matemático) "aprende" a gerar entradas para o sistema (saídas da rede) que levam este a determinadas saídas (que serão as entradas da rede), representando assim o comportamento inverso do sistema. No segundo caso, o modelo a ser estimado também é colocado em série com o processo a ser identificado. Porém, a entrada para o modelo é um sinal independente (sinal de referência), sendo este comparado com a saída do sistema, gerando um erro, que por sua vez é utilizado para o ajuste dos parâmetros do modelo. Uma variação deste método consiste em utilizar uma outra rede neural previamente treinada para simular o comportamento do sistema. Este procedimento traz vantagens quando as saídas do sistema são portadoras de altos níveis de ruídos, quando se dispõe de poucos dados experimentais da planta, ou quando a

planta está sendo representada por um modelo fenomenológico complexo, que requer alto esforço computacional para ser resolvido, aumentando assim demasiado o tempo de treinamento do modelo inverso. Cabe ressaltar que neste caso o modelo inverso aprende o comportamento inverso do modelo utilizado, o qual pode divergir de modo significativo ou não do sistema real, dependendo da qualidade do modelo utilizado.

No procedimento de modelagem inversa, necessita-se do conhecimento da saída o sistema um passo à frente $y^p(t+1)$. Porém este valor não é conhecido quando se realiza o aprendizado em linha. Esta dificuldade pode ser contornada substituindo o valor $y^p(t+1)$ pelo valor do sinal de referência correspondente $r(t+1)$, o qual é assumido como sendo conhecido neste instante de tempo t . Deste modo, a relação entrada-saída não linear que modelará o comportamento inverso do sistema terá a forma genérica:

$$u(t) = f^{-1} \left[y^p(t), \dots, y^p(t-n+1), r(t+1); u(t-1), \dots, u(t-m+1) \right]$$

ou seja, o modelo inverso recebe como entradas as saídas do sistema atual e passadas, o sinal de treinamento (referência) e os valores passados das entradas do sistema.

2.5.4 MODELOS NEURAIS HÍBRIDOS

Apesar de ainda não utilizados para fins de controle, acredita-se que os modelos que combinam o conhecimento prévio do sistema na forma de equações fenomenológicas com a modelagem de aspectos desconhecidos através do aprendizado a partir de dados históricos utilizando redes neurais, reunindo assim as vantagens de ambos os paradigmas de modelagem e identificação, culminando nos chamados modelos híbridos, venham a ter grande importância em áreas tais como estimativa em linha de medidas difíceis de serem realizadas a partir de medidas secundárias, otimização em linha, controle automático, detecção de falhas, dentre outras, em um futuro próximo.

O trabalho pioneiro de PSICHOGIOS e UNGAR (1992) continua sendo uma referência básica até hoje quando o assunto é a modelagem híbrida utilizando modelos fenomenológicos e redes neurais. Estes pesquisadores propuseram uma metodologia na qual uma rede neural é treinada e utilizada em paralelo com o modelo fenomenológico, conforme ilustrado pela Fig. 2-4, na qual a rede neural estima os parâmetros $\mathbf{p}$ do processo, os quais são utilizados como entrada para o modelo fenomenológico. A maior dificuldade está no treinamento da rede, já que não se conhece *a priori* um conjunto padrão de valores de $\mathbf{p}$ para realizar o treinamento. Este é efetuado a partir do erro entre a saída do modelo

fenomenológico e aquela desejada (e conhecida), ou seja, admite-se que o erro na estimativa dos parâmetros p do modelo pela rede seja proporcional ao erro final do modelo e assim pode-se utilizar este último erro para retropropagá-lo através da rede a fim de se estimar os parâmetros desta (ajuste dos pesos).




Figura 2 - 4 – Modelo híbrido com rede neural.

Uma variante da metodologia esquematizada pela Fig. 2-4 é utilizar a rede neural para estimar o erro entre o modelo fenomenológico e o sistema, ou seja, neste caso a rede é utilizada para compensar o erro entre o processo real e o modelo disponível.

O potencial de aplicação dos modelos híbridos nos processos de interesse da Engenharia Química é grande, pois muitas áreas tais como a bioengenharia (PSICHOGIOS e UNGAR, 1992; FU e BARFORD, 1996; CHEN *et al.*, 2000; SILVA *et al.*, 2000), a área de processamento de alimentos (STUART *et al.*, 1997; FONSECA *et al.*, 2000; KAMINSKI e TOMCZAK, 2000), os reatores químicos (AGUIAR e MACIEL FILHO, 2001), dentre outras, possuem muito fenômenos pouco modelados matematicamente até o momento, fazendo destes fenômenos fortes candidatos à modelagem do tipo "caixa preta" utilizando o ajuste de redes neurais, que em conjunto com o modelo fenomenológico (modelo "caixa branca"), resulta no modelo híbrido (modelo "caixa cinza").

2.5.5 SIMPLIFICAÇÃO E CRITÉRIOS DE VALIDAÇÃO DO MODELO IDENTIFICADO

Como já foi mencionado anteriormente, estudos mostraram que uma rede neural com uma camada intermediária e com um número suficiente de neurônios nessa camada pode representar qualquer função não linear, com precisão arbitrária. Ou seja, a fim de

aumentar a precisão da representação, freqüentemente o identificador aumenta de modo correspondente o número de neurônios da rede, as vezes aumentando também o número de camadas intermediárias, resultando assim em redes de maior complexidade. O principal problema de redes complexas é a tendência destas em ajustar de modo excessivo os dados apresentados e perder a capacidade de generalização, como já foi discutido anteriormente. Além deste fato, a etapa de treinamento se torna mais difícil tanto do ponto de vista computacional (dependendo de maior esforço para os cálculos), quanto do ponto de vista matemático ou a localização dos mínimos em superfícies dimensionalmente superiores, aumentando a quantidade de mínimos locais.

O procedimento comum descrito na literatura é iniciar a identificação com uma estrutura "superdimensionada" da rede, ou seja, com um número grande de neurônios na camada intermediária e após a etapa de treinamento, realizar a poda das redundâncias e conexões desnecessárias. Isto resultará em redes mais compactas, ditas "parcimoniosas"⁶. Os métodos mais usuais de poda em redes neurais são chamados de OBS (*Optimal Brain Surgeon*) e OBD (*Optimal Brain Damage*). Ambos os métodos utilizam uma medida da "saliência" de um peso através da estimativa da segunda derivada do erro de saída da rede E com relação àquele peso. Perturba-se o peso em estudo e mede-se em seguida a mudança ocorrida no erro E na saída da rede. A poda é realizada de modo iterativo, isto é, treina-se a rede para um nível de erro razoável, calcula-se a "saliência", apagam-se os pesos com "saliências" pequenas e treina-se a rede novamente. O método de poda pode ser aplicado a redes estáticas e dinâmicas.

BHAT e McAVOY (1992) propuseram um algoritmo denominado por estes autores de *Algoritmo StripNet* o qual consiste em se definir um critério de ajuste (por exemplo, o PSE – *Predicted Squared Error*) e proceder a um método iterativo no qual os pesos que não contribuem na minimização do erro (chamados pesos redundantes), segundo o critério de ajuste adequado, tendem automaticamente a zero e são então retirados da rede.

HENRIQUE *et al.* (2000) propuseram um método aplicado em redes neurais "feedforward" utilizando a técnica dos mínimos quadrados ortogonais, chamado pelos autores de OLS (*Orthogonal Least-Squares*). O método proposto se mostrou bastante eficiente na determinação de pesos sinápticos, tendências (*bias*), unidades internas (*hidden*

⁶ Parcimonioso: Adj. parco, econômico, simples (em inglês *parcimonious*).

nodes) e entradas da rede desnecessários. Os resultados foram comparados com técnicas clássicas de poda como OBD e OBS, sendo o método proposto computacionalmente muito mais eficiente. O estudo foi realizado utilizando um reator de pH simulado e experimental (identificação dinâmica e estática), sendo as redes podadas resultantes dos diferentes métodos bem similares. O estudo experimental envolveu a utilização de medidas portadoras de ruídos e a capacidade do método de ajuste e poda de lidarem com esta situação.

Existem vários critérios de avaliação do grau de ajuste de um modelo a um conjunto de dados experimentais. Tal avaliação envolve em geral um método estatístico, sendo os mais comuns os que se seguem:

- coeficiente de correlação múltipla corrigido (r_A^2);
- erro de predição final (FPE – *Final Prediction Error*);
- critério de informação de Akaike (AIC – *Akaike's Information Criterion*);
- lei de Kinchin do critério logarítmico iterativo (LILC – *Kinchin's law of iterated logarithm criterion*);
- critérios de informação Bayesiana (*The Bayesian information criteria*).

Com exceção do primeiro critério, todos os demais avaliam o compromisso entre o tamanho do modelo, determinado pelo número de parâmetros, e a precisão deste, determinada por uma função de perda.

Na área de identificação de sistemas o método mais comum de validação do modelo identificado é a investigação dos resíduos (erros preditos) através da validação cruzada realizada no conjunto de teste, ou seja, uma parte dos dados experimentais de identificação que foram previamente separados e não foram utilizados na etapa de treinamento. É comum verificar a função de auto-correlação dos resíduos e a função de correlação cruzada entre as entradas e os resíduos. Um histograma mostrando a distribuição dos resíduos também pode ser bastante útil na avaliação destes. Uma quantificação do grau de ajuste pode ser feita através do parâmetro NSSE avaliado no conjunto de teste. Este parâmetro pode ser visto como sendo uma estimativa do erro de generalização e não pode ser muito grande quando comparado com o erro de treinamento, pois neste caso há a suspeita de que a rede está ajustando de modo excessivo os dados de treinamento. Se um conjunto de teste não estiver disponível, um erro médio de generalização pode ser estimado a partir do conjunto de

treinamento somente utilizando o erro de predição final de Akaike (FPE). Mesmo que o conjunto de teste seja disponível, o parâmetro FPE fornece algumas informações importantes.

Segundo NØRGAARD (2000b) a inspeção visual do gráfico comparando as predições com as medidas reais é provavelmente a ferramenta de validação mais importante. Entretanto, necessita-se de um pouco de cuidado na avaliação de predições um passo a frente (*one-step ahead prediction*) pois freqüentemente esta se mostra visualmente muito precisa, mesmo que o modelo estimado esteja muito longe daquele modelo "verdadeiro". Isto ocorre principalmente quando o sistema é amostrado de modo rápido comparado com sua dinâmica mais rápida. LJUNG (1987) recomenda que se faça uma simulação pura do modelo a partir de uma seqüência de controle somente, sem utilizar as saídas observadas.

Uma outra metodologia utilizada na validação do modelo estimado é aquela que utiliza os *modelos do erro* que são descrições explícitas do erro do modelo. Segundo LJUNG (1999), um modelo do erro está implicitamente presente na maioria dos métodos de validação. Entretanto, os métodos tradicionais de validação do modelo consistem essencialmente de um teste no qual se avalia o quanto a região de confiança do modelo do erro contém o modelo zero. A utilização explícita dos modelos do erro permitem uma melhor visualização das possíveis deficiências do modelo nominal, permitindo que o modelo estimado seja aceito mesmo nos casos onde o modelo do erro não contém o modelo de ordem zero. Do mesmo modo, baseado no modelo do erro, pode-se rejeitar um modelo que havia previamente passado nos testes convencionais de validação do mesmo.

2.6 CONCLUSÕES

Neste Capítulo foram apresentados os principais procedimentos de identificação de sistemas lineares e não lineares, segundo uma visão unificada. Mostrou-se que a identificação pode ser realizada utilizando-se modelos de diferentes graus de complexidade, significado físico, etc., a partir de um apropriado conjunto de dados experimentais de entrada e saída do sistema. Neste contexto, as redes neurais artificiais estáticas com várias camadas têm sido largamente utilizadas na identificação de sistemas não lineares com relativo sucesso.

O comportamento dinâmico do sistema pode ser adquirido utilizando tais redes neurais alimentadas com dados atuais e passados das entradas e saídas do sistema. Um campo promissor na identificação é a utilização das redes neurais acopladas com modelos fenomenológicos, resultando nos chamados modelos híbridos.

Capítulo 3

CONTROLE NÃO LINEAR DE PROCESSOS QUÍMICOS

3 CONTROLE NÃO LINEAR DE PROCESSOS QUÍMICOS

3.1 INTRODUÇÃO

É praticamente senso comum entre aqueles que atuam na área de controle automático de processos que a característica mais desafiadora ao sucesso do sistema de controle é a presença de não linearidades inerentes no processo. Isto porque a presença de não linearidades introduz características dinâmicas complexas de difícil tratamento do ponto de vista matemático, dificultando o desenvolvimento de uma sistemática apoiada em ferramentas de análise e síntese de sistemas em malha aberta e fechada, tais as amplamente desenvolvidas para sistemas lineares na segunda metade do Século XX.

Entretanto, a primeira tentativa foi aplicar a teoria de controle linear aos processos não lineares, já que a teoria de controle linear (técnicas de projeto e análise) foi a primeira teoria de controle a ser desenvolvida de modo mais ou menos completo. Dentre outras vantagens apresentadas pelo controle linear estão a possibilidade de solução analítica do seu equacionamento, levando a provas rigorosas de estabilidade e desempenho em malha fechada, sem contar o pequeno esforço computacional requerido na solução demandada. Sistemas fracamente não lineares podem ser controlados com relativo êxito utilizando técnicas de controle linear (e.g., controle adaptativo), o que sustentou por algum tempo a possibilidade de se aplicar somente esta teoria de controle aos sistemas não lineares.

No entanto, a falha da teoria de controle linear quando aplicada a sistemas altamente não lineares, aliada ao desenvolvimento da teoria de controle não linear, somado aos avanços em "hardware" na eletrônica digital, permitiram que técnicas de controle não linear começassem a ser implementadas com sucesso, embora muito ainda há que ser feito nesta área até que seu emprego ganhe a confiança tanto daqueles que a utilizam como campo de pesquisa, quanto daqueles que detêm o desafio de estabilizar plantas não lineares nas unidades industriais.

Neste capítulo, serão revisadas as principais estratégias de controle desenvolvidas para sistemas não lineares, com ênfase na utilização das redes neurais artificiais como controladores ou como modelo de controle. A utilização das redes neurais em controle pode ser classificada em três categorias, segundo BAUGHMAN e LIU (1995):

1. *Controle direto por rede (Direct network control)*: envolve o treinamento de uma rede neural que aprende a mimetizar (imitar) o comportamento de um controlador existente, em geral um controlador por retroalimentação do erro entre a variável de saída e o valor desejado (*set point*). BAUGHMAN e LIU (1995) descrevem um controlador comercial (*Intelligent Arc Furnace Controller*) desenvolvido segundo este esquema geral com o objetivo de otimizar a posição dos eletrodos do arco elétrico em fornos de manufatura de aço, segundo os autores citados, com enorme sucesso na indústria metalúrgica. Neste caso, a vantagem em utilizar um controlador direto por rede neural está no fato de que o processo é variante no tempo, complexo, com dinâmica não linear e possui três eletrodos que resultam em uma dinâmica com alto grau de interação entre eles. Tradicionalmente o sistema era controlado por três malhas de controle independentes, que resultavam em comportamento pobre, devido à interação existente nas mesmas e a impossibilidade do desacoplamento destas na análise do sistema ocasionada pelas não linearidades. Uma rede neural foi então treinada para aprender o comportamento simultâneo dos três eletrodos, sendo permanentemente atualizada a partir de dados operacionais, de modo adaptativo.

2. *Controle inverso por rede (Inverse network control)*: envolve o treinamento de uma rede que descreva o modelo inverso de um processo, isto é, que prediz a(s) entrada(s) necessária para produzir a(s) saída(s) desejadas (*set points*) de um processo. O controlador assim obtido pode ser utilizado operando individualmente (método não aconselhável, segundo a literatura) ou posto em paralelo com um controlador convencional de modo a melhorar o desempenho deste último. O treinamento do controlador por modelo inverso pode ser direto ou especializado. Os detalhes deste procedimento serão analisados mais especificamente em item posterior deste capítulo.

3. *Controle indireto por rede (Indirect network control)*: envolve o treinamento de uma rede neural que servirá como modelo de um processo (para o caso dos controladores baseados em modelo), ou para determinar os *set points* de um controlador local (para o caso de um controlador supervisório), afetando indiretamente o processo a ser controlado. BAUGHMAN e LIU (1995) citam uma divisão clássica do controle baseado em modelo em duas categorias: (i) Procedimento de síntese direta: a resposta de saída descrita é especificada na forma de uma trajetória de referência, e o modelo do processo sintetiza diretamente a ação de controle necessária para que a saída do processo siga uma

trajetória de modo exato: Controle de síntese direta (DSC), Controle por modelo interno (IMC) e Controle por modelo genérico (GMC); (ii) Procedimento de otimização: a resposta de saída desejada é especificada na forma de uma função objetivo e o modelo do processo é usado para derivar a ação de controle requerida para minimizar (ou maximizar) esta função objetivo. A otimização pode incluir também restrições operacionais. Principais técnicas: Controle preditivo baseado em modelo (MPC) e Controle ótimo (OC). Algumas destas estratégias serão objeto de estudo nos demais itens deste capítulo. O controle indireto é atualmente o uso mais freqüente das redes neurais no controle de processos, sendo o controle preditivo baseado em modelo (MPC) a estratégia de maior interesse, seguido pelo controle por modelo interno (IMC).

Muitas aplicações utilizando redes neurais em controle de processos têm sido reportadas na literatura. Seria impossível aqui detalhá-las, porém há bons artigos de revisão (ou livros) que podem ser consultados para maiores detalhes, tais como: BAUGHMAN e LIU (1995); HUSSAIN (1999); ASSIS e MACIEL FILHO (2001).

O procedimento adotado no desenvolvimento deste capítulo será o de ressaltar o estado da arte, as vantagens e desvantagens de cada estratégia de controle para sistemas não lineares, com ênfase naquelas que utilizam redes neurais, como já citado anteriormente, e as principais aplicações relatadas na literatura. A teoria será apresentada de modo mais resumido possível e somente destacará os pontos mais importantes que permitirão um melhor acompanhamento dos capítulos seguintes, pois a teoria de controle não linear é complexa, utiliza conceitos de álgebra avançada, e a teoria de controle preditivo não linear geralmente emprega técnicas de otimização com restrição. A respeito destas estratégias de controle existem vários excelentes livros-textos (BAUGHMAN e LIU, 1995; HENSON e SEBORG, 1997) e tutoriais (HUNT *et al.*, 1992; KRAVARIS E KANTOR, 1990a; 1990b) que a apresentam de modo rigoroso e outros que serão citados no desenvolvimento do presente capítulo.

3.2 CARACTERÍSTICAS E MODELOS DOS PROCESSOS NÃO LINEARES

Algumas características apresentadas pelos processos químicos (também pelos bioquímicos, petroquímicos, etc.) dificultam o controle automático dos mesmos, dentre as quais (BEQUETTE, 1991):

- presença de não linearidades;

- interações multivariáveis entre as variáveis controladas e manipuladas;
- variáveis de estado não mensuráveis;
- perturbações frequentes e não mensuráveis;
- processos distribuídos e de alta ordem;
- parâmetros incertos e variando no tempo;
- restrições nas variáveis manipuladas, saídas e estados;
- tempo morto nas entradas e atraso nas medidas;

Com exceção da primeira característica, as demais também podem ocorrer em sistemas lineares, dificultando o controle destes. Ressalta aqui o fato de que os esforços recentes em pesquisa têm se concentrado no desenvolvimento de técnicas de controle que sejam capazes de lidar com essas características citadas anteriormente. O Controle Adaptativo (SEBORG *et al.*, 1986; ÅSTRÖM e WITTENMARK, 1995) foi desenvolvido para lidar com sistemas não lineares através da linearização do modelo que os descrevem, assumindo que o sistema poderia ser representado por diversas regiões lineares de operação, assim como para lidar com sistemas com parâmetros variando no tempo (ASSIS, 1996). As técnicas de projeto de sistemas de controle robusto foram desenvolvidas para superar o problema da incerteza no modelo. O Controle com Modelo Interno (IMC - *Internal Model Control*) foi desenvolvido de tal modo a se permitir um procedimento transparente de projeto de sistemas de controle para processos. Vários estudos analisaram o efeito do tempo morto em processos nos sistemas multivariáveis, sendo o clássico preditor de Smith uma das primeiras tentativas de modelar e considerar esta característica na etapa de projeto do controlador. Alguns pesquisadores, dentre os quais o renomado D. Seborg, da Universidade da Califórnia, detêm a opinião de que as áreas mais promissoras e que ainda têm muito em aberto em controle de processos são: o controle de sistemas não lineares e o controle adaptativo.

Neste ponto, distingue-se o controle de sistemas não lineares do controle não linear de sistemas. No primeiro caso tem-se a aplicação de qualquer teoria de controle, linear ou não linear, aos sistemas não lineares; no segundo caso tem-se a aplicação de técnicas especialmente desenvolvidas para lidarem com sistemas não lineares pois tais técnicas utilizam de modo explícito um modelo não linear do processo, em geral um

modelo identificado de modo fora de linha (*off line*) ou de modo em linha (*on line*), no projeto e implementação do sistema de controle. O objetivo da presente tese é explorar o segundo caso, sendo algumas técnicas do primeiro caso também utilizadas com finalidades de comparação de resultados.

Uma parte importante em qualquer projeto de sistema de controle é o desenvolvimento de uma representação matemática do processo. Mesmo se uma técnica de controle linear está sendo utilizada, a verificação do desempenho desta é feita normalmente utilizando simulação de um modelo detalhado do processo, geralmente um modelo fenomenológico e não linear. O procedimento de modelagem do processo não é de nenhum modo trivial, sendo a parte que mais consome tempo e investimentos (75% dos recursos, segundo HUSSAIN, 1999) em desenvolvimento de estratégias de controle baseadas em modelos do processo. A complexidade do modelo deve ser limitada pelos futuros usos do mesmo, já que esta afetará drasticamente a obtenção de soluções a partir do modelo. Hoje, já começa a nascer uma preocupação de que se deve levar em consideração o controle automático na etapa de projeto do processo, pois algumas das mais importantes decisões que afetam o controle são tomadas durante as etapas de operação em planta-piloto e em estado estacionário.

Uma grande quantidade de processos de interesse no âmbito da Engenharia Química pode ser representada com relativo grau de fidelidade por um conjunto de equações algébrico-diferenciais ordinárias de primeira ordem. Matematicamente, a representação é:

$$\frac{dx}{dt} = f(x, u(t - \theta), p, l) \quad 3 - 1$$

equação do modelo dinâmico

$$g_1(x, u, p) = 0 \quad 3 - 2$$

relações algébricas de equilíbrio, cinéticas, etc.

$$y = g_2(x(t - \phi)) \quad 3 - 3$$

relações dos estados de saída

onde:

x = variáveis de estado;

u = variáveis manipuladas;

p = parâmetros;

l = perturbações na carga (medidas ou não medidas);

y = saídas ou variáveis medidas

θ = tempo morto entre as variáveis manipuladas e as variáveis de estados;

ϕ = tempo morto entre as variáveis de estado e as medidas.

Notar que esta formulação também pode ser utilizada para sistemas a parâmetros distribuídos desde que um modelo agrupado (*lumped model*) seja derivado pela discretização das equações diferenciais parciais, formando um sistema de equações diferenciais ordinárias.

Tendo em vista a posterior aplicação na teoria de controle não linear, o modelo de um processo genérico não linear pode ser escrito de modo alternativo como sendo:

$$\begin{aligned}\dot{\mathbf{x}}(t) &= \mathbf{F}(\mathbf{x}(t), \mathbf{u}(t)) \\ \mathbf{y}(t) &= \mathbf{G}(\mathbf{x}(t))\end{aligned}\quad 3 - 4$$

Onde $\mathbf{x}$, $\mathbf{u}$ e $\mathbf{y}$ são os vetores de estado, entrada e saída de dimensões n , m e r , respectivamente. A função vetor $\mathbf{F}$ mapeia o domínio $\mathbb{R}^n \times \mathbb{R}^m$ dentro da faixa $\mathbb{R}^n$, enquanto que a função vetor $\mathbf{G}$ mapeia $\mathbb{R}^n$ a $\mathbb{R}^r$.

Alguns casos particulares do modelo genérico descrito anteriormente são importantes para a teoria de controle não linear: modelo de controle afim; modelo bilinear.

1. *Modelo de controle afim*: Muitos modelos advindos da modelagem fenomenológica podem ser representados segundo a estrutura:

$$\mathbf{F}(\mathbf{x}, \mathbf{u}) = \mathbf{f}(\mathbf{x}) + \mathbf{\Gamma}(\mathbf{x})\mathbf{u}\quad 3 - 5$$

na qual a função vetor não linear $\mathbf{F}(\mathbf{x}, \mathbf{u})$ foi dividida em duas partes aditivas, sendo apenas uma delas dependente do vetor de entrada $\mathbf{u}$, na forma linear.

2. *Modelo bilinear*: Para problemas com entrada simples (i.e., $\mathbf{u}(t) = u(t)$ é um escalar), e se o modelo de controle afim for restrito para $\mathbf{f}(\mathbf{x}) = \mathbf{A}\mathbf{x}$ e $\mathbf{\Gamma}(\mathbf{x}) = \mathbf{N}\mathbf{x} + \mathbf{b}$, o resultado é um modelo bilinear. $\mathbf{A}$ e $\mathbf{N}$ são matrizes $n \times m$ e $\mathbf{b}$ é um vetor de dimensão n .

Esta classe de modelos pode ser estendida para problemas com entradas múltiplas (MIMO), considerando termos múltiplos aditivos para a entrada:

$$\Gamma(\mathbf{x})\mathbf{u} = \sum_{i=1}^m u_i(t) \mathbf{N}_i \mathbf{x} + \mathbf{B}\mathbf{u} \quad 3 - 6$$

onde $\mathbf{B}$ é uma matriz de dimensão $n \times m$. Notar que quando $\mathbf{N}_i = \mathbf{0}$, para todos os i 's, o modelo bilinear se reduz à forma bastante conhecida do modelo linear.

3.3 ESTRATÉGIAS DE CONTROLE PARA SISTEMAS NÃO LINEARES

3.3.1 CONTROLE LINEAR

A primeira tentativa de controlar um sistema não linear foi a aplicação dos controladores desenvolvidos para sistemas lineares sendo o controlador Proporcional-Integral-Derivativo (PID) o de aplicação mais antiga e o mais comumente ainda utilizado nos processos industriais. O controlador PID toma uma ação de controle proporcional ao erro, à integral do erro e à derivada do erro, sendo o erro a diferença entre o valor desejado para a saída (*set point*) e o valor atual da saída.

$$u(t) = u_o + k_c \left[e(t) + \frac{1}{\tau_I} \int_0^t e(t) dt + \tau_D \frac{de(t)}{dt} \right] \quad 3 - 7$$

$$e(t) = y_{sp}(t) - y(t) \quad 3 - 8$$

Este controlador se aplica somente a processos com uma entrada e uma saída (SISO) e não leva em consideração a presença de tempo morto ou atraso na medida. Seu largo emprego deve-se principalmente à sua simplicidade, já que pode ser implementado facilmente através de miniprocessadores digitais ou nos sistemas de aquisição e transmissão de dados lógicos programáveis (CLP's) bastante utilizados hoje. Neste caso, a versão digital do controlador PID é utilizada, encontrada através das aproximações (SEBORG *et al.*, 1989):

$$\int_0^t e(t) dt \approx \sum_{k=1}^n e_k \Delta t \quad 3 - 9$$

$$\frac{de}{dt} \approx \frac{e_n - e_{n-1}}{\Delta t} \quad 3 - 10$$

resultando em:

$$u_n = \bar{u} + K_C \left[e_n + \frac{\Delta t}{\tau_I} \sum_{k=1}^n e_k + \frac{\tau_D}{\Delta t} (e_n - e_{n-1}) \right] \quad 3 - 11$$

que é conhecido como lei de controle PID digital na forma da *posição*. Para evitar: calcular o somatório na expressão anterior; especificar o valor de referência $\bar{u}$; *reset windup*, o algoritmo conhecido como forma da velocidade é usualmente adotado para a forma digital da lei PID de controle:

$$\Delta u_n = K_C \left[(e_n - e_{n-1}) + \frac{\Delta t}{\tau_I} e_n + \frac{\tau_D}{\Delta t} (e_n - 2e_{n-1} + e_{n-2}) \right] \quad 3 - 12$$

Em estudos de novas estratégias de controle, o controlador PID constitui-se em uma referência para efeitos de comparação de desempenho. Segundo BEQUETTE (1991), outro fator que dará ao controlador PID uma longa vida é o controle cascata: virtualmente todos os controladores avançados estão em cascata com controladores de vazão, os quais são eficientemente implementados com o controlador PID. Além disso, muitas malhas têm dois controladores em cascata. Por exemplo, muitas estratégias de controle avançado para reatores de mistura contínuos e exotérmicos (CSTRs) assumem que a temperatura do refrigerante é a variável manipulada. Isto significa que a estratégia avançada muda o *set point* do controlador da temperatura de refrigeração, o qual por sua vez muda o *set point* do controlador de vazão de refrigerante.

A principal desvantagem do controlador PID (as vezes pode se tornar a principal vantagem) é o fato de que ele não se baseia em um modelo do processo, não levando assim em consideração informações conhecidas da dinâmica deste que muito poderiam contribuir na melhoria do seu desempenho.

SØRENSEN (1994) apresentou uma proposta de utilização de redes neurais segundo a teoria de controle linear, aplicada à sistemas não lineares, baseada na linearização do modelo matemático do processo, descrito por uma rede neural, em torno do ponto de operação corrente. A idéia se resume em assumir um modelo determinístico do processo da forma:

$$y(t) = g(y(t-1), \dots, y(t-n), u(t-d), \dots, u(t-d-m)) \quad 3 - 13$$

obtido através da etapa de identificação do processo. O "estado" $\varphi(t)$ é então introduzido como um vetor composto dos argumentos da função g:

$$\varphi(t) = [y(t-1) \cdots y(t-n) \quad u(t-d) \cdots u(t-d-m)]^T \quad 3 - 14$$

No tempo $t = \tau$ lineariza-se g em torno do estado corrente $\varphi(t)$ para obter o modelo aproximado:

$$\tilde{y}(t) = -a_1 \tilde{y}(t-1) - \dots - a_n \tilde{y}(t-n) + b_0 \tilde{u}(t-d) + \dots + b_m \tilde{u}(t-d-m) \quad 3 - 15$$

onde:

$$a_i = \left. \frac{-\partial g(\varphi(t))}{\partial y(t-i)} \right|_{\varphi(t)=\varphi(\tau)} \quad 3 - 16$$

$$b_i = \left. \frac{\partial g(\varphi(t))}{\partial u(t-d-i)} \right|_{\varphi(t)=\varphi(\tau)} \quad 3 - 17$$

e

$$\tilde{y}(t-i) = y(t-i) - y(\tau-i) \quad 3 - 18$$

$$\tilde{u}(t-i) = u(t-i) - u(\tau-i) \quad 3 - 19$$

Separando a porção da expressão contendo componentes do vetor de estados corrente, um modelo aproximado pode ser escrito como:

$$y(t) = (1 - A(q^{-1}))y(t) + q^{-d}B(q^{-1})u(t) + \zeta(\tau) \quad 3 - 20$$

onde o termo $\zeta(\tau)$ é dado por:

$$\zeta(\tau) = y(\tau) + a_1 y(\tau-1) + \dots + a_n y(\tau-n) - b_0 u(\tau-d) - \dots - b_m u(\tau-d-m) \quad 3 - 21$$

e

$$A(q^{-1}) = 1 + a_1 q^{-1} + \dots + a_n q^{-n} \quad 3 - 22$$

$$B(q^{-1}) = b_0 + b_1 q^{-1} + \dots + b_m q^{-m} \quad 3 - 23$$

O modelo aproximado pode ser interpretado como sendo um modelo linear afetado por uma perturbação adicional DC, $\zeta(\tau)$, dependendo do ponto operacional.

O princípio descrito anteriormente se aplica facilmente no projeto de sistemas de controle. A idéia geral é ilustrada na Figura 3-1 (NØRGAARD, 2000b). Observa-se que o controlador não é adaptativo por definição pois este não é projetado tendo em mente

parâmetros que variam no tempo. Entretanto, a idéia é muito próxima do regulador auto-ajustável indireto (*indirect Self Tuning Regulator*) examinado por ÅSTRÖM e WITTENMARK (1995). Ao invés de se estimar de modo recursivo o modelo linear em cada intervalo de amostragem, o controlador aqui examinado é projetado tendo como base um modelo linear que é extraído do modelo não linear (rede neural). O método é então um tipo de controle com ganho planejado (*gain scheduling control*) onde o planejamento é infinito. Percebe-se que o controlador em si não depende diretamente da rede neural treinada.

Uma vez disponível o modelo linear extraído do modelo não linear descrito pela rede neural, diversos tipos diferentes de projeto de controladores podem ser implementados, tais como:

- alocação de pólos com todos os zeros cancelados. Os zeros são cancelados e o controlador é projetado de tal forma que o sistema em malha fechada siga uma função de transferência previamente escolhida;




Figura 3-1 – Linearização instantânea aplicada no projeto de sistemas de controle.

- alocação de pólos sem zeros cancelados. Apenas os pólos do sistema em malha fechada são movidos às localizações prescritas;

• variância mínima. Baseado na consideração de que o desvio, $\zeta(\tau)$, seja ruído branco: $\zeta(\tau) = \frac{e(\tau)}{\Delta}$, o controlador de variância mínima é implementado. Este controlador é projetado de modo a minimizar o seguinte critério:

$$J_d(t, u(t)) = E \left\{ \left[y(t+d) - W(q^{-1})r(t) \right]^2 + \delta [\Delta u(t)]^2 \middle| I_t \right\} \quad 3 - 24$$

onde I_t especifica as informações coletadas até o tempo t :

$$I_t = \{y(t), y(t-1), \dots, y(0), u(t-1), \dots, u(0)\} \quad 3 - 25$$

sendo a Equação de Diophantine resolvida em linha.

Os controladores por alocação de pólos e de variância mínima são geralmente implementados segundo a estrutura RST, na qual

$$R(q^{-1})y(t) = T(q^{-1})r(t) - S(q^{-1})y(t) \quad 3 - 26$$

conforme mostrado na Figura 3-2.




Figura 3-2 – Controlador RST.

Do mesmo modo o controlador preditivo generalizado - **GPC** (*Generalized Predictive Controller*) reside na idéia de minimizar em cada iteração o seguinte critério:

$$J_s(t, U(t)) = \sum_{i=N_1}^{N_2} [r(t+i) - \hat{y}(t+i)]^2 + \rho \sum_{i=1}^{N_u} [\Delta u(t+i-1)] \quad 3 - 27$$

com relação os N_u futuros sinais de controle:

$$U(t) = [u(t) \dots u(t+N_u-1)]^T \quad 3 - 28$$

e sujeito à restrição:

$$\Delta u(t+i) = 0, \quad N_u \leq i \leq N_2 - d \quad 3 - 29$$

N_1 denota o horizonte mínimo de predição (ou custo), N_2 o horizonte máximo de predição e N_u o horizonte (máximo) de controle; ρ é um fator peso que penaliza variações na ação de controle; $\zeta(\tau)$ é um modelo do ruído branco e as predições das saídas futuras, $\hat{y}(t+i)$, são determinadas como predições de variância mínima. O problema de otimização, o qual necessita ser resolvido a cada instante de amostragem pois o modelo linear é obtido com esta periodicidade, resulta em uma seqüência de sinais futuros de controle, $U(t)$. Desta seqüência, somente o primeiro componente $u(t)$ é implementado no processo e calcula-se nova seqüência para o próximo instante de tempo.

3.3.2 ESTRATÉGIAS ESPECIAIS E "AD HOC"

A presença de não linearidades em processos foi desde o início do advento do emprego dos controladores reconhecida como sendo uma das principais variáveis que levavam a um desempenho pobre dos controladores utilizados. A primeira tentativa de contornar este problema foi modificar o *hardware* envolvido nos sistemas de controle a fim de eliminar as não linearidades, como por exemplo utilização de válvulas de igual percentagem ou extratores de raiz quadrada. Posteriormente esta idéia foi estendida na utilização de transformação de variáveis: em colunas de destilação, a utilização do logaritmo da composição como variável medida lineariza a dinâmica do processo com relação a tal variável. Diversas variantes são descritas na literatura (BEQUETTE, 1991).

LUYBEN (1989) propôs uma modificação no controlador PID de tal modo que a constante k_C variava em função do erro, criando assim um controlador não linear:

$$k_C = k_{CO} * (1 + b * |e(t)|) \quad 3 - 30$$

A vantagem desta estratégia é que o controlador se torna insensível aos ruídos na medida quando a saída está próxima ao *set point*. A ação de controle se torna mais vigorosa à medida que a saída se distancia do *set point*.

Uma outra maneira de lidar com as não linearidades é utilizar vários conjuntos de constantes do controlador (PID ou outro qualquer) previamente ajustados para regiões específicas de operação. Este procedimento é conhecido como Controlador de Parâmetros Programados (*Parameter Scheduled Controller*) e foi inicialmente proposto dentro do Controle Adaptativo, mas a idéia foi estendida para outras estratégias de controle. MEGAN e COOPER (1995) propuseram um controlador preditivo DMC, com características adaptativas, utilizando redes neurais. Considerou-se o caso com duas entradas e duas saídas

(MIMO) e utilizou-se duas redes neurais *vector quantizing* (VQN) que monitoram continuamente as entradas e saídas do processo para detectar a presença de perturbações nestas, sendo a matriz dinâmica do controle DMC adaptada todas as vezes que são detectadas alterações. O caso estudo considerado foi uma coluna de destilação e os resultados foram aceitáveis.

Quando às perturbações que afetam um processo são mensuráveis e um modelo matemático do mesmo é disponível, uma das maneiras mais eficientes de minimizar o impacto de tais perturbações no processo é a utilização do controle antecipativo (*Feedforward Control*). Quando acoplado com o controle de retroalimentação (*Feedback Control*), pode levar a excelentes resultados, eliminando a presença de possíveis *off sets*.

3.3.3 CONTROLE COM MODELO INVERSO DO PROCESSO

O procedimento de controle denominado "modelo interno de controle" ou IMC (*Internal Model Control*) foi proposto no início da década de 1980 pelos pesquisadores Garcia e Morari e inicialmente utilizava um modelo linear do processo como modelo de controle, utilizado em paralelo com o processo real (chamado de modelo antecipativo ou *forward model*). Um outro modelo descrevendo o comportamento inverso do sistema é utilizado para calcular a entrada (chamado de modelo inverso ou *inverse model*). O esquema genérico desta estratégia de controle é mostrado na Fig. 3-3 (SEBORG *et al.*, 1989) e se aplica tanto a sistemas lineares quanto àqueles não lineares. Percebe-se também que o controle IMC une em uma mesma estrutura características de retroalimentação (*feedback*) e antecipação (*feedforward*).




Figura 3-3 – Estrutura do Controle com Modelo Interno (IMC).

A diferença entre as saídas do sistema (y) e do modelo em paralelo (y_m) é retroalimentada e constitui-se na entrada do subsistema controlador. O filtro antes do controlador é utilizado para introduzir uma robustez desejada e para dar ao sistema de controle características de servo-mecanismo (*tracking response*). O controlador do tipo IMC se aplica somente a sistemas que são estáveis em malha aberta e garante a estabilidade dos mesmos em malha fechada.

A utilização de redes neurais em estrutura IMC é intuitiva e mostrada na Fig. 3-4 (NØRGAARD, 2000b). Pode-se treinar uma rede para representar a dinâmica inversa de um processo (g_c) e outra para a dinâmica direta (g_m) (HUNT e SBARBARO, 1991). O sinal de controle é sintetizado através de uma combinação de um modelo antecipativo (*forward*) do processo com um modelo inverso. Uma propriedade atrativa desta técnica de projeto é que ela provê uma resposta livre de *off-set*, independente do processo ser afetado ou não por uma perturbação constante.




Figura 3-4 – Controle por modelo inverso utilizando redes neurais.

Em muitos casos apresentados na literatura utilizando este procedimento o sinal controle u é calculado numericamente a partir da inversão de um modelo neural do processo (*forward model*) em cada intervalo utilizando o método de Newton ou os métodos de substituição baseados no teorema da contração do mapeamento. A primeira derivada com relação à entrada de controle pode ser calculada através destas técnicas pelo método usual da retropropagação. Estas técnicas numéricas demandam, entretanto, alto esforço computacional, são muito sensíveis às estimativas iniciais e não necessariamente conduzem a uma solução global e única, podendo acarretar sérios problemas de estabilidade do

controlador. Uma alternativa é utilizar uma rede neural treinada fora de linha para aprender a dinâmica inversa do modelo, diretamente a partir do sinal de entrada do sistema e do sinal de saída, sem cálculos numéricos.

O segundo procedimento leva diretamente ao controle inverso direto utilizando redes neurais. Conceitualmente, o mais básico controlador baseado em redes neurais é aquele que utiliza o modelo inverso do processo como controlador. O princípio de funcionamento desta técnica de controle é a consideração de que o processo possa ser descrito por (NØRGAARD, 2000b):

$$y(t+1) = g(y(t), \dots, y(t-n+1), u(t), \dots, u(t-m)) \quad 3 - 31$$

e que uma rede neural possa ser treinada para representar o modelo inverso do processo:

$$\hat{u}(t) = \hat{g}^{-1}(y(t+1), y(t), \dots, y(t-n+1), u(t-1), u(t-m)) \quad 3 - 32$$

Onde $\hat{u}(t)$ representa a entrada do processo predita pela ANN.

O modelo inverso é então aplicado como um controlador do processo pela inserção da saída desejada, a referência $r(t+1)$, no lugar da saída $y(t+1)$. A Fig. 3-5 ilustra esta técnica de controle. Nesta estratégia de controle, antes de se considerar o sistema de controle em si, um modelo inverso do processo necessita ser treinado. Para tanto, dispõe-se de várias técnicas, sendo que as duas mais usuais são: treinamento generalizado e treinamento especializado (PSALTIS *et al.*, 1988). No modo de treinamento generalizado, a rede neural é treinada de maneira fora de linha (*off line*) de modo a minimizar o seguinte critério de desempenho (θ representa os pesos da rede neural):

$$J_1(\theta) = \sum_{t=1}^N (u(t) - \hat{u}(t))^2 \quad 3 - 33$$

Um experimento é então realizado e um conjunto de padrões correspondentes às entradas e saídas do sistema é gerado e armazenado.




Figura 3-5 – Controle inverso direto utilizando RNAs. Geralmente há falta de robustez do controlador nesta configuração.

A rede utilizada como controlador pode também ser permanentemente treinada em linha de modo a minimizar alguma função custo previamente definida, resultando no **controle adaptativo que utiliza redes neurais** (chamado de controle adaptativo direto por HUSSAIN, 1999).

Já o treinamento especializado é realizado em linha (*on line*) e está intimamente relacionado com o controle adaptativo com modelo de referência (chamado de controle adaptativo indireto por HUSSAIN, 1999), sendo que neste caso há mais robustez por parte do controlador (devido à retroalimentação da saída), desde que o modelo do processo seja confiável. A idéia é minimizar o critério de desempenho, ou a função custo:

$$J(\theta) = \sum_t (y_m(t) - y(t))^2 \quad 3 - 34$$

onde:

y_m representa a trajetória de referência, sendo dada por:

$$y_m(t) = \frac{q^{-1} B_m(q)}{A_m(q)} r(t) \quad 3 - 35$$

A_m e B_m são polinômios, q é o operador deslocamento a ré e $r(t)$ a trajetória de referência. O modelo inverso é obtido se $A_m = B_m = 1$, mas frequentemente uma versão utilizando filtro passa-baixo é preferida. Neste caso, o resultado será algo como um modelo inverso suavizado (*detuned* ou *smoothed*).

O treinamento especializado é dito como sendo direcionado ao propósito (*goal directed*), pois ao contrário do treinamento generalizado, esta técnica tenta treinar a rede de tal modo que a saída do processo siga a referência de perto. Por esta razão, o treinamento especializado é particularmente indicado na otimização do controlador para uma trajetória de referência pré-estabelecida.

O treinamento especializado necessita ser realizado em linha (*on-line*) e, portanto, é bem mais difícil de ser implementado na prática do que o treinamento generalizado. Antes do treinamento do modelo inverso do processo, um modelo antecipativo (*forward*) do processo necessita ser treinado, pois este modelo é requerido pelo esquema de controle, conforme pode ser visto na Figura 3-6 (NØRGAARD, 2000b).

Ao contrário do treinamento generalizado, o esquema de controle que utiliza o treinamento especializado realiza o projeto do controlador baseado em um modelo do processo. Maiores detalhes acerca desta técnica podem ser encontrados em HUNT & SBARBARO (1991). O treinamento especializado é mais complexo de ser implementado pois utiliza atualização recursiva dos pesos da rede atuando como controlador, quando comparado com o treinamento generalizado e requer mais parâmetros de projeto.




Figura 3-6 – Diagrama do princípio do treinamento especializado.

KRISHNAPURA e JUTAN (2000) propuseram uma metodologia interessante na qual foi utilizada uma rede neural que possui apenas quatro parâmetros e é similar ao controlador clássico PID, sendo a rede atuando diretamente como controlador. Os autores consideram que no controle adaptativo convencional que utiliza redes neurais, há um grande número de parâmetros (pesos da rede) que necessitam ser modificados, o que não é uma tarefa trivial. Para realizar a retropropagação do erro da saída do processo, foi considerado uma rede aumentada, na qual foi incluída o processo, porém com parâmetros fixos. Deste modo, pode-se calcular com facilidade o Jacobiano e fazer a atualização somente dos parâmetros da rede aumentada relativos ao controlador, sendo a saída do processo forçada a seguir uma trajetória pré-estabelecida; a rede utilizada possui duas camadas e apenas um neurônio em cada uma; foram utilizadas entradas da rede: *set point*, saída do controlador e do processo, no intervalo de tempo anterior; o ajuste dos pesos foi feito através do treinamento especializado; o desempenho da rede foi testado com sucesso no controle de um reator CSTR linear e não linear e em um sistema de neutralização (ajuste de pH).

O uso de modelos inversos para controle por retroalimentação pode levar ao controlador do tipo *dead-beat*, o qual é indesejável em vários casos. Se um controlador PID tiver sido sintonizado previamente de modo a estabilizar um processo instável em malha aberta, um modelo inverso pode ser usado para prover um sinal antecipativo (*feedforward*) diretamente a partir da referência. Esta estratégia foi proposta por LEUNEN (1993) e SØRENSEN (1994) e é ilustrada na Figura 3-7.




Figura 3-7 - Esquema *feedforward* para otimização de um sistema de controle existente.

De modo geral, pode se dizer que uma vez que o modelo inverso do processo foi treinado, há diferentes maneiras de utilizá-lo para finalidades de controle: controle inverso direto; controle IMC e controle antecipativo.

3.3.4 GEOMETRIA DIFERENCIAL

Do mesmo modo que a análise e o projeto de controladores lineares podem ser realizados com ferramentas matemáticas tais como a transformada de Laplace e a álgebra linear, a geometria diferencial tem sido empregada nos últimos anos na análise e projeto de sistemas de controle não linear. Entretanto, a complexidade inerente dos sistemas não lineares torna o emprego dos métodos de geometria diferencial não raro tão complexos que os ganhos de sua aplicação são pequenos comparados aos esforços necessários para obtê-los. Mesmo assim, esta metodologia tem recebido bastante atenção do ponto de vista de investigação teórica pois como se esgotaram praticamente todos os campos de investigação em sistemas lineares a atenção dos pesquisadores se voltou para o estudo dos sistemas não lineares e tenta-se obter o mesmo sucesso na análise teórica obtida para os sistemas lineares que impulsionou muito a utilização destes na prática.

Uma visão geral dos métodos de controle geométricos pode ser encontrada em HENSON e SEBORG (1992) e no tutorial de KRAVARIS e KANTOR (1990a; 1990b). Mais recentemente HENSON e SEBORG (1997) editaram na forma de livro diversas contribuições que apresentam os princípios básicos das diferentes metodologias utilizadas em controle não linear, bem como inúmeras aplicações no âmbito da Engenharia de Processos, sendo dada maior ênfase aos aspectos práticos em detrimento a um tratamento teórico aprofundado, o que torna esta referência interessante para os que desejam se iniciar nas técnicas de controle não linear.

A maioria dos trabalhos empregando métodos de geometria diferencial são desenvolvidos para sistemas lineares na(s) entrada(s). A forma geral do modelo destes sistemas (para um sistema de entrada simples e saída simples) é:

$$\begin{aligned}\frac{dx}{dt} &= f(x) + g(x)u \\ y &= h(x)\end{aligned}\tag{3-36}$$

onde x é o vetor de estados, u é a entrada manipulada e y é a saída medida. Na análise de sistemas não lineares a álgebra matricial dos sistemas lineares é substituída pela álgebra de Lie. A derivada de Lie é definida como sendo:

$$L_f h(x) = \sum_{i=1}^n f_i(x) \frac{\partial h(x)}{\partial x_i} \quad 3 - 37$$

e pode ser interpretada como sendo a derivada direcional da função $h(x)$ na direção do vetor $f(x)$. A diferenciação de $h(x)$ em direção de $g(x)$ também pode ser realizada:

$$L_g L_f h(x) = \sum_{i=1}^n g_i(x) \frac{\partial (L_f h(x))}{\partial x_i} \quad 3 - 38$$

Do mesmo modo, derivadas de mais alta ordem podem ser obtidas como:

$$L_f^k h(x) = L_f [L_f^{k-1} h(x)] \quad 3 - 39$$

Sendo a *ordem relativa* de um sistema o último inteiro positivo r para o qual:

$$L_g L_f^{r-1} h(x) \neq 0 \quad 3 - 40$$

A ordem relativa representa o número de vezes que a saída y necessita ser diferenciada com relação ao tempo para recuperar a entrada u . Para modelos com função de transferência lineares, esta é a diferença na ordem dos polinômios do denominador e numerador.

Segundo BEQUETTE (1991), há três procedimentos distintos de projeto de transformações de retroalimentação de estados (*state feedback transformations*) utilizadas correntemente em controle de processos químicos: (1) linearização das equações de estado torna o modelo de estado linear entrada-estado, em malha fechada; (2) linearização entrada/saída torna a relação entrada-saída linear em malha fechada; (3) aproximação ou linearização parcial encontra transformações que linearizam o sistema para ordem 2 ou superior. Para classes restritas de sistemas, há a possibilidade de linearização total, ou seja, tornar o sistema linear tanto em relação aos estados quanto em relação à entrada/saída. Uma vez o sistema apresentando um comportamento linear em malha fechada, independente do método utilizado, emprega-se os métodos clássicos desenvolvidos para sistemas lineares para que sejam atingidos os objetivos de regulação (controle regulatório) ou supervisão (controle supervisório).

Em geral uma lei de compensação estática para controle por retroalimentação de estados lineares é escrita como sendo:

$$u = p(x) + q(x)v \quad 3 - 41$$

Linearização da equação de estado. Uma lei de compensação por retroalimentação de estados é encontrada de tal modo que a relação entre a entrada de referência, v , e a equação de estado dinâmica seja linear, após uma transformação de coordenadas, $\xi = T(x)$ e $v = T_{n+1}(x,u)$

$$\frac{d\xi}{dt} = A\xi + bv \quad 3 - 42$$

A lei de controle é comumente desenvolvida utilizando o método de alocação dos pólos, porém este método apresenta a desvantagem de que a alocação dos pólos em malha fechada não garante que o sistema de controle resultante será livre de *offset's*. Outra desvantagem é que um conjunto de equações diferenciais parciais necessita ser resolvido para determinar a transformação de variáveis; uma solução analítica somente é disponível em poucos e especiais casos.

Linearização entrada/saída (Controle de Linearização Global). Uma lei de compensação por retroalimentação de estados é encontrada de tal modo que a relação entre a entrada de referência, v , e a saída, y , seja linear

$$\begin{aligned} \frac{dx}{dt} &= [f(x) + g(x)p(x)] + g(x)q(x)v \\ y &= h(x) \end{aligned} \quad 3 - 43$$

A representação esquemática da estrutura de controle linearizante é apresentada na Figura 3-8.




Figura 3-8 – Estrutura do controle de linearização global.

A lei de compensação por retroalimentação de estados (r = ordem relativa) é:

$$u = \frac{v - \sum_{k=0}^r \beta_k L_f^k(h)}{\beta_r L_g L_f^{r-1} h(x)} \quad 3 - 44$$

que resulta em um comportamento linear na forma entrada/saída entre a saída y e a entrada de referência v

$$y(s) = \frac{1}{\beta_0 + \beta_1 s + \beta_2 s^2 + \dots + \beta_r s^r} v(s) \quad 3 - 45$$

Escolhendo um controlador linear com a função de transferência na forma

$$v(s) = \frac{\beta_0 + \beta_1 s + \beta_2 s^2 + \dots + \beta_r s^r}{(\epsilon s + 1)^r - 1} e(s) \quad 3 - 46$$

resulta em uma função de transferência em malha fechada criticamente amortecida:

$$y(s) = \frac{1}{(\epsilon s + 1)^r} y_{sp}(s) \quad 3 - 47$$

Um número importante de processos químicos possuem uma ordem relativa igual a 1; isto resulta em um processo em malha fechada de 1ª ordem. A principal desvantagem do procedimento de linearização entrada/saída é que ele só é aplicável a sistemas de fase mínima.

Linearização Aproximada. Envolve a procura de uma transformação de coordenadas e retroalimentação de estados que forma um sistema linear aproximado de ordem κ :

$$\frac{d\xi}{dt} = A\xi + bv + O(x, u)^{\kappa+1} \quad 3 - 48$$

onde ξ e v são os estados e entradas transformados.

Uma das maneiras de utilizar as redes neurais no controle não linear é treinar duas redes para representar a dinâmica do processo da seguinte forma (NØRGAARD, 2000b):

$$\begin{aligned} \hat{y}(t) = & f(y(t-1), \dots, y(t-n), u(t-2), \dots, u(t-m)) + \\ & g(y(t-1), \dots, y(t-n), u(t-2), \dots, u(t-m))u(t-1) \end{aligned} \quad 3 - 49$$

sendo f e g duas redes separadas. Uma lei de controle por retroalimentação linearizante do processo é obtida pelo cálculo da ação de controle dada por:

$$u(t) = \frac{w(t) - f(y(t), \dots, y(t-n+1), u(t-1), \dots, u(t-m+1))}{g(y(t), \dots, y(t-n+1), u(t-1), \dots, u(t-m+1))} \quad 3 - 50$$

selecionando de modo conveniente o controle virtual $w(t)$ como uma combinação linear apropriada de saídas passadas somadas a uma referência permite uma alocação arbitrária dos pólos em malha fechada. Do mesmo modo que o controlador por modelo de referência, a linearização por retroalimentação é o correspondente não linear ao método de alocação dos pólos com todos os zeros cancelados (ÅSTRÖM e WITTENMARK, 1995). O princípio desta metodologia é mostrado na Figura 3-9.




Figura 3-9 – Linearização por retroalimentação discreta, utilizando RNAs.

A dificuldade de se modelar com precisão os bioprocessos através de métodos fenomenológicos fazem desta classe de processos fortes candidatos ao controle utilizando redes neurais. BOSKOVIC e NARENDRA (1995) apresentaram extensa investigação de um processo fermentativo, não linear e com parâmetros variando no tempo e determinaram quando e por que uma rede neural necessitaria ser utilizada em sistemas dinâmicos complexos em preferência a outros controladores. Os autores argumentam que os controladores não lineares, para o caso estudo, apresentaram melhores resultados quando comparados com os lineares, porém requerem muita informação *a priori* acerca do processo; para evitar tal conhecimento, utilizaram uma rede

neural para realizar o mapeamento não linear inserida em uma lei de controle não linear, cujo objetivo é realizar a linearização entrada/saída do processo por retroalimentação; os pesos da rede foram ajustados em linha e testaram o desempenho de uma rede multicamada convencional e uma rede de funções de base radiais; testaram cinco controladores: não linear com modelo fixo; não linear adaptativo; linear adaptativo; não linear adaptativo com rede neural multicamada; não linear adaptativo com rede neural de base radial; finalmente, concluem que a utilização das redes neurais em processos fermentativos depende do desvio esperado dos parâmetros e condições iniciais; do erro tolerável; do conhecimento *a priori* das diferentes não linearidades e como estas são não raro desconhecidas, ou conhecidas apenas parcialmente, o controlador linear adaptativo e o não linear que utiliza rede neural são os mais indicados no controle de tais processos. Se precisão e robustez forem itens críticos, o controle que utiliza as redes neurais é preferível.

BRAAKE *et al.* (1998) utilizaram redes neurais para linearizar de forma exata (considera um modelo do processo na forma afim) e aproximada (considera um modelo não linear genérico que é linearizado em cada intervalo de tempo por série de Taylor), na forma entrada/saída, um processo fermentativo no qual o objetivo foi controlar a pressão do fermentador, sendo utilizados controladores de simples entrada e saída (SISO) e de múltipla entrada e saída simples (MISO), sendo que as investigações para o controlador SISO foram feitas experimentalmente e as para o controlador MISO por simulação computacional. Após a linearização do processo, utilizaram um controlador preditivo para controlar o sistema linear resultante. Os resultados foram muito bons para as diversas possibilidades consideradas. Um procedimento semelhante foi descrito por VILAÇA *et al.* (2000), sendo que a rede neural utilizada foi a de função de base radial, para modelar o processo, na forma afim. A rede neural modela a parte estática do modelo do processo e este deve ser integrado para recuperar a saída $y(t+1)$, procedimento que causa uma importante redução na dimensionalidade e estrutura da rede e evita a definição tediosa da estrutura das redes na forma de modelo ARMAX. O caso estudo considerado foi o reator CSTR com reação exotérmica e troca térmica.

GE *et al.* (1998) apresentaram uma metodologia para linearizar por retroalimentação, de forma aproximada, um sistema não linear, utilizando redes neurais multicamadas e linearização por geometria diferencial na forma entrada-saída. O método proposto se aplica a sistemas descritos por modelo não linear genérico, ou seja, não se

restringe os sistemas descritos por modelo na forma afim. A rede neural inserida na lei de controle é aplicada para reconstruir a entrada ideal IFLC (*Implicit Feedback Linearization Control*) para se alcançar uma linearização por retroalimentação aproximada, sendo seus pesos continuamente ajustados, levando o controlador final a ter um comportamento adaptativo. A lei de controle final, que atua sobre o sistema já linearizado, foi desenvolvida a partir da técnica de estabilidade de Lyapunov, sendo a saída forçada a seguir uma trajetória especificada de acordo com um modelo de referência pré determinado. A técnica proposta foi aplicada no controle de um reator de mistura CSTR com reação exotérmica e troca térmica, no qual a entrada de controle aparece de forma não linear. O objetivo de controle é controlar a concentração do reagente A na saída, manipulando a vazão de refrigerante. Os resultados foram comparados com o controlador clássico PI, sendo os obtidos com o controlador adaptativo aplicado ao sistema linearizado através de uma rede neural mostraram-se bem superiores aos obtidos com o controlador PI, em mudanças contínuas de *set points*.

Utilizando como caso-estudo o controle de um reator CSTR, com reação exotérmica e sistema de troca térmica, KAVCHAK e BUDMAN (1999) descreveram como melhorar o desempenho de adaptação em redes com função de base radial utilizadas na modelagem de sistemas não lineares através da seleção de uma dilatação ótima e apresentaram um algoritmo que permite adaptação simultânea da dilatação e pesos da rede. A rede considerada foi utilizada em um controlador não linear que lineariza a entrada/saída do processo, sintetizado para ser estável de acordo com o segundo critério de estabilidade de Lyapunov. Os resultados foram comparados com um controlador não linear ideal e concluíram que um processo operando sob o controlador proposto necessita de uma excitação persistente a fim de manter sua característica adaptativa, necessidade esta amplamente discutida na teoria de controle adaptativo de sistemas lineares.

3.3.5 SÍNTESE DE SISTEMAS DE REFERÊNCIA

As técnicas de síntese por sistemas de referência (RSS – *Reference System Synthesis*) utilizam um modelo do processo e uma resposta desejada deste em malha fechada (especificada através de um modelo de referência estável) para determinar a lei de controle por retroalimentação. Esta idéia é similar ao procedimento que tem sido utilizado para sistemas lineares discretos, o controlador de Dahlin, que especifica uma trajetória de

primeira ordem com tempo morto. Na técnica RSS, o modelo do processo é escrito como sendo:

$$\dot{x} = f(x, u, p, l) \quad 3 - 51$$

e a resposta desejada é especificada como sendo:

$$\dot{x}_r = f(x_{sp}, x, u, p, l) \quad 3 - 52$$

Um exemplo de uma resposta desejada que incorpora ação proporcional e integral é:

$$\dot{x}_r = k_c(x_{sp} - x) + \frac{k_c}{\tau_I} \int (x_{sp} - x) dt \quad 3 - 53$$

Uma função de controle:

$$u = k(x_{sp}, x, p, l) \quad 3 - 54$$

é encontrada de tal modo que o modelo justapõe-se à resposta desejada ($\dot{x} = \dot{x}_r$). Se o processo for linear na entrada, então uma solução explícita para a variável manipulada surge; se o processo for não linear na entrada, então uma solução implícita será geralmente obtida.

Considerando a existência de muitos processos não lineares de baixa dimensão que são difíceis de serem modelados e controlados pelas vias convencionais e processos de alta ordem, McLAIN e HENSON (2000) aplicaram o método da análise do componente principal para reduzir a dimensão do sistema e utilizaram uma rede neural de função de base radial em um controlador não linear que lineariza as entradas/saídas de um reator de polimerização altamente não linear. Os pesos da rede são ajustados em linha de tal modo que a saída da planta siga assintoticamente um modelo de referência linear, sendo o sistema de controle sintetizado um controle adaptativo por modelo de referência (MRAC – *Model Reference Adaptive Control*) não linear. Os resultados foram comparados com um controlador linear com realimentação de estados e que utiliza a mesma quantidade de informações que o controlador não linear. Foram investigados os casos regulatório e supervisor (variação exponencial do *set point*).

3.3.6 CONTROLE PREDITIVO BASEADO EM MODELO

Durante as décadas de 1980 e 1990 houve um aumento significativo na utilização de técnicas de controle preditivas baseadas em modelos lineares (LMPC – *Linear Model Predictive Control*). Uma excelente revisão destas técnicas, abrangendo aspectos teóricos e controladores preditivos comerciais disponíveis, pode ser encontrada em OGUNNAIKE e RAY (1994).

A mais citada das técnicas LMPC é o controle por matriz dinâmica (DMC – *Dynamic Matrix Control*), que é baseado na seleção de um conjunto de L mudanças futuras na variável manipulada (horizonte de controle), que minimizam uma função objetivo baseada na soma dos quadrados da diferença entre as saídas preditas pelo modelo e a trajetória da variável de saída desejada sobre um horizonte de predição, R . Apesar de que a otimização para o DMC é feita para uma sequência de mudanças futuras no controle, apenas a próxima mudança no controle é implementada. Incertezas no modelo e perturbações no processo são levadas em consideração através do cálculo de uma perturbação aditiva como sendo a diferença entre a medida do processo e a predição do modelo no instante de tempo atual (*current time step*). Assume-se que as perturbações futuras serão iguais às perturbações atuais, e uma nova trajetória é calculada. Notar que o controle preditivo é uma estratégia de controle ótimo em malha aberta com retroalimentação provida pela estimativa da perturbação (a qual também faz a compensação de incertezas no modelo).

Há uma solução analítica para o DMC desde que não haja restrições no controle; restrições podem ser incorporadas através da adição de fatores ponderando a velocidade da resposta. O controle por matriz dinâmica quadrático (QDMC) foi desenvolvido para incorporar restrições no processo de modo explícito, tanto nas variáveis manipuladas, quanto nas saídas do processo. LUNDSTRÖM *et al.* (1995) mostram que o desempenho do algoritmo DMC em malha fechada é limitado por duas considerações, a saber: (i) que uma resposta em degrau estável pode ser usada para representar a planta; (ii) que a diferença entre a saída medida e predita pode ser modelada como uma perturbação degrau agindo sobre a saída. Tais considerações levam às seguintes limitações:

1. Um bom desempenho pode requerer um número excessivo de coeficientes na resposta em degrau;

2. Um desempenho pobre pode ser observado para perturbações afetando a entrada da planta;

3. Desempenho robusto pobre pode ser observado para plantas multivariáveis com interações severas;

Para superar estas limitações os autores sugerem a utilização de um novo algoritmo de controle preditivo baseado em modelo (MPC), o qual inclui um observador e por isso chamado de controle preditivo baseado em modelo e observador (OBMPC – *Observer Based Model Predictive Controller*). O observador pode ser por exemplo o conhecido filtro de Kalman, que fornece uma observação ótima dos estados.

Estratégias de controle preditivas foram bem recebidas na indústria porque elas são intuitivas e são capazes de lidar com restrições de modo explícito. Uma das maiores limitações do método é que ele foi desenvolvido baseado na teoria de sistemas lineares e não produz bons resultados para sistemas altamente não lineares. Uma extensão direta dos métodos de controle preditivo baseado em modelo linear é alcançada pela utilização de um modelo dinâmico não linear do processo, no lugar do modelo linear de convolução.

O controlador preditivo baseado em modelo (MPC) que utiliza um modelo não linear do processo é chamado de controle não linear preditivo baseado em modelo (NLMPC – *Non Linear Model Predictive Control* ou NLPC - *Nonlinear Predictive Control*). O objetivo do controle preditivo não linear (NLPC) é selecionar um conjunto de mudanças futuras no controle (horizonte de controle) de tal modo a minimizar uma função baseada em uma trajetória de resposta desejada sobre um horizonte de predição. Matematicamente, uma formulação geral pode ser apresentada como sendo (BEQUETTE, 1991):

$$\min_{u(k), \dots, u(k+L-1)} \Phi(u) = \int_k^{k+T_p} e^2 dt = \sum_{i=k+1}^{k+R} (y_{sp}(i) - y_{pred}(i))^2 \quad 3 - 55a$$

sujeito à:

$$\dot{x} = f(x, u, p, l) \quad (3 - 55b)$$

$$y_m = g(x) \quad (3 - 55c)$$

$$u_{min} \leq u(i) \leq u_{max} \quad (3 - 55d)$$

$$u(i-1) - \Delta u_{max} \leq u(i) \leq u(i-1) + \Delta u_{max} \quad (3 - 55e)$$

$$u(i) = u(k + L - 1) \quad \text{para } \forall i > k + L - 1 \quad (3 - 55f)$$

$$x_{min} \leq x(i) \leq x_{max} \quad (3 - 55g)$$

$$y_{min} \leq y(i) \leq y_{max} \quad (3 - 55h)$$

$$x(k) = x_k \quad (3 - 55i)$$

A função objetivo é a soma dos quadrados dos resíduos entre as saídas previstas pelo modelo e os valores de referência (*set points*), sobre o horizonte de predição R intervalos de tempo (3 - 55a). As variáveis de decisão da otimização são as ações de controle L intervalos de tempo no futuro; após o L-ésimo intervalo de tempo, assume-se que a ação de controle seja constante (3 - 55f). Notar que restrições absolutas (3 - 55d) e incrementais (3 - 55e) nas variáveis manipuladas são explicitamente incluídas nesta formulação. Restrições nos estados e nas variáveis de saídas estão incluídas em 3 - 55g,h.

Apesar da otimização ser baseada sobre um horizonte de controle, apenas a primeira ação de controle é implementada. Após esta implementação, são obtidas as medidas das saídas da planta. Faz-se a compensação entre as divergências entre a planta e o modelo e a otimização é realizada novamente.

Há um número importante de itens a serem considerados na solução das Eqs. 55a-i, tais como:

- a escolha da técnica de otimização com restrição;
- como resolver a restrição imposta pelo modelo dinâmico (3 - 55b);
- devido ao fato de que muitas das variáveis de estado não podem ser medidas (conhecidas), necessita-se tomar uma decisão acerca das condições iniciais propícias para as variáveis de estado no início do horizonte de predição (3 - 55i);
- as saídas do modelo (y_m) são uma função das variáveis de estado (3 - 55c); portanto, uma correção necessita ser feita em y_m para obter uma melhor predição das saídas (y_{pred}).

Uma discussão detalhada destes itens está além dos objetivos deste trabalho e o leitor que desejar efetuar-la deve consultar a literatura disponível (BEQUETTE, 1991;

HENSON e SEBORG, 1997). Uma excelente discussão do que se espera da próxima geração dos controladores preditivos baseados em modelo, sob ótica da indústria, pode ser encontrada em NIKOLAOU (1998). Visões mais acadêmicas, porém sem perder de vista a aplicação industrial, acerca do estágio atual e futuro do controle preditivo são amplamente discutidas por HENSON (1998) e por MORARI e LEE (1999), sendo leitura obrigatória para todos os *predictive control practitioners*.

O modelo matemático do processo (planta ou sistema) utilizado no NLMPC é freqüentemente um modelo fenomenológico advindo dos balanços e geralmente composto por um sistema de equações diferenciais ordinárias (EDOs), equações diferenciais parciais (EDPs) ou por um sistema de equações algébricas. Para realizar o procedimento de otimização, os métodos usuais consistem basicamente em três procedimentos distintos:

- **procedimento sequencial:** a solução do modelo e o cálculo das ações de controle são realizados de forma sequencial e de modo separado, pois sendo o modelo descrito por um sistema de EDOs, este é integrado por um integrador e então as respostas são passadas para o otimizador. Este procedimento requer alto esforço computacional, pois o otimizador necessita resolver o sistema de EDOs reiteradas vezes.
- **procedimento simultâneo:** O sistema de EDOs é discretizado utilizando um método de colocação ortogonal e o sistema algébrico resultante é resolvido simultaneamente com o otimizador, resultando geralmente em um problema de largas dimensões.
- **procedimento de linearização:** o modelo não linear é linearizado em torno do ponto de operação a fim de que se resulte em um problema de otimização linear cuja solução é bem mais simples e rápida do que as anteriores.

Uma alternativa interessante é utilizar redes neurais para representar o modelo do processo, pois deste modo têm-se todos os benefícios do procedimento simultâneo, porém com um número muito menor de equações já que não houve discretização do modelo fenomenológico.




Figura 3-10 – Estrutura do controlador NLMPC.

esquema geral de um controlador NLPC (as vezes também chamado de NLMPC – *NonLinear Model Predictive Controller*) é mostrado na Figura 3-10. Neste caso, o NLPC foi implementado segundo a estrutura IMC.

HUNT *et al.* (1992) apresentam uma função objetivo na forma:

$$J = \sum_{j=1}^{N_1} \left(y^r(t+j) - y^m(t+j) \right)^2 + \sum_{j=1}^{N_2} \lambda_j \left(u(t+j-1) - u(t+j-2) \right)^2 \quad 3 - 56$$

sujeita às restrições do modelo dinâmico e onde as constantes N_1 e N_2 definem os horizontes sobre os quais a minimização do erro e os incrementos de controle são considerados. O valores de λ são os pesos aplicados à ação de controle.

Se o procedimento de treinamento especializado descrito anteriormente (Controle inverso) for modificado de modo que a função objetivo assuma a seguinte forma (NØRGAARD, 2000b):

$$J_s(\theta) = \sum_t \left(r(t) - y(t) \right)^2 + \rho \left(u(t) \right)^2, \quad \rho \geq 0 \quad 3 - 57$$

o treinamento da rede neural é muito similar ao treinamento especializado de modelos inversos e pode ser realizado em linha. Um modelo preditivo (*forward*) do processo necessita estar disponível, obtido na etapa de identificação. O treinamento pode utilizar o algoritmo recursivo modificado de Gauss-Newton. Sumariamente,

$$e_u(t) \equiv \frac{\partial y(t)}{\partial u(t-1)} e(t) \quad 3 - 58$$

$$\Psi_u(t) \equiv \frac{du(t-1)}{d\theta} \quad 3 - 59$$

$$\Psi(t) = \frac{\partial \hat{y}(t)}{\partial u(t-1)} \Psi_u(t) \quad 3 - 60$$

O gradiente é modificado de tal modo a resultar em uma nova atualização dos pesos:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + P(t)\Psi_u(t)(e_u(t) - \rho u(t-1)) \quad 3 - 61$$

A técnica da linearização instantânea descrita anteriormente não é adequada quando as não linearidades presentes no sistema não são suaves. Infelizmente, critérios de projeto práticos e relevantes baseados diretamente em um modelo neural não linear são raros. Um dos mais conhecidos é a utilização das redes neurais no controle preditivo e também um dos mais promissores. O emprego das redes neurais se dá de acordo com o critério J_5 definido anteriormente. Entretanto, no controle preditivo não linear a predição das saídas futuras não é obtida através de linearização, mas a partir do uso recursivo e sucessivo do modelo não linear NNARX:

$$\begin{aligned} \hat{y}(t+k|t) = g(\hat{y}(t+k-1), \dots, \hat{y}(t+k-\min(k,n)), y(t), \dots, y(t-\max(n-k,0)), \\ u(t-d+k), \dots, u(t-d-m+k)) \end{aligned} \quad 3 - 62$$

O problema de otimização resultante neste caso é solução muito mais difícil e um método de procura iterativo é requerido. Vários algoritmos de otimização podem ser utilizados, cada um com vantagens e desvantagens, sendo os mais comuns o método de Quasi-Newton aplicando o algoritmo de BFGS para atualizar o inverso do Hessiano e o método de Levenberg-Marquardt baseado no método de Newton.

Na utilização dos métodos de otimização necessita-se especificar uma sequência inicial de controles futuros $U^{(0)}(t) = [u^{(0)}(t), u^{(0)}(t+1), \dots, u^{(0)}(t+N_u-1)]$ para proceder ao método iterativo. Como na minimização do critério J_5 mais de um local mínimo pode ser encontrado, é desejável que o problema de otimização seja executado várias vezes, com diferentes sequências iniciais $U^{(0)}(t)$, a fim de se tentar localizar o mínimo absoluto. O esquema geral do método é ilustrado na Figura 3-11.




Figura 3-11 – Controle não linear por otimização (esquema geral).

A utilização de redes neurais em controle preditivo tem sido o procedimento mais comum dentre todos os demais. As aplicações no âmbito da Engenharia de Processos são inúmeras, revisadas em HUSSAIN (1999), que descreve aplicações até o ano de 1997.

NIKRAVESH *et al.* (1997; 2000) consideraram uma estratégia de controle preditiva baseada em modelo chamada Controle por Rede Neural Dinâmica (DNNC – *Dynamic Neural Network Control*). No primeiro trabalho investigaram a estabilidade do modelo do processo e do controlador, ambos descritos por redes neurais, utilizando a teoria de Lyapunov. O controlador DNNC é definido como sendo o inverso do modelo do processo, sendo obtido via configuração IMC. Os autores definiram um índice de estabilidade da rede neural, que é uma função dos autovalores do modelo do processo e do modelo inverso, o qual foi utilizado para determinar a estrutura ótima da rede DNNC. Nas investigações utilizaram como caso estudo o reator CSTR com reação exotérmica e troca térmica. As vantagens do controlador DNNC neural com camada interna única requeridas foram: estrutura simples da rede neural; melhor inicialização dos pesos da rede por possuir poucos parâmetros; projeto do controlador e implementação mais simples quando comparados às estratégias convencionais que utilizam redes neurais. Os parâmetros de sintonia (os pesos da rede) são semelhantes aos parâmetros do controlador DMC.

Investigação experimental em plantas industriais do desempenho de controladores preditivos utilizando redes neurais foram reportados por: ALVAREZ *et al.* (1999), controle de um reator para produção de xilose; VEGA *et al.* (2000), modelagem de um processo difusional na produção de açúcar, predição em uma planta de tratamento de efluentes utilizando lodo ativado e controle preditivo de uma unidade de dissolução (*melter*) de cristais de açúcar de qualidade pobre; BENNE *et al.* (2000), controle de uma unidade de evaporadores de múltiplo efeito (5 evaporadores em série) pertencentes à indústria de açúcar. Em todos os trabalhos os resultados foram considerados satisfatórios ou bons,

sendo que os processos se caracterizam pela alta não linearidade e pela presença de tempo morto ou atraso de transporte.

O controle preditivo não linear (NMPC) de reatores de polimerização foi objeto de investigação de VEGA *et al.* (2000) e BOLSONI *et al.* (2000). No primeiro caso considerou-se um reator tubular com reciclo utilizado na polimerização do estireno. Redes neurais foram combinadas com um modelo fenomenológico do processo, resultando em um modelo híbrido, o qual foi empregado no controlador preditivo, na configuração IMC, SISO e MIMO. Através de simulações, testou-se a capacidade do controlador para forçar o processo a acompanhar alterações de *set points* na(s) saída(s) do mesmo. No segundo trabalho, considerou-se o controle de um reator de lama para polimerização do propileno. O modelo utilizado pelo controlador preditivo apresenta uma dinâmica linear (modelo ARX) e um ganho estático não linear dado por uma rede neural. Os resultados foram comparados com um controlador preditivo linear (LMPC).

SANTOS *et al.* (2000) utilizaram uma rede neural para identificar e controlar uma unidade de craqueamento catalítico fluido composta de reator e regenerador. A rede utilizada foi no formato NNARMAX e o objetivo de controle foi a temperatura da fase densa no primeiro estágio no regenerador, através da manipulação da vazão de ar ao regenerador (controle SISO). O controle preditivo não linear foi posto na forma de um problema de otimização com restrições no qual o modelo do processo foi substituído por uma rede neural. Foram apresentados resultados obtidos por simulação para o caso regulatório e supervisório.

3.3.7 CONTROLE ADAPTATIVO

Embora não tenha tido uma vasta aplicação industrial como o controle preditivo, o controle adaptativo apresenta uma idéia extremamente atraente do ponto de vista aplicativo: a concepção do sistema de controle se adaptar automaticamente à mudanças ocorridas no processo, desconhecidas no momento de projeto do controlador, e sem a interferência externa de um manipulador. O controle adaptativo surge da observação direta de que todos os seres na natureza (inclusive o homem) possuem capacidades adaptativas sem as quais seria praticamente impossível a vida na Terra, devido à diversidade de situações adversas encontradas tais como sazonalidades no clima, deslocamento enfrentando a lei da gravidade, mudanças no *habitat*, dentre outras. Do ponto de vista formal a teoria de

controle linear foi extensamente investigada na década de 1970 e 1980, porém restrita à sistemas lineares (SEBORG *et al.*, 1986; ÅSTRÖM e WITTENMARK, 1995).

A conexão existente entre o controle adaptativo e as redes neurais foi instantânea, quando do pleno desenvolvimento destas, pois conceitualmente uma rede neural se ajusta ou "se adapta" a certo conjunto de dados que lhe são apresentados por meio do ajuste de seus pesos. O próprio treinamento recursivo (ou treinamento em linha – *on line*) beneficiou-se das muitas técnicas de ajuste recursivo de parâmetros desenvolvidos no âmbito do controle adaptativo. NARENDRA (1990) já destacava que as bem estabelecidas técnicas de controle e identificação adaptativas podiam ser aplicadas na análise e síntese de sistemas dinâmicos, os quais continham redes neurais como subsistemas. Nesta perspectiva, as redes neurais recorrentes pareciam ser os instrumentos ideais para se realizar a adaptação, ao lado das redes convencionais com treinamento em linha. Entretanto, os métodos de treinamento recursivo não progrediram na velocidade esperada e as redes recursivas até hoje encontram limitado campo de aplicação devido principalmente aos complexos algoritmos de treinamento disponíveis.

Entretanto, a idéia de adaptação tem permanecido nas estratégias de controle que utilizam redes neurais (BALLINI e Von ZUBEN, 2000), se não como uma técnica distinta, mas como método combinado nas estratégias tais como o controle linearizante e o controle preditivo. Assim, cresce o número de trabalhos investigando sistemas de controle não linear adaptativo, que quase sempre significa conferir características adaptativas às técnicas descritas anteriormente neste capítulo.

3.3.8 CONTROLE NEURAL-NEBULOSO

BAUGHMAN e LIU (1995) discutem uma interessante classe de controladores que unem redes neurais e lógica nebulosa (*fuzzy logic*), no âmbito da Engenharia de Processos. A vantagem em tal união residiria no fato de se aproveitar as excelentes capacidades genéricas de descrição quantitativa das redes neurais com os conhecimentos qualitativos operacionais que se dispõe acerca de dado processo descritos pela lógica nebulosa. O conceituadíssimo IEEE (*Institute of Electrical and Electronics Engineers, Inc.*) publicou um volume de seu *Proceedings of the IEEE* (V. 38, n. 3, Março de 1995) especialmente dedicado à lógica nebulosa e às suas aplicações em engenharia. Neste volume, além dos aspectos teóricos relativos à lógica nebulosa, foram discutidos diversos aspectos dos controladores neuro-nebulosos.

BAUGHMAN e LIU (1995) descrevem três aplicações de controladores neural-nebulosos:

1. *Controle de um processo fermentativo em batelada.* O processo consiste de uma fermentação em batelada com produção de levedura como objetivo e tendo o etanol como produto indesejável por questões de inibição. O objetivo de controle é conduzir o processo fermentativo segundo uma trajetória pré-especificada de crescimento celular (definida previamente pelo projetista) pelo ajuste da temperatura de fermentação. Uma rede neural foi treinada para prever a concentração de células sob as condições correntes de operação. O controlador nebuloso determina as modificações na temperatura requeridas para que a concentração de células pré-estabelecida seja atingida num tempo futuro determinado.

2. *Controle de um bioreator.* O interesse aqui foi o de controlar a concentração de glicose em uma fermentação operada a batelada alimentada utilizando *Saccharomyces cerevisiae*, que é uma importante cepa hospedeira para DNA recombinante. O controle da concentração de glicose é fundamental pois altas concentrações desta levam à produção de etanol, o qual por sua vez inibe a produção do material genético desejado. Para inferir a concentração de glicose em linha, a qual não é facilmente mensurável desta maneira, utilizou-se as concentrações de oxigênio dissolvido e de etanol como variáveis medidas para controlar a concentração de glicose. Há inúmeras relações qualitativas entre as diferentes concentrações que podem ser capturadas através da lógica nebulosa. Duas redes neurais relacionadas às concentrações de etanol e oxigênio dissolvido provêm as informações necessárias para se gerar as funções membro, que por sua vez repassadas ao controlador nebuloso.

3. *Controle de um processo de cultivo de células em alta densidade.* Muitas estratégias de controle avançado foram investigadas na regulação da concentração de glicose no cultivo em batelada alimentada da *E. coli* recombinante, entretanto, tiveram pouco sucesso devido a: falta de modelos matemáticos do processo; interações complexas entre células e ambiente de cultivo; falta de sensores confiáveis com medidas em linha; processo com resposta lenta. Desenvolveu-se então um controlador neural-nebuloso que manipulava a vazão de glicose alimentada baseado nos desvios de *set points* dos valores de pH (medida indireta da concentração de glicose) e taxa específica de crescimento celular.

Os controladores neurais-nebulosos representam uma interessante perspectiva de controle para processos onde há a coexistência de dados experimentais observáveis, com falta de modelos matemáticos que os descrevam, juntamente com conhecimentos qualitativos operacionais adquiridos com os procedimentos empíricos. Os bioprocessos tem sido os mais fortes candidatos a serem controlados sob esta perspectiva por apresentarem justamente tais características. Esta classe de processos tende a crescer cada vez mais tendo em vista a descoberta de inúmeras rotas biotecnológicas para novos e antigos produtos de interesse comercial. Devido ao fato da maioria destes produtos serem produzidos em pequena escala, em processos batelada ou batelada alimentada, primando pela versatilidade e possuindo alto valor agregado (tais como medicamentos, células animais, insumos para a indústria alimentícia, dentre outros), o emprego de técnicas genéricas com capacidade de aprendizado, tais quais as redes neurais, na automação, otimização, monitoramento, detecção de falhas, etc., será de suma importância ao bom êxito desta nova fase dos processos, os bioprocessos.

3.4 CONCLUSÕES

Neste capítulo foram apresentadas as principais características dos sistemas não lineares as quais implicam em dificuldade de se obter um bom desempenho em malha fechada de tais sistemas. Em seguida foram apresentadas de modo resumido as principais estratégias de controle encontradas na literatura aplicáveis ou desenvolvidas para o controle dos sistemas não lineares, com ênfase naquelas que utilizam redes neurais artificiais na síntese do controlador. Revisando extensivamente a literatura dos últimos anos, percebe-se que o controle baseado em modelos inversos na estrutura IMC, o controle não linear que utiliza métodos de geometria diferencial e o controle preditivo baseado em modelo, são as principais metodologias empregadas no controle dos sistemas não lineares, cada uma delas apresentando vantagens e desvantagens quando comparada com as demais.

A utilização de redes neurais no controle de processos tem sido ampla, destacando-se no controle preditivo e no controle não linear, onde as mesmas têm substituído o modelo do processo ou tem sido incorporadas aos modelos fenomenológicos nas estruturas híbridas de modelos. Percebe-se também na literatura uma tendência em utilizar métodos nos quais o controlador é baseado em uma rede neural tendo seus pesos ajustados em linha, levando assim a diferentes tipos de controladores adaptativos. A

estabilidade em malha fechada tem sido investigada através da aplicação dos critérios de estabilidade de Lyapunov.

A maioria das aplicações reportadas na literatura descrevem investigações efetuadas via simulação, entretanto começam a surgir relatos de aplicações experimentais em processos reais, com sucesso. Os processos utilizados nas investigações tem sido basicamente reatores químicos de diversas modalidades, com destaque para o reator de mistura perfeita, apesar de outras operações ligados à indústria açucareira também terem sido objeto de investigação.

Acredita-se que muito ainda há por fazer, tanto no desenvolvimento dos aspectos teóricos relacionados ao controle de sistemas não lineares utilizando redes neurais, quanto na aplicação aos diversos processos no âmbito da Engenharia Química.

Capítulo 4

ESTUDO DE CASO: CSTRs EM SÉRIE

4 ESTUDO DE CASO: CSTRs EM SÉRIE

4.1 INTRODUÇÃO

Inicialmente far-se-á a identificação e o controle de um processo considerado um *benchmarking* no estudo de identificação e controle de sistemas não lineares, a saber, o reator CSTR com reação exotérmica e troca térmica. Este processo, apesar de já ter sido extensivamente estudado, continua sendo um desafio não superado pela maioria das estratégias de controle bem sucedidas e constitui-se uma referência na área de Controle de Processos, principalmente no Controle Não Linear, nas suas diversas modalidades. Existem inúmeras variantes deste processo na literatura e neste estudo, escolheu-se a versão constituída por dois tanques conectados em série, conforme descrito a seguir.

4.2 DESCRIÇÃO DO PROCESSO E MODELO MATEMÁTICO

O processo em estudo através de simulação matemática constitui-se de reatores tanques com mistura perfeita (CSTRs) conectados em série, conforme mostrado na Fig. 4-2. O sistema consiste de dois reatores operados a volume constante e resfriados por uma




Figura 4-1 - Esquema dos reatores tanques com mistura perfeita.

corrente simples de refrigerante, que resfria o primeiro reator e em seguida o segundo, no modo concorrente (entrada do refrigerante paralela à entrada dos reatores). Dentro dos reatores ocorre uma reação irreversível, exotérmica, $A \rightarrow B$. O objetivo da operação em malha fechada é controlar a

concentração do efluente A no segundo reator, C_{A2} , através da manipulação da vazão do refrigerante, q_C . O modelo do processo consiste em quatro equações diferenciais ordinárias, de primeira ordem, não lineares, conforme apresentado por HENSON E SEBORG (1990):

$$\frac{dC_{A1}}{dt} = \dot{C}_{A1} = \frac{q}{V_1} (C_{Af} - C_{A1}) - k_o C_{A1} \exp\left(\frac{-E}{RT_1}\right) \quad 4-1$$

$$\begin{aligned} \frac{dT_1}{dt} = \dot{T}_1 = \frac{q}{V_1} (T_f - T_1) + \frac{(-\Delta H)k_o C_{A1} \exp\left(\frac{-E}{RT_1}\right)}{\rho C_p} \\ + \frac{\rho_c C_{pC}}{\rho C_p V_1} q_c \left[1 - \exp\left(\frac{-hA_1}{q_c \rho_c C_{pC}}\right) \right] (T_{C,f} - T_1) \end{aligned} \quad 4-2$$

$$\frac{dC_{A2}}{dt} = \dot{C}_{A2} = \frac{q}{V_2} (C_{A1} - C_{A2}) - k_o C_{A2} \exp\left(\frac{-E}{RT_2}\right) \quad 4-3$$

$$\begin{aligned} \frac{dT_2}{dt} = \dot{T}_2 = \frac{q}{V_2} (T_1 - T_2) + \frac{(-\Delta H)k_o C_{A2} \exp\left(\frac{-E}{RT_2}\right)}{\rho C_p} \\ + \frac{\rho_c C_{pC}}{\rho C_p V_2} q_c \left[1 - \exp\left(\frac{-hA_2}{q_c \rho_c C_{pC}}\right) \right] \left[T_1 - T_2 + \exp\left(\frac{-hA_1}{q_c \rho_c C_{pC}}\right) (T_{C,f} - T_1) \right] \end{aligned} \quad 4-4$$

Se as variáveis de estado, perturbações, entradas e saídas forem definidas como:

$$x = \begin{bmatrix} C_{A1} & T_1 & C_{A2} & T_2 \end{bmatrix}^T, \quad d = \begin{bmatrix} C_{Af} & T_{C,f} \end{bmatrix}^T, \quad u = q_c, \quad y = C_{A2} \quad 4-5$$

onde:

- x ... vetor de estados
- d ... vetor das perturbações
- u ... entrada manipulada (escalar)
- y ... saída (escalar)

o modelo pode ser representado como sendo da forma:

$$\begin{aligned} \dot{x} &= f(x, d, u) \\ y &= h(x) \end{aligned} \quad 4-6$$

que corresponde à um modelo não linear no qual as entradas manipuladas (dentre elas q_c) e perturbações (C_{Af} , T_f , T_{Cf} , etc.) aparecem de forma também não linear, pois não é possível separá-las das demais variáveis, como a forma linear exige. Os parâmetros operacionais do sistema são mostrados na Tabela 4-1, assim como o estado estacionário de referência.

Tabela 4-1 – Condições nominais de operação dos CSTRs.

Parâmetro	Descrição	Valor nominal
q	Vazão volumétrica do processo	100 L.min ⁻¹
C_{Af}	Concentração do componente A na alimentação	1 mol.L ⁻¹
T_f	Temperatura da alimentação	350 K
T_{Cf}	Temperatura do refrigerante na entrada	350 K
V_1, V_2	Volume dos tanques 1 e 2	100 L
$h.A_1, h.A_2$	Coeficiente de transferência de calor x área de troca térmica	$1,67 \times 10^5$ J.min ⁻¹ .K ⁻¹
k_0	Fator pré-exponencial da equação de Arrhenius	$7,2 \times 10^{10}$ min ⁻¹
E/R	Energia de ativação da reação	1×10^4 K
$(-\Delta H)$	Entalpia (Calor) da reação	$4,78 \times 10^4$ J.mol ⁻¹
ρ, ρ_C	Densidade do líquido reagente e refrigerante	1000 g.L ⁻¹
C_p, C_{pC}	Capacidade calorífica do reagente e refrigerante	$0,239$ J.g ⁻¹ .K ⁻¹
$C_{A1s}, T_{1s},$	Estado estacionário de referência	$C_{A1s} = 0,08361$ mol.L ⁻¹
$C_{A2s}, T_{2s},$		$T_{1s} = 440,16$ K
q_{Cs}		$C_{A2s} = 0,004872$ mol.L ⁻¹
		$T_{2s} = 447,85$ K
		$q_{Cs} = 103,41$ L.min ⁻¹

4.3 DINÂMICA DO PROCESSO EM MALHA ABERTA

O processo em estudo apresenta uma dinâmica fortemente não linear; utiliza-se aqui uma classificação intuitiva, em três níveis - fracamente, moderadamente e fortemente não linear, pois não há uma classificação rigorosa do grau de não linearidade de um determinado processo. Isto pode ser verificado nos resultados que se seguem. Estes resultados (Fig. 4-2) apresentam o comportamento do processo após uma perturbação do tipo degrau na variável manipulada (q_C), de $\pm 10\%$ no valor nominal de operação desta. Vê-se claramente que as respostas para os degraus de mesma magnitude diferem-se completamente, o que caracteriza a não linearidade, pois um processo linear possui comportamento simétrico, para perturbações positivas e negativas de mesma magnitude na variável controlada, em relação ao valor do estado estacionário.

Não linearidade estática nesta região de operação. A resposta dinâmica também ilustra o efeito da não linearidade, como pode ser verificado pela oscilação após a perturbação de $+10\%$. Embora não mostrado aqui, as demais variáveis possuem comportamentos qualitativos similares ao mostrado na Fig. 4-2, exceto pelo fato das temperaturas apresentarem uma relação inversa com a vazão de refrigerante. Os novos

estados estacionários atingidos para as perturbações de + 10% e - 10% são, respectivamente:

$C_{A1s} = 0,1204$	0,05931	mol.L^{-1}
$T_{1s} = 432,39$	447,47	K
$C_{A2s} = 8,913 \times 10^{-3}$	$2,681 \times 10^{-3}$	mol.L^{-1}
$T_{2s} = 442,74$	453,31	K
$q_{Cs} = 113,75$	93,07	mol.L^{-1}




Figura 4-2 – Resposta em malha aberta para perturbações degrau na vazão de refrigerante, q_C .

A escolha do tempo de amostragem é uma variável importante e segundo SEBORG *et. al* (1989) constitui-se mais em uma arte do que em uma ciência e sugere na página 535 desta referência algumas regras gerais para controladores PID. Recomenda que o tempo de amostragem Δt seja calculado por:

$$0,25 < \frac{\Delta t}{t_r} < 0,5 \quad \text{onde } t_r \text{ é o tempo de subida (rise time) conforme definido por}$$

Åström & Wittenmark (1984). Para o processo em estudo, utilizou-se a resposta do sistema para a perturbação de -10% para o cálculo de t_r , pois esta apresenta um comportamento

similar à de um sistema de 1ª ordem mais tempo morto (exigido pela heurística). Deste modo, $t_r = 0,8$ min e assim $0,2 \text{ min} < \Delta t < 0,4 \text{ min}$. Entretanto, KRISHNAPURA E JUTAN (2000) utilizaram $\Delta t = 0,1$ min e para efeito de comparação utilizar-se-á também este valor, pois é melhor amostrar com mais frequência do que o controlador ignorar as mudanças dinâmicas do sistema.

Os reatores de mistura perfeita processando reações não isotérmicas e com troca térmica são caracterizados por possuírem múltiplos estados estacionários, característica esta que dificulta sua operação e faz a presença do controle automático uma necessidade, já que dos três estados estacionários existentes, um é instável e via de regra é o ponto operacional desejado por apresentar temperaturas moderadas. Seguindo a metodologia proposta por LUYBEN (1989), foram calculados os possíveis estados estacionários para o processo em estudo, que pode ser resumida como sendo:

1. Especificar um conjunto de valores para a temperatura no primeiro reator T_1 , por exemplo de 300 K a 500 K, de 5 K em 5 K;
2. Calcular C_{A1} no estado estacionário correspondente a cada valor de T_1 , utilizando a Eq. 4-1, ou:

$$C_{A1} = \frac{q \cdot C_{Af}}{q + k_0 V_1 \exp\left(\frac{-E}{RT_1}\right)} \quad 4 - 7$$

3. Utilizando a Eq. 4-3, isolar C_{A2} :

$$C_{A2} = \frac{q \cdot C_{A1}}{q + k_0 V_2 \exp\left(\frac{-E}{RT_2}\right)} \quad 4 - 8$$

4. Utilizando T_1 (do item 1), C_{A1} (do item 2) e a expressão de C_{A2} em função de T_2 , calcular a temperatura no segundo reator T_2 utilizando a Eq. 4-4 quando $\frac{dT_2}{dt} = 0$;

5. Calcular C_{A2} utilizando a Eq. 4-8;
6. Calcular o calor gerado (Q_G) e o calor retirado (Q_R) no primeiro reator através da expressão:

$$Q_G = (-\Delta H) V_1 k_0 C_{A1} \exp\left(\frac{-E}{RT_1}\right) \quad 4-9$$

$$Q_R = q\rho C_p (T_1 - T_{c,f}) + \rho_c C_{pc} q_c \left(1 - \exp\left(\frac{-hA_1}{q_c \rho_c C_{pc}}\right)\right) (T_1 - T_{c,f}) \quad 4-10$$

A Figura 4-3 mostra o calor gerado (sigmóide) e o calor retirado (reta) no primeiro reator em função da temperatura do mesmo. Os pontos de interseção entre a sigmóide e a reta denotam os estados estacionários, já que nestes o calor gerado e o calor retirado se igualam. A Figura 4-4 mostra como a temperatura no segundo reator varia em função da temperatura no primeiro reator. Percebe-se que estas temperaturas possuem dois intervalos




Figura 4-3 - Multiplicidade de estados estacionários (calor gerado - sigmóide e retirado - reta). [T] = K, [Q] = J/min

nos quais são iguais e correspondem a C_{A2} próximo de zero e um. Entre 350 K e 460 K, o valor de T_2 é superior a T_1 . Um fato interessante é que quando T_1 aumenta de um Kelvin (de 358 K para 359 K), T_2 aumenta de 74,5 Kelvin (passando de 370,64 K para 445,18 K). Isto se explica pelo fato de que o aumento em T_1 fez com que o segundo reator passasse a operar em outro estado estacionário de

temperatura mais elevada. Outro fato a ser notado é que para uma mesma temperatura T_2 , por exemplo 447 K, existem três possíveis correspondentes temperaturas T_1 , isto em certo intervalo de T_2 (aproximadamente de 440 K a 450 K). Este fato faz com que neste intervalo controlar T_2 não garante o controle de T_1 , já que para um mesmo valor de T_2 pode haver até 3 possíveis valores de T_1 . Percebe-se, portanto, que o grau de complexidade da dinâmica de reatores de mistura não isotérmicos, com troca térmica, é alto, dificultando assim sua operabilidade.




Figura 4-4 - Relação entre T_1 e T_2 no estado estacionário. $[T] = K$

4.4 IDENTIFICAÇÃO DO PROCESSO

Com o objetivo de desenvolver um modelo do processo para fins de implantação de estratégias de controle avançado foi realizada a identificação do sistema utilizando-se as redes neurais artificiais segundo dois procedimentos distintos. O modelo desenvolvido foi comparado com outros modelos comuns na área de controle e os resultados são apresentados a seguir.

A Figura 4-5 mostra o conjunto de entrada – saída ("input – output") utilizado na identificação, sendo q_C a variável de entrada e C_{A2} a variável de saída. Estes dados foram gerados a partir de uma perturbação aleatória imposta à variável de entrada, dentro de certo limite (limite este factível do ponto de vista operacional, sendo escolhidos os valores $q_C \in [60 \text{ l/min}, 140 \text{ l/min}]$), a qual poderia permanecer ou não no seu valor atual, segundo determinada probabilidade, no caso 50%. Os dados foram divididos em dois subconjuntos a saber: i) treinamento; ii) teste; como pode ser visualizado na referida figura. Em seguida os **dados (treinamento e teste) foram escalonados de tal modo a apresentarem média zero e variância 1**, procedimento este recomendável quando se tem em mente a utilização das redes neurais artificiais na correlação de tais dados.

Inicialmente propõe-se efetuar a identificação utilizando modelos não lineares na forma entrada – saída, ou regressores. A escolha de um regressor apropriado para descrever a dinâmica de um sistema não é uma tarefa fácil e pressupõe certo empirismo. Uma

variável importante na escolha do regressor é a ordem do sistema. Tal ordem pode ser determinada a partir do conhecimento físico do sistema em estudo ou pode ser inferida a partir do conjunto de dados de entrada – saída. Neste último caso, pode-se empregar a metodologia proposta na literatura (HE e ASADA, 1993) para se determinar a estrutura do atraso (*lag space structure*) (m e n) antes da identificação do modelo dinâmico do sistema :

$$y(t) = f(y(t-1), \dots, y(t-n), u(t-1), \dots, u(t-m)) \quad 4 - 11$$




Figura 4-5 – Dados de entrada (a) e saída (b) utilizados na identificação do sistema. Conjunto de treinamento e teste, respectivamente.

Utilizando um índice de avaliação, que é calculado para várias estruturas do atraso, pode-se determinar qual delas é a mais conveniente. A medida que se aumenta o atraso, o índice decresce até que uma estrutura de atraso suficiente é atingida. Se o atraso for aumentado além desta quantia, o índice não se reduz de modo significativo. Em outras palavras: o procedimento consiste em se localizar o ponto no qual o índice possui uma curvatura acentuada a partir da qual permanece praticamente inalterado, ou diminui muito suavemente. Isto pode ser visualizado na Figura 4-6, na qual mostra o índice em função do número de entradas e saídas passadas. Observa-se que há uma redução drástica na inclinação da reta quando a ordem do modelo é ≥ 2 . Baseado nestes resultados, adotar-se-á

um modelo com $m = 2$, $n = 2$ (ordem 2) e $k = 1$, sendo k o atraso do sistema. Apesar da presença de ruídos nos dados afetarem sensivelmente a tomada de decisão acerca da ordem do modelo a partir do procedimento anterior, este se constitui em um ponto de partida na inferência nem sempre fácil da estrutura do regressor a ser utilizado na identificação do sistema. Entretanto, estes resultados são obtidos a partir da teoria de sistemas lineares e não há garantia de que este procedimento seja válido para sistemas descritos por estruturas não lineares. A vantagem deste procedimento é evitar uma determinação iterativa e tediosa da quantidade de entradas a serem utilizadas no regressor.




Figura 4-7 – Influência da ordem do regressor no índice de avaliação. Eixo x: número de entradas/saídas passadas; Eixo y: ordem do índice de avaliação.




Figura 4-6 - Influência da ordem do regressor no índice de avaliação. (bidimensional). x: saídas; y: entradas; z: índice de avaliação.

4.4.1 AJUSTE DE UM MODELO LINEAR

A tentativa de ajustar um modelo linear na representação dos dados do processo deve sempre ser a primeira escolha, pois sempre que possível deve-se utilizar modelos o mais simples possível, desde que representem com desejada exatidão a dinâmica do sistema. Se o modelo linear atende às necessidades de identificação, não há motivos para se continuar na busca de modelos mais elaborados (e também mais complexos).

Escolheu-se um modelo linear na forma OE ("Output-Error model"), que é representado por:

$$y(t) = \frac{B(q)}{F(q)} u(t - nk) + e(t) \quad 4 - 12$$

para identificar o sistema, utilizando a seguinte função disponível no "System Identification Toolbox" do Matlab™:

```
>> th = oe([y1' u1'],[2 2 1]);
```

onde:

y1...vetor com os dados da saída do processo (conjunto de treinamento);

u1...vetor com os dados da entrada do processo (conjunto de treinamento);

th ... parâmetros estimados do modelo de erro da saída (OE), juntamente com as covarianças estimadas e informações da estrutura (acessíveis com o comando >> present(th);

Para o processo em estudo os seguinte valores foram calculados:

$B = [-0,0482 \cdot 10^{-5} \quad 0,4841 \cdot 10^{-5}]$ e $F = [1,0000 \quad -1,8121 \quad 0,8927]$




Figura 4-8 – Identificação do sistema utilizando um modelo linear ARX.

[Loss fcn: 6.9422e-008

Akaike's FPE:

7.0542e-008

Sampling interval 1]

A Figura 4-8 mostra uma comparação entre a saída medida e aquela estimada utilizando o modelo linear e o conjunto teste de dados. O modelo linear tende a subestimar os valores medidos (curva mais suave), não conseguindo

acompanhar a dinâmica do processo. A Figura 4-9 mostra as funções de correlação para o modelo linear ajustado e percebe-se que a função de correlação para os resíduos mostra-se pouco aceitável.

A identificação pode ser melhorada continuamente se for adotada uma forma recursiva do algoritmo de estimativa (LJUNG, 1987), apesar das possíveis desvantagens deste procedimento, tal qual a perda de capacidade de atualização dos parâmetros ou




Figura 4-9 – Funções de correlação dos resíduos (a) e de correlação cruzada entre a entrada e os resíduos (b) para o modelo linear ajustado, em função do atraso.

mesmo a não convergência destes.

4.4.2 IDENTIFICAÇÃO UTILIZANDO REDES NEURAIS NNARMAX

Para efeito de comparação com o modelo linear, identificar-se-á uma rede neural na forma do modelo ARX, rede que é chamada de NNARX (Capítulo 2). Inicialmente, investigar-se-á: (i) o efeito do número de neurônios na camada interna (com função de ativação tangente hiperbólica na

camada interna) e (ii) o número de iterações na etapa de treinamento. A rede neural utilizada terá arquitetura totalmente conectada e função linear na camada de saída. A Figura 4-10 mostra a arquitetura da rede utilizada para o caso de 7 neurônios na camada intermediária. Como se trata do modelo NNARX, este não possui característica recorrente, sendo as entradas da rede as saídas do processo y em três intervalos de tempo anteriores $[y(t-1), y(t-2), y(t-3)]$, juntamente com o sinal de entrada u em três instantes anteriores $[u(t-1), u(t-2), u(t-3)]$, caracterizando uma estrutura na forma $[3,3,1]$, ou, $[n_a, n_b, n_k]$. Comparou-se também com a estrutura $[2,2,1]$, ou seja, utilizando quatro sinais de entrada (dois saídas y , e duas entradas u).

Utilizando o conjunto de treinamento para ajustar os pesos da rede neural, o desempenho desta na predição $\hat{y}(t)$ foi avaliada utilizando o conjunto de teste, para o qual foi calculado o índice NSSE (Normalized Sum of Squared Errors), uma medida quantitativa da qualidade da predição da rede em relação aos dados "reais". Avaliou-se o NSSE para redes contendo de 1 a 20 neurônios na camada interna, para 50, 100 e 200 iterações no ajuste dos pesos. Sabe-se que um número grande de neurônios na camada interna aumenta a capacidade da rede em ajustar os dados, porém esta diminui sua capacidade de generalizar dados não mostrados na etapa de treinamento (*overfitting*). O mesmo é válido para o número de iterações na etapa de ajuste.




Figura 4-10 – Arquitetura da rede neural utilizada na identificação (yhat: predição da rede.) Estrutura [3,3,1].

Variando o número de saídas y e entradas u passadas alimentadas na camada de




Figura 4-11 – Influência do número de saídas y e entradas u alimentadas na rede neural. (o : na; — : nb)

mínimo em torno de 5 neurônios (para a estrutura [2,2,1]) e 7 neurônios (para a estrutura [3,3,1]). Observa-se que até 4 neurônios, não há diferença significativa no número de iterações acima de 50, na capacidade de generalização da rede. Tendo em vista estes resultados, adotar-se-á uma rede com 7 neurônios na camada interna e com treinamento de

entrada da rede (para 5 neurônios na camada interna), percebe-se que após 3 atrasos não há queda significativa no NSSE avaliado para o conjunto teste (Figura 4-11). Portanto, comparar-se-á a predição deste estrutura com a determinada considerando um mapeamento linear. Analisando a Fig. 4-12,

percebe-se que o NSSE em função do número de neurônios da camada interna passa por um ponto de

100 iterações (em todos os casos garantiu-se que o ponto de mínimo fosse atingido) e entrada da rede na forma [3,3,1], para efeitos de representar o mapeamento entrada-saída do reator, pois esta configuração geral apresenta o menor NSSE para o conjunto de teste. Esta estrutura de rede constituirá no modelo do processo que será utilizado posteriormente no controle do mesmo. O algoritmo de treinamento utilizado foi o de Levenberg-Marquardt.




Figura 4-12 - Influência do número de neurônios da camada interna e número de iteração no treinamento sobre o NSSE em um conjunto teste, em função do número de entradas consideradas.




Figura 4-13 – NSSE no treinamento da rede NNARX em função do n°. de iterações.

A Figura 4-13 mostra o NSSE (para os dados escalonados) em função do número de iterações na etapa de treinamento. Seu decaimento denota a busca do ponto de mínimo em função dos pesos da rede neural.

A Figura 4-14a mostra as saídas "reais", correspondentes ao conjunto teste, confrontados com os resultados preditos pela rede

neural previamente treinada ($NSSE_{TS} = 7,85 \cdot 10^{-11}$ para o conjunto teste em oposição ao $NSSE_{TR} = 1,14 \cdot 10^{-11}$ para o conjunto de treinamento; para efeito de comparação, com uma rede neural com 5 neurônios na camada interna, este valores se alteram para: $NSSE_{TS} = 2,32 \cdot 10^{-9}$ para o conjunto teste em oposição ao $NSSE_{TR} = 9,66 \cdot 10^{-10}$ para o conjunto de treinamento). A diferença entre o valor "real" e o predito pela rede é mostrado na Figura 4-14b. Seguindo a mesma metodologia, ajustou-se uma rede na forma NNOE (rede recorrente), tendo como $NSSE_{TS} = 5,29 \cdot 10^{-9}$ (contra $NSSE_{TS} = 1,29 \cdot 10^{-7}$ para a rede com 5 neurônios), ou seja, um ajuste um bem inferior do que o modelo anterior. Entretanto, as estruturas recorrentes são importantes quando se deseja utilizar o modelo neural do processo em predições com horizontes maiores que um intervalo à frente, como no caso do controle preditivo.




Figura 4-14 – Predição um passo a frente de C_{A2} utilizando uma rede neural na forma NNARX (a) Dados "reais" e preditos; (b) erro predito.

Nota-se que há uma boa distribuição do erro ao longo da predição, o que pode ser melhor visualizado nas Figuras 4-15a e b, que utilizam as funções de auto-correlação do

erro predito e de correlação cruzada da entrada u e do erro predito, respectivamente. Percebe-se através destes dados que o ajuste para o modelo NNOE (Figura 4-15b) foi pior também do ponto de vista da correlação do que aquele obtido para o modelo NNARX (Figura 4-15a).




Figura 4-15 - Funções de autocorrelação do erro predito e coeficiente de correlação cruzada entre a entrada e o erro predito para o modelo neural NNARX (a) e NNOE (b).

Do mesmo modo pode-se estimar a predição final do erro de Akaike do erro médio generalizado (*Akaike's final prediction error estimate of the average generalization error*) para ambos os modelos, que neste caso foi: $FPE_{NNARX} = 8,84 \cdot 10^{-11}$ e $FPE_{NNOE} = 6,02 \cdot 10^{-9}$, resultados semelhantes ao NSSE. O histograma dos erros preditos é mostrado nas Figuras 4-16(a;b), juntamente com os parâmetros da rede linearizados em cada intervalo de amostragem.




Figura 4-16 - Histograma do erro predito e coeficientes linearizados da rede neural ajustada. (a) modelo NNARX; (b) modelo NNOE.

Apesar da estrutura NNARX não ser recorrente, pode-se verificar seu comportamento na predição de k passos a frente (*k step ahead prediction*), através da alimentação de predições pretéritas na rede onde as observações não são disponíveis e considerando os resíduos não disponíveis como zero (nos modelos que utilizam resíduos). Este estudo permite verificar a possibilidade de utilizar um modelo na forma NNARX como modelo do processo, substituindo um modelo fenomenológico, embora o treinamento da rede neural tenha sido efetuado com os dados "reais" do processo (y) e não realimentação de saídas estimadas ($\hat{y}$). A Figura 4-17 mostra a predição 250 passos à frente para o um modelo NNARX como o descrito anteriormente. Como pode-se perceber pela figura, a capacidade preditiva do modelo é excelente, considerando que não foi treinado para considerar realimentação da saída.




Figura 4-17 – Predição pelo modelo NNARX 250 passos à frente e comparação com a saída "real" do processo.

Pode-se verificar se a rede neural treinada está com excesso de parâmetros ou conexões utilizando um procedimento de poda (*prunning*). Considerando uma rede com 10

neurônios na camada interna (que corresponde a um total de 81 parâmetros¹), criou-se a poda, ou seja, investigou-se a influência da retirada sistemática de pesos da rede sobre o desempenho da mesma frente ao conjunto de treinamento (NSSE e FPE) e ao conjunto de teste (NSSE), mostrado na Figura 4-18. O método de poda utilizado foi o OBS (*Optimal Brain Surgeon*). Observa-se que o NSSE para o conjunto de teste passa por um ponto de mínimo em torno de 60 parâmetros² que corresponde aproximadamente a uma rede neural com 7 neurônios na camada interna (57 parâmetros) ou exatamente à rede com 10 neurônios na qual são eliminadas 18 conexões. Se a segunda alternativa for escolhida, deve-se treinar novamente a rede retirando as conexões redundantes e as que resultam em uma deterioração no índice de desempenho. Isto resultará naturalmente em um método mais complexo de treinamento. Isto foi realizado e encontrou um NSSE para o conjunto de teste de $9,58.10^{-11}$, que é ligeiramente superior ao encontrado para uma rede cheia com 7 neurônios e, portanto, esta estrutura será utilizada.




Figura 4-18 – Efeito da poda (*pruning*) sobre os índices de avaliação da rede.

4.4.3 IDENTIFICAÇÃO DA DINÂMICA INVERSA DO PROCESSO

As estratégias de controle baseadas no modelo inverso do processo necessitam de um modelo identificado que provê a entrada (sinal de controle) a partir do conhecimento da saída desejada $y(t+1)$. Utilizando a mesma estrutura do regressor do item anterior, ou seja,

¹ no. de parâmetros = no. de neurônios + no. de neurônios $\times$ no. de entradas + no. de saídas + no. de saídas $\times$ no. de neurônios

² O número exato é 63.

$n_a = 3$, $n_b = 3$ e $n_k = 1$, com as entradas da rede neural NNARMAX sendo compostas pelas saídas atual e passadas do processo $[y(t), y(t-1), y(t-2)]$, pelas entradas passadas $[u(t-1), u(t-2)]$ e pela saída futura $y(t+1)$, sendo que tal saída futura é dada pela saída desejada, a referência $r(t+1)$, ao invés da saída real do processo, não disponível neste instante de tempo futuro. A saída da rede neural é a entrada atual $u(t)$ que deve ser aplicada ao processo. Um esquema de uma rede neural com 7 neurônios na camada intermediária é mostrado na Figura 4-19; nesta rede, todos os neurônios estão conectados a todas as entradas e a saída.




Figura 4-19 – Arquitetura da rede neural utilizada na identificação da dinâmica inversa do processo a ser controlado.

A entrada $u(t)$ "real" (obtida pelo modelo simulado) e a estimada pela rede neural são mostradas na Figura 4-20, juntamente com o erro predito (diferença entre a saída "real" e a predita pela rede). Percebe-se que houve um bom aprendizado por parte da rede neural.

Os pesos das redes neurais identificadas anteriormente encontram-se nos Anexos.

4.4.4 IDENTIFICAÇÃO UTILIZANDO REDES NEURAIS ESTÁTICAS

Uma maneira alternativa de realizar a identificação de sistemas dinâmicos é treinar uma rede neural de tal modo que ela "aprenda" a prever a variação que está ocorrendo nas variáveis de estado, ou seja, a rede quantifica o valor dado pela derivada em um modelo fenomenológico. Se um sistema for descrito por:

$$\frac{dx}{dt} = f(x(t), u(t)) \quad 4 - 13$$

este pode ser discretizado de tal modo a se prever o próximo valor de x , por exemplo, utilizando Euler:

$$x(t+1) = x(t) + f(x(t), u(t)) \cdot \Delta t \quad 4 - 14$$

ou seja, dado o valor dos estados em um determinado tempo (em geral o estado estacionário de referência), a rede neural será treinada para aprender a representar o valor de $f(x(t), u(t)) \cdot \Delta t$, ou, a rede prediz a variação que os estados sofrerão até o próximo intervalo de tempo.




Figura 4-20 – Identificação da dinâmica inversa do processo (entrada $u(t)$ "real" e predita pela rede neural)

Este método de identificação tem a vantagem de ser aplicável a qualquer tipo de sistema, com uma ou mais entrada e saída (SISO e MIMO). Acredita-se também que para sistemas com poucos dados experimentais, há mais vantagem em utilizá-lo, já que é mais fácil a partir dos mesmos capturar o comportamento incremental dos estados. A principal desvantagem do método é o grande número de dados que serão apresentados à rede neural quando o sistema possui maior número de estados. Isto porque quanto maior o número de estados, maior a possibilidade de combinação destes, necessária para realizar um completo mapeamento do sistema sob identificação.

Inicialmente definiu-se os intervalos de variação dos estados como mostrado na Tabela 4-2. O número possível de combinações entre as variáveis é $5 \times 5 \times 4 \times 4 \times 8 = 3200$,

acrescido do estado estacionário de referência. Assim, a matriz que será apresentada à rede neural terá 5 variáveis de entrada (C_{A1} , T_1 , C_{A2} , T_2 e q_C).

Utilizando o modelo fenomenológico e um intervalo de amostragem de 0,1 min foram gerados os dados de saída, ou seja, o incremento entre o estado atual e o estado no próximo intervalo de amostragem. Utilizaram-se 8 neurônios na camada interna com função de ativação tangente-sigmoidal e funções lineares na camada de saída. A capacidade da rede em prever a dinâmica do sistema foi considerada em duas possibilidades: (i) predição em "malha aberta"; (ii) predição em "malha fechada".

Tabela 4-2 – Combinação das variáveis utilizadas na identificação.

variável/estado	valor inicial	valor final	incremento	número de pontos
C_{A1}	0,06 mol/l	0,14 mol/l	0,02 mol/l	5
T_1	430 K	446 K	4 K	5
C_{A2}	0,005 mol/l	0,011 mol/l	0,002 mol/l	4
T_2	442 K	454 K	4 K	4
q_C	90 l/min	118 l/min	4 l/min	8

O primeiro caso parte do estado estacionário conhecido de referência e utiliza o incremento fornecido pela rede neural para prever o próximo valor dos estados, que por sua vez são novamente atualizados pela rede (Figura 4-21); no segundo caso, parte-se também do estado estacionário conhecido de referência e utiliza o incremento fornecido pela rede neural para prever o próximo valor dos estados, porém este é corrigido pelo valor obtido através do modelo (medida) para se calcular o próximo valor dos estados (Figura 4-22 e 4-23). Neste caso, os valores fornecidos pela rede não são utilizados sequencialmente, sendo utilizados somente até que se obtenha a medida real diretamente do processo.

Na simulação dinâmica efetuou-se um degrau de +10% na variável de entrada (vazão de refrigerante). Observa-se que há um *off set* significativo para a identificação em malha aberta e fechada para a concentração, sendo este bem mais acentuado para o primeiro caso. Isto significa que a rede não conseguiu "aprender" de modo conveniente o comportamento dinâmico do sistema, embora qualitativamente há um acompanhamento da tendência expressa pelo modelo dinâmico, ou seja, a rede conseguiu capturar o comportamento qualitativo de maneira adequada. Um dos fatores que levam à presença de *off sets* é a quantidade insuficiente de padrões utilizados na aprendizagem. Isto pode ser

reduzido aumentando a frequência dos dados apresentados, entretanto, isto significaria considerável aumento no tempo de treinamento.




Figura 4-21 – Identificação do sistema em "malha aberta" (Concentração e temperatura do primeiro reator; + processo "real"; - rede neural).




Figura 4-22 - Identificação do sistema em "malha fechada" (Concentração e temperatura do primeiro reator).




Figura 4-23 - Identificação do sistema em "malha fechada" (Concentração e temperatura do segundo reator).

4.5 CONTROLE DO PROCESSO UTILIZANDO REDES NEURAIS

Em todos os resultados que se seguem a saída do processo é forçada a seguir uma trajetória pré-estabelecida (que pode ser considerada como sendo uma referência fixa), sendo que em dois momentos distintos o sistema sofre a ação de uma perturbação na concentração do reagente A na corrente de entrada (C_{Af}), conforme segue:

- $0 \text{ min} \leq t \leq 9 \text{ min}$, $C_{Af} = 1 \text{ mol/L}$
- $9 \text{ min} < t \leq 16 \text{ min}$, $C_{Af} = 1,1 \text{ mol/L}$ (perturbação degrau de +10%)
- $16 \text{ min} < t \leq 25 \text{ min}$, $C_{Af} = 0,9 \text{ mol/L}$ (perturbação degrau de - 18%)

O intervalo de amostragem foi fixado em 0,1 min, com os seguintes limites impostos na variável manipulada: $60 \text{ L/min} \leq q_C \leq 140 \text{ L/min}$.

4.5.1 CONTROLE COM O CONTROLADOR CLÁSSICO PID

Inicialmente efetuou-se o controle do processo utilizando um controlador PID clássico, com algoritmo industrial, sendo a versão digital de:

$$D(s) = K_c \frac{1 + \tau_d s}{1 + \alpha \tau_d s} \frac{1 + \tau_i s}{\tau_i s} \quad 4 - 15$$

O desempenho deste é mostrado na Figura 4-24 ($K_C = 150 \text{ L}^2/\text{mol.min}$; $\tau_D = 3 \text{ min}$; $\tau_I = 0,25 \text{ min}$; $\alpha = 0,1$). O controlador PID é de difícil sintonia pois não há um método sistemático para realizar esta tarefa. Os métodos disponíveis na literatura de alocação de

poios pressupõem que o processo possa ser descrito de modo exato por uma função de transferência de 1ª ou de 2ª ordem, o que dificilmente se consegue para processos mais complexos, como o em estudo, composto por 4 equações diferenciais. Existem também os métodos empíricos da curva de reação, limitados a processos estáveis em malha aberta e com resposta equivalente a sistemas de 1ª ordem mais tempo morto. O método de Ziegler e Nichols baseia-se na análise no domínio da frequência e dependem de excitações cíclicas na entrada do processo, o que é de difícil obtenção em processos reais. Quando se dispõe de um modelo matemático fiel do processo, o meio mais conveniente é realizar a sintonia do controlador PID através de simulação computacional, o que obviamente envolve um procedimento tedioso por tentativa e erro, ou seja, um método completamente empírico de ajuste das constantes do controlador. Caso o modelo do processo não seja muito complexo, pode-se utilizar um método de otimização no qual procura-se minimizar uma função objetivo que depende do erro entre o valor da saída desejado (*set point*) e a saída real. As restrições passam a ser o modelo do processo, juntamente com as expressões matemáticas que descrevem a ação de controle (em geral um sistema algébrico-diferencial). O método garante a solução ótima para os valores das constantes proporcional, integral e derivativa para a faixa de operação de validade do modelo, porém é incapaz de lidar com mudanças ocorridas neste e com perturbações não previstas por ocasião da otimização.




Figura 4-24 – Desempenho do controlador PID (problema regulatório e supervisório).

Como era de se esperar, o controlador PID tem seu desempenho bastante deteriorado frente à perturbação de maior magnitude, ocorrida em 16 min, ocasionando mesmo um *off set* irreversível a partir de então na saída do processo.

4.5.2 CONTROLE COM MODELOS INVERSOS

O desempenho do sistema de controle pode ser melhorado de modo sensível, pelo menos com relação a capacidade do controlador em seguir a trajetória pré-estabelecida para a saída do processo e em rejeitar perturbações na carga, quando se utiliza um controlador inverso direto, no qual a ação de controle é calculada através de uma rede neural que foi previamente treinada para "aprender" a dinâmica inversa do processo, como mostrado na Figura 4-25. A desvantagem deste controlador, citada na literatura e observada nos resultados, é a característica *ringing* do controlador, isto é, a alta oscilação imposta na ação de controle, o que é extremamente indesejável.




Figura 4-25 - Desempenho do controlador inverso direto (problema regulatório e supervisório)

Uma tentativa de melhorar a ação de controle calculada através do controlador inverso direto é comparar a saída do processo com a saída predita por um modelo e em seguida alimentar esta diferença, combinada com o valor de referência desejado, no controlador inverso, levando assim a um controlador preditivo um passo a frente, ou seja, a configuração IMC apresentada no capítulo anterior. O valor alimentado no controlador

pode ser filtrado ou não; quando este é filtrado [$A_m(q) = 1 - 0,7/q$; $B_m(q) = 0,3$], ocorre uma "suavização" na trajetória de referência, o que pode ser observado na Figura 4-26.




Figura 4-26 - Desempenho do controlador inverso com modelo interno (IMC), com filtro (problema regulatório e supervisório)




Figura 4-27 - Desempenho do controlador inverso com modelo interno (IMC), sem filtro (problema regulatório e supervisório)

A Figura 4-27 mostra a mesma configuração de controle, porém sem filtro, o que causa uma leve deterioração no desempenho do controlador. Além de suavizar a trajetória

de referência, o filtro também tem a finalidade de atenuar a amplitude para altas frequências de oscilação do sinal de entrada, para o caso da presença de ruídos presentes na leitura do instrumento de medida na saída do processo y .

4.5.3 CONTROLE NÃO LINEAR

Utilizando duas redes neurais treinadas para representar o modelo do processo como descrito pela Eq. 3-49, efetuou-se o controle da variável C_{A2} através da linearização por retroalimentação, na qual a saída é forçada a seguir a trajetória de referência $r(t)$, sendo a ação de controle virtual $w(t)$ uma combinação linear apropriada das saídas passadas e da referência desejada, de tal modo a alocar de modo arbitrário os pólos do sistema em malha fechada, acrescida da integral do erro (diferença entre a saída do sistema e a referência desejada), para evitar problemas de *off set*. O polinômio característico escolhido foi $A_m(z) = z^3 - 1,4 z^2 + 0,49 z$, que possui como pólos $z = 0; 0,7; 0,7$ (todos pertencentes ao círculo unitário, como requer a teoria de controle discreto).

Os parâmetros de sintonia do controlador são os pólos do polinômio característico e a constante de integração ($1/\tau = 0,3$). A escolha do polinômio característico, como já foi mencionado é arbitrária, ou seja, a escolha é tal que proporciona estabilidade em malha fechada ($z < 1$), sendo que se os pólos apresentarem parte imaginária a saída possui comportamento oscilatório. Utilizando os parâmetros citados anteriormente, obtém-se como resultado a Figura 4-28.

Observa-se nesta figura que a trajetória de referência $r(t)$ é filtrada utilizando o polinômio característico de tal modo a se obter a referência "real" $y_m(t)$, a qual a saída do processo procura seguir de modo assintótico. O controlador exige bastante da ação de controle, o que é devido ao fato do controle linearizante por retroalimentação ser uma contrapartida não linear ao método de alocação de pólos com todos os zeros cancelados. A grande vantagem desta estratégia de controle é a sua simplicidade e a facilidade de sintonia, uma vez disponível as redes neurais necessárias para representar o processo na forma de um modelo afim.




Figura 4-28 - Desempenho do controlador linearizante por retroalimentação (problema regulatório e supervisório)

4.5.4 CONTROLE POR LINEARIZAÇÃO INSTANTÂNEA

A linearização instantânea, como já foi descrito no capítulo anterior, utiliza uma rede neural previamente treinada para representar a dinâmica do processo e a partir desta "extrai" a cada intervalo de amostragem um modelo linear, que por sua vez é empregado no projeto da ação de controle, através da utilização da teoria de controle linear.

Uma das possibilidades de utilização da teoria de controle linear é a técnica da alocação dos pólos (*pole placement*), com ou sem cancelamento dos zeros do processo. Ambos os casos foram considerados aqui. Na Figura 4-29 tem-se o caso em que todos os zeros são cancelados e na Figura 4-30, o mesmo controlador, porém sem o cancelamento dos zeros. Observa-se a superioridade inquestionável do segundo caso, no qual a resposta do processo segue de forma muito próxima a referência desejada, sendo a ação de controle calculada de modo parcimonioso, com a ausência de *ringing*, presente no primeiro caso.

Os parâmetros de projeto utilizados foram:

- numerador do modelo desejado: $B_m = 0,09$
- denominador do modelo desejado: $A_m = z^2 - 1,4z + 0,49$
- polinômio de observação: $A_o = 1$
- fator pré-especificado de R : $A_r = [1, -1]$ (necessário para ação integral)

- fator pré-especificado de S : $A_S = 1$

Os polinômios R e S são calculados através da solução da equação de Diophantine:

$$A.R + B.S = A_C = A_m.A_O$$

onde A_C é o polinômio característico fatorado em A_m e A_O .




Figura 4-29 - Desempenho do controlador linear por alocação dos pólos, com todos os zeros cancelados (problema regulatório e supervisório)

Uma outra alternativa, uma vez disponível um modelo linear do processo, é a utilização do algoritmo GPC (*Generalized Predictive Controller*), que calcula a ação de controle baseado na minimização de uma função custo. Os excelentes resultados obtidos para este controlador são mostrados na Figura 4-31, sendo utilizados os seguintes parâmetros:

- Horizonte mínimo de predição: $N_1 = 1$;
- Horizonte máximo de predição: $N_2 = 7$;
- Horizonte de controle: $N_u = 2$;
- Fator peso sobre a diferença do sinal de controle (fator de supressão): $\rho = 10^{-8}$;

Este controlador é de relativa facilidade de sintonia, sendo que a escolha dos parâmetros acima é mais ou menos arbitrária, porém com um pouco de experiência qualquer praticante desta técnica consegue após alguns poucos ajustes chegou-se à valores

razoáveis para estas constantes. Outra grande vantagem deste algoritmo é a rapidez e confiabilidade de sua solução, já que como o processo é descrito por um modelo linear, os métodos de otimização empregados possuem solução analítica, o que é de extrema importância do ponto de vista de controle na prática.




Figura 4-30 - Desempenho do controlador linear por alocação dos pólos, sem cancelar os zeros (problema regulatório e supervisório)

Um atrativo interessante do controlador preditivo é a sua capacidade de "antever" as mudanças que a saída sofrerá, para o caso supervisório, fazendo com que mesmo antes da mudança do *set point* ocorrer, a saída já procura acompanhar tal mudança futura, devido à sua capacidade preditiva; o quanto esta antecipação ocorre, depende do tamanho do horizonte de predição.

4.5.5 CONTROLE PREDITIVO NÃO LINEAR (NPC)

A última estratégia de controle testada foi o controle preditivo não linear (NPC), utilizando rede neural como modelo do processo. O método de otimização empregado foi o de Quasi-Newton, com os seguintes parâmetros do controlador:

- Horizonte mínimo de predição: $N_1 = 1$;
- Horizonte máximo de predição: $N_2 = 5$;
- Horizonte de controle: $N_u = 3$;
- Fator peso sobre a diferença do sinal de controle (fator de supressão): $\rho = 10^{-8}$;

Obviamente, quanto maior o horizonte de predição, maior é o esforço computacional gasto no cálculo da ação de controle, sendo que aumenta também o *off set* da saída controlada. O controlador NPC é mais sensível à mudanças nas dimensões dos horizontes de predição e controle, sendo que esta estratégia possui excelente desempenho no caso supervisório (Figura 4-32), porém o mesmo não ocorre para o caso combinado supervisório e regulatório (Figura 4-33), apresentando considerável *off set* neste último caso. Acredita-se que tal *off set* se deve ao fato de que após a última perturbação, o modelo de controle não foi mais capaz de prever com precisão as saídas do processo.




Figura 4-31 - Desempenho do controlador linear preditivo (GPC) aproximado (problema regulatório e supervisório)




Figura 4-32 - Desempenho do controlador preditivo não linear (problema supervisório)




Figura 4-33 - Desempenho do controlador preditivo não linear (problema regulatório e supervisório)

4.5.6 AVALIAÇÃO DOS CONTROLADORES SEGUNDO CRITÉRIOS DE DESEMPENHO

Uma avaliação quantitativa do desempenho dos controladores aplicados ao caso-estudo pode ser feito a partir da utilização dos critérios de desempenho baseados na integral do erro, sendo os mais comuns (SEBORG *et al.*, 1989):

- ISE (*Integral of the Squared Error*):

$$ISE = \int_0^{\infty} [e(t)]^2 dt \quad 4 - 16$$

- IAE (*Integral of the Absolute value of the Error*):

$$IAE = \int_0^{\infty} |e(t)| dt \quad 4 - 17$$

- ITAE (*Integral of The time-weighted Absolute Error*):

$$ITAE = \int_0^{\infty} t|e(t)| dt \quad 4 - 18$$

Os valores para cada uma das estratégias de controle são mostrados na Tabela 4-3.

Tabela 4-3 – Critério de desempenho dos controladores utilizados.

Estratégia de controle	ISE	IAE	ITAE
Controle inverso direto	$1,28 \cdot 10^{-4}$	$3,33 \cdot 10^{-2}$	$3,55 \cdot 10^{-1}$
IMC com filtro	$1,36 \cdot 10^{-4}$	$3,29 \cdot 10^{-2}$	$3,08 \cdot 10^{-1}$
IMC sem filtro	$1,39 \cdot 10^{-4}$	$3,40 \cdot 10^{-2}$	$3,52 \cdot 10^{-1}$
Linearização por retroalimentação	$1,61 \cdot 10^{-4}$	$4,23 \cdot 10^{-2}$	$4,89 \cdot 10^{-1}$
Linearização instantânea com zeros cancelados	$1,67 \cdot 10^{-4}$	$4,56 \cdot 10^{-2}$	$5,73 \cdot 10^{-1}$
Linearização instantânea sem cancelar zeros	$1,33 \cdot 10^{-4}$	$3,08 \cdot 10^{-2}$	$3,09 \cdot 10^{-1}$
Linearização instantânea sem cancelar zeros (*)	$1,64 \cdot 10^{-5}$	$1,15 \cdot 10^{-2}$	$1,17 \cdot 10^{-1}$
GPC aproximado	$4,47 \cdot 10^{-5}$	$1,48 \cdot 10^{-2}$	$1,55 \cdot 10^{-1}$
NPC supervisor	$4,34 \cdot 10^{-5}$	$1,25 \cdot 10^{-2}$	$1,04 \cdot 10^{-1}$
NPC supervisor/regulatório	$2,92 \cdot 10^{-4}$	$6,13 \cdot 10^{-2}$	1,01
PID industrial	$8,07 \cdot 10^{-4}$	$9,59 \cdot 10^{-2}$	1,41
PID algoritmo da velocidade	$3,30 \cdot 10^{-3}$	$1,71 \cdot 10^{-1}$	3,05

(*) critério de desempenho calculado em relação à referência e não ao *set point*.

Uma observação que deve ser feita é que os critérios de desempenho são calculados sempre em relação ao *set point* desejado. Entretanto, para as estratégias de controle que utilizam filtragem no valor do *set point*, gerando uma trajetória de referência mais "suave", o valor a ser atingido que o controlador "enxerga" é o de referência e não o *set point*. Isso faz com que os dados fornecidos pelos parâmetros ISE, IAE e ITAE não permitam uma comparação rigorosa entre os controladores. Como exemplo, o controlador linear por alocação de pólos, sem cancelamento de zeros, possui valores quantitativos dos parâmetros de desempenho ISE e ITAE piores do que os do controlador IMC, entretanto, visual e

qualitativamente percebe-se que seu desempenho é bem superior. Isto pode ser verificado quando os critérios de desempenho são calculados em relação à referência e mostrados na Tabela 4-3 para ilustração.

Os valores obtidos através dos critérios de desempenho devem ser analisados também quanto ao significado intrínseco advindo da definição de cada um deles. Isto porque o índice ISE, por exemplo, tende a penalizar mais os erros maiores, em relação aos índices LAE e ITAE. O índice ITAE, por sua vez, penaliza mais erros que persistem por longos períodos de tempo. Do ponto de vista da sintonia de controladores baseando-se nos critérios de desempenho, a literatura recomenda que seja efetuada através do critério ITAE, pois leva a um ajuste de controladores mais conservativo. Segundo este critério, a melhor estratégia de controle foi o GPC aproximado e a pior o controlador PID (em ambas as versões).

4.6 CONCLUSÕES

Neste capítulo foi apresentada uma metodologia sistemática de identificação e controle de um processo representativo da Engenharia Química, a saber, um sistema reacional composto por dois reatores tanques com mistura perfeita e conectados em série, utilizando redes neurais artificiais, que foi capaz de capturar com sucesso as complexidades da dinâmica deste processo, em especial sua característica altamente não linear.

A partir da identificação da dinâmica do processo (dinâmica direta e inversa), desenvolveram-se e aplicaram-se diferentes estratégias de controle com o objetivo de regular/controlar a saída do sistema (concentração do reagente A na saída do 2º reator), através da manipulação da vazão de fluido refrigerante. Diferentes níveis de utilização do modelo neural foram empregados na síntese das estratégias de controle, indo do controle inverso direto, que utiliza o modelo neural inverso diretamente como controlador, ao controle preditivo não linear, que faz uso do modelo em um procedimento complexo de otimização.

Não foi efetuada investigação acerca da capacidade do modelo neural em prever os múltiplos estados estacionários do sistema. Deixa-se para trabalhos futuros esta tarefa, tendo em vista o interesse em aplicar as técnicas de controle e a escassez de tempo para se investigar todas as possibilidades referentes ao modelo neural.

A investigação apresentada neste capítulo abordou a identificação e controle de um processo com apenas uma entrada e uma saída (SISO) e a partir da experiência e sucesso do mesmo, pode-se estender a investigação para um processo com mais de uma entrada e mais de uma saída (MIMO).

Capítulo 5

ESTUDO DE CASO: EVAPORADOR DE DUPLO EFEITO

5 ESTUDO DE CASO: EVAPORADOR DE DUPLO EFEITO

5.1 INTRODUÇÃO

O objetivo da evaporação é concentrar uma solução consistindo de um soluto não volátil e um solvente volátil. A evaporação é conduzida pela vaporização de uma porção do solvente para produzir uma solução concentrada de licor espesso, sendo uma operação unitária amplamente utilizada na indústria alimentícia, de polpa e papel, farmacêutica, mineração, dentre outros setores.

De acordo com McCABE *et al.* (1993) os principais tipos de evaporadores tubulares que utilizam vapor como fonte de calor em uso atualmente são:

1. Evaporadores verticais de tubo longo
 - a) escoamento para cima (filme ascendente ou *climbing-film*);
 - b) escoamento para baixo (filme descendente ou *falling-film*);
 - c) circulação forçada;
2. Evaporadores de filme agitado

Os evaporadores de escoamento para cima são indicados para líquidos que tendem a formar espuma. Os de filme descendente são indicados para materiais com alta sensibilidade ao calor (por exemplo, suco de laranja) e líquidos viscosos. Os evaporadores de circulação forçada são indicados para líquidos sensíveis ao calor, pois possuem pequeno tempo de residência e líquidos que tendem a formar espuma. Os com filme agitado são indicados para líquidos viscosos e sensíveis ao calor, tais como gelatina, látex de borracha, antibióticos, sucos de frutas, porém têm como desvantagem um alto custo de investimento e de manutenção das partes móveis internas.

Um terceiro tipo de evaporador, que é o de tubos verticais curtos, apesar de estar em desuso na maioria das unidades industriais, continua sendo o modelo ainda amplamente utilizado na indústria de açúcar e álcool.

Uma descrição detalhada dos diferentes tipos de evaporadores, vantagens, desvantagens, aplicações indicadas, etc., pode ser encontrada em PERRY & GREEN (1997). Segundo estes autores, a seleção do tipo de evaporador mais indicado para uma aplicação particular é governada pelas características da alimentação e do produto. Pontos a

serem considerados são: presença ou não de cristalização durante a evaporação, formação de incrustações, qualidade do produto (pode implicar em baixo tempo de retenção ou operação à baixas temperaturas, os quais serão restrições ao sistema de controle), corrosão e formação de espuma.

Três grandezas são importantes quando se trata de sistemas de evaporação:

CAPACIDADE: número de quilogramas de solvente evaporados por hora, ou:

$$capacidade = \frac{kg \text{ de solvente evaporado}}{h}$$

ECONOMIA: número de quilogramas evaporados de solvente por quilograma de vapor alimentado à unidade, ou:

$$economia = \frac{kg \text{ de solvente evaporado}}{kg \text{ de vapor d' água alimentado}}$$

CONSUMO DE VAPOR:

$$consumo \text{ de vapor } [kg/h] = \frac{capacidade}{economia}$$

Na maioria dos casos de evaporadores industriais o solvente é a água.

A necessidade de economia de vapor obriga o uso do princípio de múltiplo efeito¹. Na evaporação em múltiplo efeito, o vapor da ebulição do caldo de um corpo é usado como fonte de calor para o corpo seguinte. Isto pode ser realizado pela redução da pressão no segundo corpo, de modo a reduzir o ponto de ebulição. Em um arranjo em série, ou múltiplo efeito, o Princípio de Rillieux estabelece que uma unidade de vapor evaporará tantas unidades de água quantos forem os corpos ou efeitos. Assim, em um conjunto de quatro unidades em série ou quádruplo efeito, geralmente usado, uma unidade de vapor evaporará quatro unidades de água. Tal valor não é rigorosamente correto, mas exato o suficiente para cálculos de rotina.

A utilização de evaporadores na Indústria Alimentícia é ampla. Frequentemente, nesta indústria, uma matéria prima ou um produto alimentício contém mais água que a necessária no produto final. Quando o produto alimentício é um líquido, a forma mais fácil

¹ Consumo de vapor de água (kg de vapor/kg de água evaporada) para um, dois e três efeitos, respectivamente: 1,1; 0,57; 0,40. (EARLE, pág. 105)

de eliminar a água é, em geral, evaporando-a mediante calor. Exemplos: concentração de polpa de tomate; concentração de sucos de frutas; concentração do leite (para obtenção de leite condensado ou leite em pó).

Outro setor que no Brasil a etapa de evaporação é crucial é a indústria açucareira, sendo que a seção de evaporação realiza a primeira etapa no processo de recuperação do açúcar do caldo. A prática usual é concentrar o caldo clarificado até cerca de 65° Brix, o que requer a remoção de aproximadamente 75% da água. A necessidade de economia de vapor obriga o uso do princípio de múltiplo efeito e a água condensada serve para alimentar as caldeiras. (PAYNE, 1989).

Por ser uma operação unitária que utiliza uma grande quantidade de energia (na forma de vapor d'água) é grande o interesse com relação ao aprimoramento da operação e automação das unidades de evaporação tendo em vista principalmente a redução da quantidade de energia térmica utilizada e a obtenção de um produto homogêneo, fundamental às operações unitárias que se seguem à evaporação.

Este capítulo tem como objetivo fundamental contribuir no melhor entendimento do processo de evaporação e propor malhas de controle eficazes no controle do mesmo. Os resultados apresentados serão obtidos via simulação computacional, mas espera-se que os mesmos sejam estímulo ao desenvolvimento futuro de pesquisas nesta área que envolvam também a prática experimental, indispensável na validação das conclusões que serão aqui apresentadas.

5.2 MODELAGEM MATEMÁTICA E CONTROLE AUTOMÁTICO DE EVAPORADORES: REVISÃO BIBLIOGRÁFICA

Segundo PAYNE (1989), nos evaporadores utilizados na indústria açucareira, as variáveis controladas são:

- (a) **pressão absoluta (vácuo):** controlada pela regulagem da quantidade de água que vai para o condensador, mantendo desse modo uma temperatura do xarope no último corpo ao redor de 55°C. O valor do ajuste (*set point*) da pressão absoluta dependerá também do brix do xarope. Na faixa de 65 a 70, a pressão absoluta será da ordem de 10 cm de coluna de mercúrio;
- (b) **brix do xarope:** é controlado pela regulagem da válvula de saída do xarope da última caixa. Um mínimo de 65° Brix é o padrão. Deve ser evitada uma

concentração acima de 70°, para se prevenir a possibilidade de cristalização na evaporação;

- (c) **nível de líquido nos tubos:** constitui um fator importante na taxa de transferência de calor. Se o nível estiver muito baixo, a superfície de aquecimento dos tubos não será usada integralmente, e os tubos podem secar na parte superior. Se estiver muito alto, a parte inferior do tubo fica afogada com caldo que se move a baixa velocidade, não se obtendo, por conseguinte, a máxima evaporação. O nível ótimo é aquele em que o líquido começa a ser arrastado para o topo dos tubos através das bolhas de vapor, com somente um pequeno fluxo na parte superior do espelho. Este nível varia com o tamanho dos tubos, temperatura, taxa de transferência de calor, incrustações e viscosidade do caldo. Sob boas condições, o nível ótimo está cerca de 25% do comprimento dos tubos, raramente se encontrando acima de 40%;
- (d) **alimentação:** deve ser mantida uniforme, utilizando-se o tanque de caldo como controle-pulmão. Acima de um certo nível, a alimentação é sinalizada de modo a reduzir a quantidade de caldo que chega. Abaixo de um certo nível, reduz-se o suprimento de vapor à evaporação, a um nível mínimo, uma válvula de água é aberta para manter a evaporação em funcionamento.

Os parâmetros descritos anteriormente são importantes pois definem os *set points* e as restrições com os quais o sistema de controle automático terá que lidar. Como cada uma das variáveis controladas sofre influência direta das demais, trata-se de um problema de **controle multivariável**, ou seja, um sistema com acoplamento de malha de controle.

Encontram-se na literatura duas classes de modelos matemáticos de evaporadores:

1. Modelos empíricos
2. Modelos fenomenológicos

Uma das primeiras investigações tratando da modelagem, simulação e controle automático de evaporadores foram os trabalhos de RANDALL *et al.* (1971) e CARLSON *et al.* (1971). O modelo matemático fenomenológico foi desenvolvido com o propósito de ser utilizado em uma lei de controle *feedback-feedforward* que fosse capaz de compensar as flutuações de desempenho do evaporador utilizado na concentração de polpa de tomate causadas por oscilações na concentração de entrada e depósito nas paredes dos tubos. Os estudos foram realizados em uma planta piloto equipada com medidores em linha de

concentração (refratômetros), sendo controlada por um computador analógico. Ressalta-se nestes trabalhos o grau de sofisticação das metodologias propostas considerando as limitações tecnológicas à época. Os resultados mostram a capacidade do sistema de controle em manter a concentração de saída o mais estável possível.

O modelo fenomenológico dinâmico de evaporadores mais utilizado é o que foi proposto por NEWELL e FISHER (1972). Estes autores dividiram o evaporador em várias regiões distintas (região do vapor; superfície de transferência de calor; região do líquido) e propuseram um equacionamento transiente para cada uma delas. Apesar de parecer hoje óbvio, tal procedimento foi até certo ponto inovador na época e continua sendo a principal referência na modelagem de evaporadores e de outras operações unitárias. A grande vantagem deste modelo é que ele é bastante flexível quanto à sua complexidade. Isto porque as equações dinâmicas são funções de parâmetros que dependem do equilíbrio termodinâmico entre o líquido e o vapor gerado e também de parâmetros associados à transferência de calor entre o vapor (fonte de calor) e o líquido a ser concentrado. A escolha por parte do modelador das equações a serem utilizadas para representarem tais fenômenos irá ditar a complexidade do modelo, que pode ir, por exemplo, da consideração de idealidade às formas mais complexas de não idealidade, para os fenômenos termodinâmicos envolvidos.

LOZANO *et al.* (1984) utilizaram dados experimentais de uma planta de evaporadores de triplo efeito em escala industrial para identificar modelos empíricos que foram empregados para comparar configurações de controle alternativas (através de simulação). Os autores utilizaram duas técnicas experimentais de identificação: (1) um procedimento gráfico aplicado à resposta a um degrau, com um modelo de segunda ordem mais tempo morto, e (2) um teste pulso, com os dados interpretados no domínio da frequência.

TONELLI *et al.* (1990) apresentaram uma sofisticação no modelo de NEWELL e FISHER (1972) pois introduziram um pré-aquecimento em contracorrente da solução e a consideração de atrasos ocasionados por tempo morto entre e nos efeitos. Com estas considerações, desenvolveram um simulador, validado com dados experimentais, para um evaporador de triplo efeito utilizado na concentração de suco de maçã. Tal simulador teria como propósitos: (i) descrever o comportamento particular dos evaporadores sujeitos a perturbações conhecidas e desconhecidas; (ii) investigar procedimentos de *start-up*; (iii)

facilitar o *start-up* do processo; (iv) projetar controladores para estabilizar a unidade e/ou acelerar a recuperação destes frente à perturbações randômicas ou impostas.

RUNYON *et al.* (1991) propuseram um modelo fenomenológico dinâmico para um evaporador de duplo efeito operado em contracorrente, o que não tem sido usual na literatura. A estrutura do modelo é a mesma apresentada por NEWELL e FISHER (1972). Apresentam parâmetros completos de transferência de calor e equilíbrio termodinâmico para o caso da polpa de tomate. O objetivo do modelo desenvolvido é a investigação de estratégias alternativas de controle automático da unidade.

QUAAK *et al.* (1994) descrevem uma investigação realizada na identificação e controle de um evaporador NIZO de quádruplo efeito. Estes autores compararam a dinâmica do evaporador obtida com o simulador NIZO-STREAM, que é um simulador para evaporadores de filme descendente, com um modelo na forma caixa-preta. O processo possui três entradas (vazão de alimentação; vazão de vapor ao vaporizador; vazão do refrigerante no condensador) e três saídas (sólidos totais no concentrado; vazão do concentrado; temperatura do concentrado). A concordância obtida entre os dois modelos foi razoável, sendo registrada uma diferença significativa entre os ganhos estáticos dos mesmos. Os melhores resultados foram obtidos para frequências baixas. Os modelos obtidos foram utilizados por VAN WIJCK *et al.* (1994) no desenvolvimento de um controlador multivariável, sendo que ambos resultaram em controladores com bom desempenho. A estratégia de controle utilizada foi o controlador IMC supervisor que manipula os *set points* das vazões, que são reguladas por controladores PID's com laços locais. O controlador IMC possui um compensador *feedforward* além do laço *feedback* convencional. A capacidade do controlador em levar o processo a seguir trajetórias de *set points* pré-estabelecidas foi excelente, incluindo a etapa de *start-up*. Os autores chamam a atenção para os benefícios significativos obtidos com controladores bem desenvolvidos e sintonizados, tal como a redução de custos, advinda da melhor qualidade dos produtos, maior rendimento e economia de energia e matéria prima.

DAOUTIDIS e KUMAR (1994) também utilizaram o modelo de NEWELL e FISHER (1972) na investigação de estratégias de controle não linear por geometria diferencial no controle da planta piloto do evaporador de duplo efeito. Os estudos foram realizados por simulação computacional.

DRISCOLL *et al.* (1995) desenvolveram um modelo matemático simplificado de um evaporador utilizado na indústria alimentícia baseando-se em dados operacionais de dois anos de operação. O objetivo do modelo é prever o comportamento futuro da planta e utilizá-lo em uma estratégia de controle preditiva. Resultados obtidos via simulação computacional mostraram a capacidade da estratégia de controle proposta em forçar o sistema a ter uma saída pré-estabelecida.

RUSSELL e BAKKER (1997) apresentaram o desenvolvimento de um modelo baseado em redes neurais de um evaporador de filme descendente de triplo efeito, em escala piloto. O modelo foi desenvolvido com o propósito de ser utilizado em um sistema de controle preditivo. Os dados utilizados para a geração do modelo neural foram obtidos através da simulação de um modelo fenomenológico. O procedimento adotado no desenvolvimento do modelo neural foi o de dividir o modelo completo em um grupo de sub-redes, cada um modelando um elemento específico do sistema global. Tal procedimento resultou em um modelo na forma modular, que segundo os autores dá ao mesmo a capacidade de capturar informações teóricas através de sua topologia assim como informações empíricas. O modelo desenvolvido foi utilizado para prever a dinâmica do processo n passos a frente, predição esta necessária no cômputo da ação de controle preditiva (não implementada pelos autores).

ELHAQ *et al.* (1999) escolheram o evaporador de múltiplo efeito utilizado na indústria açucareira para realizar um estudo de modelagem, identificação e controle, tanto teórico, quanto experimental. Um modelo fenomenológico foi desenvolvido com o propósito de ser referência (*benchmark*) para um modelo empírico, desenvolvido para ser utilizado como modelo de controle em um controlador GPC. Os parâmetros do modelo fenomenológico foram estimados recursivamente através do algoritmo de Bootstrap, que é uma variante do algoritmo do filtro de Kalman. A identificação utilizando modelos lineares multivariáveis na forma caixa-preta foi realizada através de uma estrutura de modelo CARIMA (*Controlled Auto-Regressive Integrated Moving Average*), com duas saídas (brix do xarope; pressão no segundo efeito) e duas entradas (vazão de vapor; vácuo no 5º efeito). A estrutura do modelo foi obtida para minimizar o índice de desempenho AIC (*Akaike Information Criterion*). O modelo identificado foi implementado em um controlador GPC e o desempenho deste avaliado através de simulação e experimentalmente. Os resultados

obtidos foram bons, sendo que os autores chamam a atenção para a etapa de maior dificuldade na implementação do controlador: a identificação e a validação do modelo.

Recentemente CADET *et al.* (1999) propuseram um novo modelo fenomenológico para um evaporador de filme ascendente (múltiplo efeito) utilizado na indústria açucareira baseado em equações de balanço e representações fenomênicas. O modelo foi validado utilizando um estudo de sensibilidade paramétrica, com dados coletados de uma planta industrial. O modelo obtido foi incluído em uma estrutura de controle preditiva não linear, sendo que os resultados obtidos via simulação foram encorajadores para se pensar em uma implementação prática.

BENNE *et al.* (2000) utilizaram redes neurais para modelar um evaporador de múltiplo efeito utilizado na indústria açucareira com propósito de utilizar tal modelo no controle preditivo da unidade. A identificação foi realizada com dados experimentais de uma planta industrial. A estrutura de rede utilizada foi a NARMAX, com três camadas, com uma entrada e uma saída (SISO), portanto uma rede recorrente. O modelo identificado foi utilizado no controlador preditivo MPC e resultados obtidos via simulação computacional são apresentados, sendo o próximo objetivo dos autores a implementação experimental do controlador.

O grupo de pesquisa australiano liderado pelo Professor Moses O. Tadé tem publicado uma série de artigos referentes à utilização do controle não linear por geometria diferencial no controle de evaporadores utilizados em refinarias de alumina (*liquor burning process evaporator associated with the Bayer Process*). TO *et al.* (1995) consideraram um sistema composto por um tanque *flash*, com reciclo e desenvolveram um modelo matemático fenomenológico no qual as variáveis de estado são o nível de líquido, a densidade e a temperatura do líquido no tanque. O modelo considerado é apresentado sem os seus parâmetros de operação industrial, sendo utilizado no desenvolvimento de: (i) um controlador não linear que lineariza de modo exato a relação entrada-saída; (ii) um controlador GMC; sendo que o primeiro caso resultou em melhor desempenho. Os resultados foram obtidos por simulação computacional. A implementação prática foi realizada por TO *et al.* (1998), sendo o controlador não linear multivariável (GLC) comparado com o controlador clássico PI. Em KAM e TADÉ (1999) os autores utilizaram um controlador não linear linearizante por retroalimentação de estados (SISO), sendo os estados não medidos estimados em linha utilizando um observador de estados. Os

resultados foram obtidos via simulação. Ressalta-se a complexidade matemática do controlador e observador desenvolvidos, com inúmeros parâmetros de ajuste. Em KAM e TADÉ (2000) há uma avaliação geral acerca do controle não linear de evaporadores, com destaque para o controle geométrico diferencial.

NEWELL e LEE (1988) consideraram apenas o segundo efeito do evaporador estudado por NEWELL e FISHER (1972) e realizaram um estudo completo acerca do controle do mesmo considerando as etapas de identificação, controle *feedforward*, desacoplamento de malhas, controle multivariável, estimativa de estados, compensação de tempo morto, controle adaptativo, preditivo e lógica nebulosa. Esta referência é bem didática e consiste em uma excelente fonte de estudos iniciais em estratégias de controle clássicas e avançadas, servindo como *benchmarking* para o desenvolvimento de outros estudos mais aprofundados para esta operação unitária e de outras. Recentemente, GOVATSMARK e SKOGESTAD (2001) utilizaram este mesmo efeito e baseado no modelo matemático do mesmo, estudaram várias estruturas de controle possíveis de serem implementadas, tendo como discriminante a minimização de uma função objetivo ditada por critérios econômicos. Conjuntos de variáveis controladas foram escolhidos (a *set points* constantes) de tal modo a operar o processo próximo ao ótimo do ponto de vista econômico ("controle auto-otimizante") em face às perturbações e erros de implementação. Os autores realizaram também um estudo analítico de estabilidade e controlabilidade para os conjuntos de variáveis controladas mais promissores.

5.3 MODELO DINÂMICO DE EVAPORADOR DE DUPLO EFEITO

As considerações feitas anteriormente com relação à modelagem de evaporadores são ilustradas através do modelo proposto por SEBORG *et al.* (1989) para um evaporador usado para concentrar uma solução diluída de um único soluto em um solvente volátil, como mostrado na Fig. 1. O modelo matemático é desenvolvido levando em conta as seguintes considerações:

1. O líquido é agitado de modo perfeito como resultado da violenta ebulição que ocorre;
2. A capacitância térmica do vapor é negligenciável comparada com a capacitância térmica do líquido;
3. A dinâmica da fase vapor é negligenciável;

4. A corrente de alimentação e as correntes de fundo têm uma densidade molar constante c e uma capacidade térmica constante C_{Pl} ;
5. O vapor e o líquido estão em equilíbrio térmico sempre;
6. Perdas de calor e efeitos de calor de solução são negligenciáveis;

5.3.1 Balanço de massa global

$$Ac \frac{dh}{dt} = F - B - D \quad 5 - 1$$

onde F , B e D são vazões molares, A é área de seção transversal e c é a densidade molar (mol/m^3). O peso molecular médio da solução é assumido como sendo constante, pois as mudanças na composição são pequenas.




Figura 5-1 – Diagrama esquemático de um evaporador contínuo.

5.3.2 Balanço de massa do soluto

$$Ac \frac{d(h x_B)}{dt} = F x_F - B x_B \quad 5 - 2$$

onde x_B e x_F denotam fração molar.

5.3.3 Balanço de energia

$$AC_{Pl} \frac{d(hT)}{dt} = C_{Pl} F T_F - C_{Pl} B T - C_{Pv} D T + UA_s (T_s - T) - \Delta H_v E \quad 5 - 3$$

onde:

C_{Pl} = calor específico do líquido

C_{Pv} = calor específico do vapor

A_s = área de transferência de calor

U = coeficiente global de transferência de calor

ΔH_v = calor latente de vaporização

E = taxa de evaporação

T_s = temperatura do vapor

Na equação anterior a temperatura de referência associada com o fluir da energia foi eliminada algebricamente. Para operação normal, mudanças com o calor sensível no líquido são pequenas comparadas com mudanças devido ao calor latente associado com a condensação do vapor e a evaporação do solvente. Consequentemente, o calor transferido do vapor que condensa é utilizado principalmente para evaporar o solvente. Isto faz com que a derivada na equação anterior seja pequena, sendo tal equação então aproximada por:

$$0 = UA_s(T_s - T) - \Delta H_v E \quad 5 - 4$$

ou

$$E = \frac{UA_s(T_s - T)}{\Delta H_v} \quad 5 - 5$$

5.3.4 Balanço material no vapor

$$\frac{1}{M} \frac{d(\rho V)}{dt} = E - D \quad 5 - 6$$

onde ρ é a densidade do vapor, V é o volume do vapor e M é o peso molecular do solvente.

5.3.5 Equações de Estado

A densidade do vapor ρ pode ser relacionada à pressão P e à temperatura T por uma equação de estado:

$$\rho = \phi_l(P, T) \quad 5 - 7$$

5.3.6 Relação da Pressão de Vapor

A pressão P no evaporador é igual à pressão de vapor da solução de líquido P_{vap} , a qual depende da temperatura T . Esta dependência com a temperatura pode ser expressa com sendo $P_{vap} = \phi_2(T)$. Desde que $P = P_{vap}$, pode-se escrever que:

$$P = \phi_2(T) \quad 5 - 8$$

5.3.7 Relação do volume

Desde que o nível do líquido pode mudar, o volume do vapor P também pode mudar. Entretanto, estas duas variáveis estão relacionadas por:

$$V_o = V + A.h \quad 5 - 9$$

onde V_o é o volume fixo do evaporador.

5.3.8 Relação Termodinâmica

Se o vapor d'água utilizado for saturado, a relação entre a pressão deste vapor e a temperatura pode ser obtida a partir de uma tabela de dados de vapor d'água:

$$P_s = \phi_3(T_s) \quad 5 - 10$$

Portanto, o modelo dinâmico simplificado do evaporador consiste de oito equações, Eq. 5-1, Eq. 5-2 e Eq. 5-5 até Eq. 5-10, e 14 variáveis, $h, F, B, D, x_B, x_F, T, T_F, T_S, E, \rho, V, P$ e P_S . Então, há seis graus de liberdade. Entretanto, as condições de operação (F, T_F e x_F) são normalmente fixadas por operações unitárias anteriores ao evaporador. Conseqüentemente, o número máximo de variáveis que podem ser manipuladas é $6 - 3 = 3$.

5.3.9 O Modelo de NEWELL e FISHER

A primeira etapa no estudo do sistema de controle é o desenvolvimento de um modelo matemático simples e confiável do processo. Na Fig. 5-2 é mostrado o diagrama esquemático de um evaporador de duplo efeito, em escala piloto, considerado por NEWELL e FISHER (1972). A solução concentrada entra no primeiro efeito a uma vazão de alimentação F , concentração do soluto C_f , e a temperatura T_f . Considerou-se uma solução de alimentação composta de trietilenoglicol em água. Vapor d'água a uma vazão S_f é injetado na calandra do primeiro evaporador para vaporizar a água, produzindo a corrente de vapor O_1 . O efluente líquido do primeiro efeito B_1 a uma concentração C_1 é enviado para o lado dos tubos do segundo efeito e é vaporizado posteriormente sob uma pressão reduzida

$$\frac{dW_1}{dt} = F - B_1 - O_1 \quad 5 - 11$$

$$W_1 \frac{dC_1}{dt} = F(C_f - C_1) + O_1 C_1 \quad 5 - 12$$

$$W_1 \frac{dh_1}{dt} = F(h_f - h_1) - O_1(H_{1v} - h_1) + Q_1 - L_1 \quad 5 - 13$$

De modo análogo o balanço material para o segundo efeito dá:

$$\frac{dW_2}{dt} = B_1 - B_2 - O_2 \quad 5 - 14$$

$$W_2 \frac{dC_2}{dt} = B_1(C_1 - C_2) + O_2 C_2 \quad 5 - 15$$

Realizando um balanço de energia no estado-estacionário no segundo efeito encontra-se:

$$O_2 \left(H_{2v} - h_2 + \frac{\partial h_2}{\partial C_2} C_2 \right) = Q_2 - L_2 + B_1(h_1 - h_2) + \frac{\partial h_2}{\partial C_2} B_1(C_2 - C_1) \quad 5 - 16$$

$$O_2 = \frac{B_1(h_1 - h_2) - B_1(C_1 - C_2) \frac{\partial h_2}{\partial C_2} + Q_2 - L_2}{H_{2v} - h_2 + C_2 \frac{\partial h_2}{\partial C_2}} \quad 5 - 17$$

Onde Q_1 e Q_2 são as quantidades de calor adicionadas em cada efeito, dadas por:

$$Q_1 = u_1 A_1 (T_s - T_1) = \lambda_s S_f \quad 5 - 18$$

$$Q_2 = U_2 A_2 (T_1 - T_2) = O_1 (H_{v1} - h_{c1}) \quad 5 - 19$$

As quantidades L_1 e L_2 são as perdas de calor para o meio-ambiente em cada efeito; h_f , h_1 e h_2 são as entalpias do líquido; H_{1v} e H_{2v} são as entalpias do vapor; λ_s representa o calor de vaporização da corrente de entrada na temperatura T_s .

$$O_1 = \frac{U_2 A_2 (T_1 - T_2)}{H_{v1} - h_{c1}} \quad 5 - 20$$

$$h_{c1} = T_1 - 32,0 \quad 5 - 21$$

$$H_{v1} = 0,4T_1 + 1066,0 \quad 5 - 22$$

$$H_{v2} = 0,4T_2 + 1066,0 \quad 5 - 23$$

$$h_1 = T_1(1 - 0,16C_1) - 32,0 \quad 5 - 24$$

$$h_2 = T_2(1 - 0,16C_2) - 32,0 \quad 5 - 25$$

Que resulta nas seguintes equações:

$$\frac{dW_1}{dt} = F - B_1 - \frac{U_2 A_2 (T_1 - T_2)}{H_{v1} - h_{c1}} \quad 5 - 26$$

$$\frac{dC_1}{dt} = \frac{F}{W_1} (C_f - C_1) + \frac{C_1}{W_1} \left[\frac{U_2 A_2 (T_1 - T_2)}{H_{v1} - h_{c1}} \right] \quad 5 - 27$$

$$\frac{dh_1}{dt} = \frac{F}{W_1} (h_f - h_1) + \frac{\lambda_s S_f}{W_1} - \frac{L_1}{W_1} - \frac{(H_{v1} - h_1)}{W_1} \left[\frac{U_2 A_2 (T_1 - T_2)}{H_{v1} - h_{c1}} \right] \quad 5 - 28$$

Sendo:

$$\frac{\partial h_2}{\partial C_2} = -0,16T_2 \quad 5 - 29$$

e,

$$O_2 = \frac{B_1(h_1 - T_2 + 32 + 0,16T_2C_1) + Q_2 - L_2}{1098 - 0,6T_2} \quad 5 - 30$$

Tem-se finalmente o modelo completo considerando os parâmetros adotados anteriormente:

$$\frac{dW_1}{dt} = F - B_1 - \left[\frac{U_2 A_2 (T_1 - T_2)}{1098 - 0,6T_1} \right] \quad 5 - 31$$

$$\frac{dC_1}{dt} = \frac{F}{W_1} (C_f - C_1) + \frac{C_1}{W_1} \left[\frac{U_2 A_2 (T_1 - T_2)}{1098,0 - 0,6T_1} \right] \quad 5 - 32$$

$$\frac{dh_1}{dt} = \frac{F}{W_1} (h_f - h_1) - \frac{L_1}{W_1} + \frac{\lambda_s S_f}{W_1} - \frac{1}{W_1} \left[\frac{U_2 A_2 (T_1 - T_2)}{1098 - 0,6T_1} \right] [1066,1 + 0,4T_1 - h_1] \quad 5 - 33$$

$$\frac{dW_2}{dt} = - \left[\frac{U_2 A_2 (T_1 - T_2) - L_2}{1098 - 0,6T_2} \right] + \left[1 - \left(\frac{h_1 - T_2 + 32,1 + 0,16T_2C_1}{1098 - 0,6T_2} \right) \right] B_1 - B_2 \quad 5 - 34$$

$$\frac{dC_2}{dt} = \frac{C_2}{W_2} \left[\frac{U_2 A_2 (T_1 - T_2) - L_2}{1098 - 0,6T_2} \right] + \left[\frac{C_2}{W_2} \left(\frac{h_1 + 32,1 + 0,16T_2C_1 - T_2}{1098 - 0,6T_2} \right) + \left(\frac{C_1 - C_2}{W_2} \right) \right] B_1 \quad 5 - 35$$

Com os seguintes estados x :

$$x_1 = W_1, x_2 = C_1, x_3 = h_1, x_4 = W_2, x_5 = C_2 \quad 5 - 36$$

Sendo as saídas y :

$$y_1 = x_1, y_2 = x_4, y_3 = x_5 \quad 5 - 37$$

As entradas u (na forma de variável desvio ou escalonada):

$$u_1 = (S_f - S_{fs}), u_2 = (B_1 - B_{1s}), u_3 = (B_2 - B_{2s}) \quad 5 - 38$$

onde o índice s denota "estado estacionário".

Este conjunto de equações (Eqs. 5-31 a 5-38) constituem um *modelo não linear de 5ª ordem* do processo. As variáveis e os parâmetros do modelo estão descritos na Tab. 5-1.

Tabela 5-1 – Parâmetros do modelo do evaporador de duplo efeito.

Variável	Descrição	Valor no Estado-Estacionário
A_2	Área de transferência de calor no 2º efeito (ft ²)	4,6
B_1	Vazão de fundo no 1º efeito (lb/min)	3,3
B_2	Vazão de fundo no 2º efeito (lb/min)	1,7
C_F	Concentração de soluto na alimentação (% peso)	3,2
C_1	Concentração de soluto no 1º efeito (% peso)	4,85
C_2	Concentração de soluto no 2º efeito (% peso)	9,412
F	Vazão de alimentação (lb/min)	5,0
h_F	Entalpia específica da alimentação (Btu/lb)	162
h_1	Entalpia específica do líquido no 1º efeito (Btu/lb)	194
O_1	Vazão de vapor saindo do topo do 1º efeito (lb/min)	1,7
O_2	Vazão de vapor saindo do topo do 2º efeito (lb/min)	1,6
P_1	Pressão no 1º efeito (psia)	< 25
P_2	Pressão no 2º efeito (psia)	7,5
S_f	Vazão de vapor (lb/min)	1,9
T_F	Temperatura da corrente de alimentação (°F)	190
T_1	Temperatura no 1º efeito (°F)	225
T_2	Temperatura no 2º efeito (°F)	160
U_2	Coefficiente de transferência de calor no 2º efeito (Btu/min/ft ² /°F)	5,2345
W_1	"Holdup" de líquido no 1º efeito (lb)	30
W_2	"Holdup" de líquido no 2º efeito (lb)	35
λ_s	Calor latente de condensação do vapor (Btu/lb)	948

Pode-se linearizar este conjunto de equações em torno do estado estacionário de referência, obtendo-se um **modelo linear de 5ª ordem** na forma:

$$\dot{x} = Ax + Bu + \Gamma d$$

$$y = Cx$$

5 - 39

onde o vetor de estados x , o vetor de controle u , o vetor de perturbações d e o vetor de saída y são dados por:

$$x = \begin{bmatrix} W_1 \\ C_1 \\ h_1 \\ W_2 \\ C_2 \end{bmatrix}, u = \begin{bmatrix} S_f \\ B_1 \\ B_2 \end{bmatrix}, d = \begin{bmatrix} F \\ C_f \\ h_f \end{bmatrix}, y = \begin{bmatrix} W_1 \\ W_2 \\ C_2 \end{bmatrix} \quad 5 - 40$$

com:

$$A = \begin{bmatrix} 0 & -0,00156 & -0,1711 & 0 & 0 \\ 0 & -0,1419 & 0,1711 & 0 & 0 \\ 0 & -0,00875 & -1,102 & 0 & 0 \\ 0 & -0,00128 & -0,1489 & 0 & 0,00013 \\ 0 & 0,0605 & 0,1489 & 0 & -0,0591 \end{bmatrix}$$

$$B = \begin{bmatrix} 0 & -0,143 & 0 \\ 0 & 0 & 0 \\ 0,392 & 0 & 0 \\ 0 & 0,108 & -0,0592 \\ 0 & -0,0486 & 0 \end{bmatrix}$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

$$\Gamma = \begin{bmatrix} 0,2174 & 0 & 0 \\ -0,074 & 0,1434 & 0 \\ -0,036 & 0 & 0,1814 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix}$$

5 - 41

5.4 DINÂMICA DO SISTEMA EM MALHA ABERTA

A dinâmica do evaporador de duplo efeito modelado matematicamente no item anterior passa a ser considerada com o propósito de se investigar o efeito das variáveis manipuladas sobre as variáveis controladas.

Inicialmente verifica-se a não linearidade do processo. Tal não linearidade é evidente quando se considera ao modelo matemático, entretanto, o procedimento gráfico mostrado a seguir é útil quando não se dispõe de um modelo matemático confiável ou o

objeto de controle for plantas complexas para as quais um modelo matemático ainda não seja disponível.

A Fig. 5-3 mostra o efeito de uma perturbação degrau de $\pm 10\%$ na variável S_f (variável manipulada) sobre a variável C_2 (variável controlada), quando se considera o modelo linear (respostas simétricas) e o modelo não linear. A falta de simetria na resposta para o modelo não linear caracteriza justamente esta característica, o que fica mais evidente quando se consideram os ganhos estáticos para o novo estado estacionário atingido (Tab. 5-2). Percebe-se que quanto maior a magnitude da perturbação, maior a diferença entre o ganho estático para o degrau positivo e negativo para o modelo não linear, ou seja, maior a não linearidade do processo.

Tabela 5-2 – Ganhos estáticos para perturbações degrau no evaporador.

<i>magnitude da perturbação degrau em S_f</i>	<i>Ganho estático para o modelo não linear</i>	<i>Ganho estático para o modelo linear</i>
+ 1%	0,0644	0,1245
- 1 %	0,0822	0,1245
+ 5 %	0,0759	0,1245
- 5 %	0,0711	0,1245
+ 10 %	0,0820	0,1245
- 10 %	0,0664	0,1245

A Fig. 5-4 mostra o comportamento de todas as variáveis controladas para uma perturbação de + 10 % em S_f . Enquanto C_2 aumenta com o incremento positivo em S_f (vazão de vapor), as demais variáveis (W_1 e W_2) diminuem, o que é esperado, já que quanto maior a vazão de vapor, maior a taxa de evaporação e para retiradas constantes, menor o *holdup* de líquido nos tanques de evaporação.

A Fig. 5-5 mostra o comportamento de um degrau de $\pm 1\%$ na vazão de retirada de líquido do 1º efeito (B_1) sobre as variáveis controladas. Novamente observa-se um comportamento não linear nestas.




Figura 5-3 – Resposta em malha aberta de C_2 para perturbações degrau em S_f (comparação do modelo linear e não linear).




Figura 5-4 – Resposta em malha aberta para uma perturbação de +10% em S_f .




Figura 5-5 - Resposta em malha aberta para perturbações de $\pm 1\%$ em B_1 .

5.5 IDENTIFICAÇÃO

A identificação de um processo é uma etapa fundamental na síntese de estratégias de controle exitosas. Inicialmente, realizou-se a identificação considerando que o processo possa ser representado como sendo de 1ª ordem, mais tempo morto. Para tal, efetuou-se

uma perturbação de +10 % em S_f e a partir da curva de resposta de C_2 (Fig. 5-6), os seguintes parâmetros foram obtidos graficamente:

Novo estado estacionário: $C_2 = 0,1097 \text{ wt/wt}$

$$\tau = 27 \text{ min}$$

$$\tau_d = 1 \text{ min}$$

$$K = \frac{\Delta C_2}{\Delta S_f} = \frac{0,1097 - 0,0941}{2,09 - 1,90} = 0,0820 \frac{\text{wt/wt}}{\text{lb/min}} \quad 5 - 42$$

Portanto,

$$\frac{C_2(s)}{S_f(s)} = \frac{0,0820 e^{-s}}{27s + 1} \quad 5 - 43$$

com $C_2(0) = 0,0941 \text{ wt/wt}$

A simulação deste modelo é mostrada na Fig. 5-7, onde se pode verificar a concordância com a resposta do processo.




Figura 5-6 – Resposta em malha aberta e determinação gráfica dos parâmetros de um modelo empírico de 1ª ordem mais tempo morto.




Figura 5-7 – Simulação no Matlab/Simulink™ do modelo de 1ª ordem identificado.

Objetivando identificar agora o sistema considerando-o com múltiplas entradas e múltiplas saídas (MIMO), simulou-se um conjunto de dados que representariam informações coletadas a partir de uma planta em operação durante 500 min (ou 500 amostragens, pois no caso utilizou-se um tempo de amostragem de 1 min). As variáveis manipuladas S_f , B_1 e B_2 (entradas) foram variadas de modo randômico, dentro de certo intervalo, e as variáveis controladas W_1 , W_2 e C_2 (saídas) registradas. A metodologia foi a mesma utilizada no caso-estudo anterior. As Figs. 5-8 e 5-9 mostram os dados de entrada-saída (conjunto de treinamento e conjunto de teste), sendo que os mesmos foram escalonados da seguinte forma:

$$saída_escalonada = \frac{saída_real - saída_estado_estacionario_inicial}{saída_estado_estacionario_inicial}$$

$$entrada_escalonada = entrada_real - entrada_estado_estacionario_inicial$$

Uma vez disponível o conjunto de dados a ser utilizado na identificação, várias análises podem ser realizadas com o mesmo, como por exemplo a estimativa de função de transferência empírica e o periodograma (relacionado ao quadrado da Transformada de Fourier dos dados), ou a comparação da estimativa dos espectros de entrada e saída, como mostrado na Fig. 5-10. Esta figura permite comparar a qualidade ou semelhança dos dados de entrada/saída utilizados na estimativa (conjunto treinamento) e avaliação desta (conjunto teste). O propósito de se examinar os dados utilizando ferramentas advindas da análise no domínio da frequência é verificar se há porções dos dados que não são adequadas para identificação, se o conteúdo da informação dos dados é apropriada nas regiões de

freqüências interessantes e se os dados devem ser processados de algum modo, antes de utilizá-los na estimativa.




Figura 5-8 – Sequência de dados de entrada escalonados utilizados na identificação (conjunto de treinamento e teste).




Figura 5-9 - Sequência de dados de saída escalonados utilizados na identificação (conjunto de treinamento e teste).




Figura 5-10 – Comparação do diagrama de Bode dos dados de treinamento e teste (estimativa do espectro).

Inicialmente será efetuada a identificação do processo considerando-se modelos lineares na forma ARX. Os seguintes modelos foram considerados, com seus respectivos graus de ajuste (NSSE para o conjunto teste):

- ARX 310: $na = [3 \ 3 \ 3]$; $nb = [1 \ 1 \ 1]$; $nk = 0$; **NSSE = 0,013394**
- ARX 440: $na = [4 \ 4 \ 4]$; $nb = [4 \ 4 \ 4]$; $nk = 0$; NSSE = 0,015103
- ARX 330: $na = [3 \ 3 \ 3]$; $nb = [3 \ 3 \ 3]$; $nk = 0$; NSSE = 0,015984
- ARX 140: $na = [1 \ 1 \ 1]$; $nb = [4 \ 4 \ 4]$; $nk = 0$; NSSE = 0,019179

Os coeficientes do modelo ARX 310 são apresentados nos ANEXOS. O desempenho destes modelos ajustados frente à saída real (para Y3) é mostrado na Fig. 5-11 sendo que o modelo ARX 310 mostra-se o mais eficiente na predição de $y(t)$. O desempenho dos modelos é razoável, considerando a dificuldade do ajuste de modelos MIMO, sendo também razoável a capacidade de predição do melhor deles (ARX 140) para 5 intervalos de amostragem à frente $y(t+5)$, importante na utilização de controladores preditivos (Figs. 5-12 e 5-13). Observa-se que o modelo identificado tem um desempenho muito superior para a saída y_1 . Dificilmente se consegue a partir de um mesmo modelo

MIMO resultados qualitativos equivalente para todas as saídas, sendo não raro uma estrutura apresentar bons resultados para uma saída e outros mais pobres para outra saída.




Figura 5-11 – Comparação entre a saída "real/medida" y_3 e as preditas pelos modelos lineares.





Figura 5-12 – Dados "medidos" de y_3 e **Figura 5-13 -** Dados "medidos" de y_1 e predição da saída 5 intervalos à frente.

A resposta y_3 no domínio do tempo para uma perturbação degrau em u_1 é mostrada na Fig. 5-14, onde se vê que todos os modelos possuem resposta assintótica finita para a perturbação aplicada. A resposta no domínio da frequência na Fig. 5-16 (comparar com a resposta do processo apresentada na Fig. 5-10) e os pólos e zeros do modelo na Fig. 5-15 (onde se vê que todos são estáveis para qualquer tempo considerado, pois todos pertencem ao círculo com raio unitário).




Figura 5-14 – Resposta y_3 a uma perturbação degrau em u_1 a partir dos modelos lineares.




Figura 5-15 – Pólos (x) e zeros (o) dos modelos identificados.




Figura 5-16 – Diagrama de Bode da resposta y_3 e a entrada u_1 a partir dos modelos lineares.

A Fig. 5-17 mostra o comportamento de todas as saídas do sistema frente a perturbações degrau aplicadas à todas as entradas, considerando o modelo ARX 310. Para a perturbação aplicada, as saídas possuem resposta limitada, apresentando estabilidade BIBO (*bounded input, bounded output*).




Figura 5-17 – Resposta transiente de todas as saídas para uma perturbação degrau em todas as entradas para o modelo ARX 310.

A seguir considera-se a identificação do processo utilizando rede neural na forma NNARX, com $n_a = 1$, $n_b = 4$, $n_k = 1$ (perfazendo um total de 15 entradas), 6 neurônios na camada interna e 3 neurônios na camada de saída (Fig. 5-18). A quantidade de neurônios foi determinada por tentativa e erro, sendo que o número de 6 representou o melhor compromisso entre capacidade de representação dos dados e ausência de ajuste excessivo (na forma de oscilação da predição, para o conjunto teste).

O critério de ajuste utilizado no treinamento da rede (6 neurônios) é mostrado na Fig. 5-19, e a validação mostrada nas Figs. 5-20 a 5-26, onde percebe-se claramente a capacidade da rede em capturar a dinâmica do sistema MIMO considerado. Os testes de autocorrelação e correlação cruzada mostram a boa estimativa dos parâmetros alcançada, sendo a distribuição dos erros em relação à origem também (embora para sistemas não lineares estes testes não sejam suficientes para completa caracterização do grau do ajuste).




Figura 5-18 – Modelo neural não linear NNARX considerado na identificação.




Figura 5-19 – Critério de ajuste na etapa de treinamento em função do número de iterações.




Figura 5-20 – (a) Saída "medida" y_1 () e predição um passo a frente (--) utilizando o modelo neural NNARX; (b) erro predito




Figura 5-21 – Saída "medida" y_2 e predição um passo a frente utilizando o modelo neural NNARX.




Figura 5-22 - Saída "medida" y_3 e predição um passo a frente utilizando o modelo neural NNARX.




Figura 5-23 – Coeficientes de autocorrelação para o erro predito (NNARX). Saída 1.




Figura 5-24 - Coeficientes de autocorrelação para o erro predito (NNARX). Saída 2.




Figura 5-25 – Coeficientes de autocorrelação para o erro predito (NNARX). Saída 3.




Figura 5-26 – Histograma dos erros preditos e parâmetros linearizados da rede (NNARX).

A seguir estabeleu-se a identificação utilizando um modelo neural na forma NNSSIF (*State Space Innovation Form*), considerando que o processo possua 3 estados (número de saídas do processo a ser identificado) que são realimentados, juntamente com o erro (diferença entre a saída "medida" e a predita) e as entradas "u" do processo. Esta forma de rede neural tem a vantagem de estar na forma clássica espaço de estados, podendo assim ser utilizada em muitas estratégias de controle que foram desenvolvidas para esta classe de modelos. Uma vantagem desta forma de rede neural em relação à anterior (NNARX) é que tem menos parâmetros a serem especificados, já que não há a necessidade de definir a estrutura do regressor. Na rede NNSSIF o usuário define apenas o número de neurônios na camada interna, número de iterações, tolerância, etc., ou seja, parâmetros comuns a todo modelo neural. A desvantagem principal desta forma de modelo neural é que sua capacidade de "memorizar" dinâmicas mais complexas é menor quando comparada com os modelos neurais da forma NNAR(...). A Fig. 5-27 mostra um modelo neural na forma NNSSIF que utiliza 6 neurônios na camada interna e que será utilizado no controle preditivo no próximo item.




Figura 5-27 – Modelo neural não linear NNSSIF.

A quantidade de neurônios na camada interna é aqui também um compromisso entre a capacidade de representação dos dados e a ausência de grandes oscilações, embora para este número de neurônios a resposta predita sempre apresenta considerável *off set* quando esta se encontra em regiões mais distantes da origem. Portanto, para fins de predição, 7

neurônios na camada interna é a melhor opção, embora há a presença de uma pequena oscilação no início da estimativa, o que pode ser visualizado nas figuras que se seguem. As Figs. 5-28 a 5-33 mostram a capacidade preditiva (um passo à frente) do modelo neural NNSSIF frente ao conjunto de dados de teste, onde se pode perceber que após uma oscilação inicial, o modelo consegue capturar muito bem a dinâmica do processo.




Figura 5-28 – Saída "medida" y_1 e predição um passo a frente utilizando o modelo neural NNSSIF.




Figura 5-29 - Saída "medida" y_2 e predição um passo a frente utilizando o modelo neural NNSSIF.




Figura 5-30 – Saída "medida" y_3 e predição um passo a frente utilizando o modelo neural NNSSIF.




Figura 5-31 - Coeficientes de autocorrelação para o erro predito (NNARX). Saída 1.




Figura 5-32 – Coeficientes de autocorrelação para o erro predito (NNARX). Saída 2.




Figura 5-33 - Coeficientes de autocorrelação para o erro predito (NNARX). Saída 3.

Particularmente úteis para fins de controle são as informações mostradas na Fig. 5-35, que apresenta os coeficientes das matrizes **A**, **B** e **K** de um modelo linear na forma pseudo-observável (espaço de estados na forma modificada – *innovation model*). Tais coeficientes são obtidos a partir da linearização da rede neural por derivação parcial em função das saídas (estados), entradas e erros, respectivamente. Deste modo, para cada instante de amostragem, a rede neural fornece a predição um passo à frente dos estados e também um modelo linear na forma espaço de estados que pode ser utilizado no projeto de controladores ótimos ou preditivos para o processo.




Figura 5-34 – Histograma dos erros preditos (NNSSIF).




Figura 5-35 – Parâmetros linearizados da rede (NNSSIF).

A representação de um sistema na forma espaço de estados modificada (*innovation model*) surge como solução para a questão do controle ótimo (LQG) aplicado a sistemas representados na forma polinomial. Isto porque a teoria de controle ótimo LQG foi

desenvolvida para sistemas representados na forma espaço de estados. Com a introdução do controle adaptativo auto-regulável (STR) havia a necessidade de unir as duas teorias de controle que partiam de paradigmas de modelagem diferentes: uma na forma de espaço de estados e outra na forma polinomial. A junção destas duas teorias foi apresentada por ASTRÖM & WITTENMARK (1995) quando propuseram que um sistema identificado na forma polinomial por um modelo da família ARX, por exemplo, poderia ser convertido para a forma espaço de estados desde que este fosse escrito na forma modificada (*innovation model*):

$$\begin{aligned}x(t+1) &= \bar{A}x(t) + \bar{B}u(t) + \bar{K}e(t) \\y(t) &= \bar{C}x(t) + e(t)\end{aligned}\tag{5 - 44}$$

onde as matrizes $\bar{A}$, $\bar{B}$, $\bar{C}$ e $\bar{K}$ são dadas na forma canônica:

$$\bar{A} = \begin{bmatrix} -a_1 & 1 & 0 & \cdots & 0 \\ \vdots & & \ddots & & \\ -a_{n-1} & 0 & & \cdots & 1 \\ -a_n & 0 & & \cdots & 0 \end{bmatrix}\tag{5 - 45}$$

$$\bar{B} = [0 \quad \cdots \quad 0 \quad b_0 \quad \cdots \quad b_n]^T\tag{5 - 46}$$

$$\bar{C} = [1 \quad 0 \quad \cdots \quad 0]\tag{5 - 47}$$

$$\bar{K} = [c_1 - a_1 \quad \cdots \quad c_n - a_n]^T\tag{5 - 48}$$

onde $m = n - d_0$ e os coeficientes a , b e c são os do modelo:

$$A(q)y(t) = B(q)u(t) + C(q)e(t)\tag{5 - 49}$$

Quando $\bar{K}$ for o ganho ótimo no estado estacionário do filtro de Kalman, $\hat{x}(t+1|t) = x(t+1)$, ou seja, a estimativa dos estados corresponde à estimativa ótima.

5.6 CONTROLE PID

A primeira proposta de controle do evaporador de duplo efeito é a utilização de um controlador clássico PI (Fig. 5-36), na forma contínua, porém com a ação de controle na forma discreta, introduzida com o retentor de ordem zero, com intervalo de amostragem de 1 min. As saídas do sistema são admitidas como sendo todas mensuráveis e as medidas são tomadas com um atraso de um intervalo de amostragem (1 min). Utilizou-se a seguinte

configuração no controle: controla-se C_2 manipulando-se D_F ; controla-se w_2 manipulando-se B_2 ; controla-se W_1 manipulando-se B_1 . O pareamento das variáveis foi efetuado a partir do conhecimento da influência de cada entrada sobre as saídas. As malhas são independentes sob o ponto de vista de implementação, porém acopladas na prática, já que qualquer variável manipulada afeta todas as saídas.




Figura 5-36 – Implementação das malhas de controle PI utilizando o Matlab/Simulink™.

Os parâmetros utilizados nos controladores PI foram sintonizados pelo método de tentativa e erro, o qual não consiste em um procedimento sistemático de sintonia, mas que dada as características de simulação do problema, pode ser adotado, desde que se tenha em mente que na prática deve-se utilizar um método clássico (Ziegler e Nichols, curva da reação, etc.), embora estes não poucas vezes revelam-se ineficazes para a maioria dos problemas práticos. A Tab. 5-3 mostra os parâmetros utilizados nas simulações.

Os resultados para o caso supervisorio (mudança de 0,1 wt/wt no *set point* de C_2) e regulatório (degrau de +10% em F e -10% em C_f , simultaneamente), são mostrados nas Figs. 5-37/38 e 5-39/40 , respectivamente. O desempenho dos controladores PI foram

razoáveis, notando-se apenas os grandes *overshoots* apresentados tanto no caso supervisorio, quanto no regulatório, assim como a presença de *off sets*.

Tabela 5-3 – Parâmetros dos controladores PI.

	<i>malha 1</i> (controle de C_2)	<i>malha 2</i> (controle de W_1)	<i>malha 3</i> (controle de W_2)
K_C	10	-3	-5
$1/\tau_I$	0,1	0,05	0,05




Figura 5-37 – Desempenho dos controladores PI (mudança de *set point* em C_2) – variáveis controladas (saídas).




Figura 5-39 – Desempenho dos controladores PI (perturbação degrau em F e C_2) – variáveis controladas (saídas).




Figura 5-38 – Desempenho dos controladores PI (mudança de *set point* em C_2) – variáveis manipuladas (entradas).




Figura 5-40 – Desempenho dos controladores PI (perturbação degrau em F e C_2) – variáveis manipuladas (entradas).

As Figs. 5-41 e 5-42 mostram o desempenho do caso regulatório, porem com a adição de um ruído branco à F (vazão de entrada), simulando uma situação próxima da real que é a oscilação nas vazões de entrada de um processo e que dificilmente são mantidas constantes. Observa-se uma degradação no desempenho do controlador, além do fato das saídas tornarem-se mais oscilantes, o que era esperado. Entretanto, o controlador se apresentou robusto para a nova perturbação introduzida.




Figura 5-41 – Desempenho dos controladores PI (perturbação degrau com ruído em F e C_f) – variáveis controladas (saídas).




Figura 5-42 – Desempenho dos controladores PI (perturbação degrau com ruído em F e C_f) – variáveis manipuladas (entradas).

5.7 CONTROLE PREDITIVO BASEADO EM MODELO LINEAR

A utilização de controladores preditivos em plantas industriais é uma das perspectivas mais fortemente consideradas atualmente nos ambientes de automação e controle de processos. Isto se deve principalmente ao fato da relativa simplicidade desta estratégia de controle, aliada à capacidade da mesma em lidar com restrições e otimização, simultaneamente.

O controlador preditivo baseado em modelo utilizado no desenvolvimento deste trabalho é o implementado por MORARI e RICKER (1998). O método de otimização empregado é a Programação Quadrática.

Inicialmente verificou-se o comportamento de um controlador preditivo para o evaporador de duplo efeito. Utilizou-se um modelo linear do processo (linearizado em torno do estado estacionário inicial), na forma espaço de estados, como modelo de controle e o modelo linear foi utilizado para obter as saídas a partir das entradas manipuladas

calculadas pelo controlador preditivo. Portanto, no primeiro caso, o modelo de controle e de simulação são equivalentes e lineares, utilizado para verificar o algoritmo. Os seguintes parâmetros de projeto foram considerados (valores escalonados, quando aplicável):

- Intervalo de amostragem: 1 min
- Horizonte de predição: 10 min
- Horizonte de controle: 3 min
- Penalização das saídas: [200 200 2000]
- Penalização das entradas: [0,6 0,6 0,6]
- $u_{\min} = [-0,95 \ -1,65 \ -0,85]$ (correspondem a -50% do valor do estado estacionário)
- $u_{\max} = [0,95 \ 1,65 \ 0,85]$ (correspondem a $+50\%$ do valor do estado estacionário)
- $\Delta u_{\max} = [0,1 \ 0,1 \ 0,1]$
- $y_{\min} = [-1 \ -1 \ -1]$ (correspondem às saídas reais zero, ou seja, $W_1 = W_2 = C_2 = 0$)
- $y_{\max} = [2 \ 2 \ 2]$ (correspondem a 3 vezes o valor do estado estacionário inicial)

As Figs. 5-43 e 5-44 mostram respectivamente os resultados obtidos para o caso supervisório (*set point* de 0,1 para y_3 , demais saídas 0) e regulatório (perturbação degrau de $+10\%$ em F e -10% em C_f , simultaneamente). Observa-se que não há presenças de *off sets* em nenhum dos casos, sendo atingido o novo *set point* rapidamente e as perturbações rejeitadas com sucesso.




Figura 5-43 – Desempenho do controlador preditivo (mudança de *set point* em C_2) – Sistema linear. (a) saídas; (b) entradas




Figura 5-44 – Desempenho do controlador preditivo (perturbação degrau em F e C_f) – Sistema linear. (a) saídas; (b) entradas

O problema de controle anterior representa uma idealização já que o processo real é não linear. Isto foi considerado na sequência, quando utilizou-se o modelo linear apenas para fins de projeto do controlador e o modelo completo usado na obtenção das saídas "reais" do processo, em malha fechada (Figs. 5-45 e 5-46). Os parâmetros de projeto do controlador foram os mesmos do caso anterior. Observa-se que para o caso supervisorio há um pequeno *off set* nas saídas que não foram mudadas, mas o controlador conseguiu atingir o novo *set point* com sucesso. Entretanto, para o caso regulatório, os *off sets* foram mais acentuados, embora os *over shoots* foram bem menores. No geral o desempenho do controlador é bom, nesta região de operação que não se distancia muito do estado estacionário original, o que significa que a dinâmica do sistema é "fracamente" não linear e daí o sucesso da utilização do controlador projetado com base no modelo linear. Quando se aumenta o grau de não linearidade do sistema (aumentando a magnitude da perturbação) o desempenho do controlador se degrada acentuadamente (grandes *off sets*), o que é visto na Fig. 5-47, quando se solicitou um *set point* de 2 para a saída y_3 (3 vezes o valor do estado estacionário inicial). Neste caso, teve-se que se alterar os pesos das saídas para [2000 2000 2000] a fim de se impedir que as saídas y_1 e y_2 diminuíssem indefinidamente, até atingirem seus valores mínimos permitidos.




Figura 5-45 – Desempenho do controlador preditivo (mudança de *set point* em C_2) – Sistema não linear. (a) saídas; (b) entradas




Figura 5-46 – Desempenho do controlador preditivo (perturbação degrau em F e C_f) – Sistema não linear. (a) saídas; (b) entradas




Figura 5-47 - Desempenho do controlador preditivo (mudança de *set point* em C_2 para 2) – Sistema não linear. (a) saídas; (b) entradas

5.8 CONTROLE PREDITIVO UTILIZANDO REDES NEURAIS ARTIFICIAIS

A introdução das redes neurais no controle preditivo MIMO foi realizada da seguinte forma: utilizou-se o modelo neural na forma NNSSIF identificado no item anterior (que possui 3 estados) para a partir do mesmo se extrair um modelo linear tridimensional. A linearização, como já foi citada anteriormente, é realizada a cada instante de amostragem. Entretanto, para simplificar a implementação do controlador, considerou-se um valor médio para os coeficientes das matrizes **A** e **B**, que foram:

$$\begin{aligned}
 \mathbf{A} &= \begin{bmatrix} 0.9674 & 0.0089 & -0.0064; \\ 0.0162 & 0.9874 & -0.0013; \\ 0.0058 & 0.0033 & 0.9550 \end{bmatrix}; \\
 \mathbf{B} &= \begin{bmatrix} -0.0224 & -0.0212 & 0.0034 & 0 & 0 & 0; \\ -0.0274 & 0.0158 & -0.0306 & 0 & 0 & 0; \\ 0.0248 & -0.0081 & 0.0083 & 0 & 0 & 0 \end{bmatrix};
 \end{aligned}$$

5 - 50

A matriz **B** foi aumentada a fim de se considerar três entradas adicionais que são as perturbações (mensuráveis ou não). As perturbações mensuráveis podem ser consideradas na etapa de treinamento da rede neural. Como isto não foi efetuado, aumentou-se o tamanho de **B** com zeros, significando que não se dispõe de um modelo para as perturbações. Portanto, nos resultados que se seguem (Figs. 5-48 e 5-49), mesmo quando há a presença de perturbações (problema regulatório), o modelo linear extraído do modelo

neural não enxerga tais perturbações. Os parâmetros de projeto do controlador foram os mesmos já mencionados anteriormente.

Para este sistema linear em particular o ranque da matriz controlabilidade é 3. Isto significa que todos os 3 estados são controláveis. Da mesma forma o ranque da matriz observabilidade é 3, o que significa que todos os estados são observáveis.




Figura 5-48 – Desempenho do controlador preditivo-NNSSIF (mudança de *set point* em C_2) – Sistema não linear. (a) saídas; (b) entradas




Figura 5-49 – Desempenho do controlador preditivo-NNSSIF (perturbação degrau em F e C_2) – Sistema não linear. (a) saídas; (b) entradas

Assim, o sistema linear descrito por estas matrizes permanece constante em todo o tempo de simulação considerado. Uma alternativa a este procedimento, aplicável quando o sistema "real" se distanciar muito do estado estacionário, é utilizar os coeficientes calculados a cada instante de amostragem, podendo se considerar neste caso uma classe de controlador preditivo-adaptativo.

Chama-se atenção para o fato de que não se trata aqui de uma estimativa de A e B a cada instante de amostragem, mas sim de "extrair" um modelo linear do modelo neural não linear previamente treinado. Frente às técnicas existentes, qual a vantagem deste procedimento?

1. É muito mais fácil resolver o problema de otimização inerente ao controle preditivo quando o modelo do processo é linear;
2. É muito mais simples identificar um conjunto de dados com múltiplas entradas e saídas e apresentando não linearidades utilizando uma rede neural do que um

modelo polinomial ao mesmo tempo evitando o problema da estimativa recursiva de parâmetros, inevitável quando o sistema é não linear;

3. O procedimento simples de extrair um modelo na forma espaço de estados a partir do modelo neural na forma NNSSIF;
4. A ampla teoria de controle desenvolvida tendo em vista o controle linear e que pode ser aplicada ao modelo "extraído" da rede neural antes de sua utilização no controle preditivo;
5. A possibilidade de adaptação facilmente introduzida com esta metodologia;

5.9 CONCLUSÕES

Foram apresentados neste capítulo os principais paradigmas de modelagem empregados a fim de se obter um modelo estático ou dinâmico de evaporadores, esta importante operação unitária presente em diversos segmentos industriais. A maioria dos modelos propostos na literatura é fenomenológico, sendo que pouco mudou em relação às primeiras propostas que datam do início da década de 1970.

Paralelamente, tem crescido o interesse em se utilizar redes neurais na identificação de evaporadores com fins de aplicação em controle automático, principalmente controle preditivo.

Partindo de um modelo dinâmico clássico de um evaporador de duplo efeito, estudou-se a dinâmica do sistema em malha aberta e fechada, sendo que foram apresentadas várias propostas de identificação, das mais simples (modelo na forma de função de transferência, modelo MIMO ARX), às mais complexas (modelos neurais NNARX e NNSSIF).

Em seguida, apresentaram-se três metodologias de controle do sistema a saber: controle clássico PI; controle preditivo baseado em modelo linear do processo; controle preditivo baseado em modelo linear extraído do modelo neural identificado.

A sistemática apresentada neste capítulo é aplicável a qualquer processo de interesse, linear ou não, sendo que a identificação utilizando redes neurais introduz uma boa perspectiva nesta área em geral complexa e carente de metodologias que não utilizem extensivamente a tentativa e erro como *modus operandi*.

Capítulo 6

CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

6 CONCLUSÕES E SUGESTÕES PARA TRABALHOS FUTUROS

6.1 CONCLUSÕES

Existe uma vasta teoria de identificação de sistemas desenvolvida, do ponto de vista teórico, e pouca aplicação prática, principalmente quanto aos processos de interesse da Engenharia Química. A identificação é uma tarefa difícil de ser realizada e consome a maior parte do tempo gasto no desenvolvimento de sistemas de controle. Entretanto, é uma etapa fundamental quando se tem em mente a aplicação das estratégias de controle avançado. Somente no final da década de 1990 começaram a surgir os primeiros trabalhos tratando da questão da identificação do ponto de vista unificado, ou seja, escrever todas as técnicas de identificação (métodos polinomiais, séries de potência, redes neurais, *wavelets*, etc.) na mesma linguagem matemática, facilitando assim ao usuário destas técnicas a escolha e a exploração das potencialidades de cada uma delas.

Dentre as diversas opções de modelos paramétricos de identificação de sistemas não lineares, as redes neurais têm mostrado os resultados mais promissores. A maioria das aplicações de identificação de sistemas dinâmicos por redes neurais utiliza uma topologia de rede na forma NNAR, ou seja, as entradas da rede são compostas de entradas e saídas do processo no instantes de tempo atual e passados e a saída da rede é a previsão um instante de amostragem à frente. A complexidade dos algoritmos de treinamento das redes recorrentes, que seriam o caminho natural de identificação de sistemas dinâmicos, tem limitado bastante o uso desta topologia, sendo poucas aplicações reportadas na literatura utilizando tal metodologia.

O emprego de redes neurais juntamente com modelos fenomenológicos tem sido bastante investigado nos últimos anos, metodologia esta conhecida como modelagem híbrida, e que procura extrair as melhores qualidades de ambos os paradigmas. Do mesmo modo as redes neurais também têm sido utilizadas com técnicas de lógica nebulosa (*fuzzy logic*), unindo assim as capacidades de representação quantitativa das redes, com a possibilidade de descrição qualitativa da lógica nebulosa. Deste modo, os chamados sistemas especialistas podem ser desenvolvidos para áreas pobres em descrição

fenomenológica mas com grande acervo de experiências empíricas, tais quais os bioprocessos.

A utilização das redes neurais na identificação de sistemas com fins de controle teve aplicação direta nas técnicas de controle preditivo, que mostram ser, a partir da análise da literatura, corroborado pelos resultados obtidos e mostrados neste trabalho, a técnica de controle mais promissora no controle de sistemas não lineares, SISO ou MIMO. A utilização das redes neurais também permite a utilização da teoria linear de controle, principalmente do Controle Adaptativo, com relativa facilidade e com bons resultados. Isto porque um bom modelo identificado através de redes neurais, que capta com maior facilidade as não linearidades do processo, pode ser utilizado em linha, com enorme rapidez computacional, como modelo rigoroso do processo a partir do qual é "extraído" a cada intervalo de amostragem um modelo linear que por sua vez é utilizado no cálculo da ação de controle, fazendo uso da teoria de projeto baseada na alocação de pólos em malha fechada.

O controle não linear também se beneficia dos modelos neurais a fim de se efetuar a linearização por retroalimentação, linearização esta cuja exatidão depende fundamentalmente da qualidade do modelo empregado. Entretanto, esta técnica, por sua incapacidade de lidar com restrições e com otimização, não tem encontrado muito eco nas indústrias. O mesmo não ocorre com o controle preditivo, que tem sido largamente empregado nas plantas químicas, embora utilizando modelos bem simplificados de processo, como os de convolução e os de resposta finita ao impulso. Entretanto, a utilização dos modelos neurais tem aberto novos horizontes à esta técnica de controle, principalmente quanto ao controle não linear preditivo (NMPC), apesar de sua dependência ainda grande das capacidades de cálculo, já que envolve complexos algoritmos de otimização e busca iterativa de soluções.

O casos-estudo aqui apresentados exploraram a maior parte das técnicas de controle avançado que utilizam redes neurais em sua formulação, sendo considerados os casos SISO e MIMO, com sucesso. Após uma investigação detalhada da dinâmica dos processos e da identificação destes utilizando modelos lineares, redes neurais na configuração NNARX e NNSSIF e também redes neurais convencionais, procedeu-se ao controle da concentração

de saída manipulando a vazão de refrigerante, para os dois reatores em série, e ao controle da concentração de saída e dos *hold ups* de um evaporador de duplo efeito. Consideraram-se os casos de controle supervisorio e regulatório (perturbação na concentração de entrada do processo), sendo as estratégias de controle preditivas as que apresentaram os melhores resultados.

6.2 SUGESTÕES PARA TRABALHOS FUTUROS

Com base nas experiências advindas com o desenvolvimento deste trabalho, acredita-se que os seguintes tópicos merecem ser explorados de modo mais aprofundado:

1. Testar outras configurações de modelos neurais, como por exemplo as *wavelets*, na identificação de sistemas não lineares;
2. Ampliar o estudo de identificação com redes neurais artificiais que predizem a derivada do modelo e não as saídas diretamente (redes convencionais e não na forma NNAR(...));
3. Implementar o procedimento de controle preditivo baseado em modelo neural NNSSIF que atualiza o modelo linear "extraído" da rede neural em todos os intervalos de amostragem ou em tempos pré-definidos, tornando o modelo linear mais fiel às novas regiões operacionais;
4. Realizar ensaios experimentais dos casos-estudo apresentados (em escala piloto ou não) e verificar o desempenho dos controladores propostos em condições reais.

REFERÊNCIAS BIBLIOGRÁFICAS E BIBLIOGRAFIA

1. AMF01 AGUIAR, H. C., MACIEL FILHO, R. Neural network and hybrid model: a discussion about different modeling techniques to predict pulping degree with industrial data. *Chemical Engineering Science*, v. 56, pp. 565-570, 2001.
2. ACCP95 ALBIOL, J., CAMPMAJÓ, C., CASAS, C., POCH, M. Biomass estimation in plant cell cultures: a neural network approach. *Biotechnology Progress*, v. 11, pp. 88-92, 1995.
3. ARN99 ALVAREZ, E., RIVEROL, C., NAVAZA, J. M. Control of chemical processes using neural networks: implementation in a plant for xylose production. *ISA Transactions*, v. 38, pp. 375-382, 1999.
4. AMF01 ASSIS, A. J., MACIEL FILHO, R. Control applications of artificial neural networks in bioprocessing and chemical engineering: a review. 4th. CONFERENCE PROCESS INTEGRATION, MODELLING AND OPTIMISATION FOR ENERGY SAVING AND POLLUTION REDUCTION, Florença, Itália, Maio de 2001
5. AMF96 ASSIS, A. J., MACIEL FILHO, R. *Projeto de Controladores Adaptativos Auto-Ajustáveis*. Campinas: Faculdade de Engenharia Química, UNICAMP, 1996. Dissertação (Mestrado).
6. AMF00 ASSIS, A. J., MACIEL FILHO, R. Soft sensors development for on-line bioreactor state estimation. *Computers and Chemical Engineering*, v.24, n.2-7, p.1099 - 1103, 2000.
7. AW95 ÅSTRÖM, K. J., WITTENMARK, B. *Adaptive Control*. 2nd. ed., Addison-Wesley, 1995.
8. AHM*93 AYNSLEY, M., HOFLAND, A., MORRIS, A. J., MONTAGUE, G. A., MASSIMO, C. Di. Artificial intelligence and the supervision of bioprocesses (Real-time knowledge-based systems and neural networks). *Advances in Biochemical Engineering Biotechnology*, v. 48, Berlin: Springer-Verlag, pp. 1-27, 1993.
9. Aze96 AZEVEDO, S. F. de. Methods for state and parameter estimation with application to industrial chemical and biochemical processes. In 12th INTERNATIONAL CONGRESS OF CHEMICAL AND PROCESS ENGINEERING, CHISA'96. Prague, Tchech Republic, 25-30 August, Paper n. 1150, 1996.
10. BZ00 BALLINI, R., ZUBEN, F. J. von. Book reviews: Application of neural networks to adaptive control of nonlinear systems. *Automatica*, v. 36, pp. 1929-1933, 2000.
11. BCS97 BARATTI, R., CORTI, S., SERVIDA, A. A feedforward control strategy for distillation columns. *Artificial Intelligence in Engineering*, v. 11,

pp. 405-412, 1997.

12. BH00 BASHEER, I. A., HAJMEER, M. Artificial neural networks: fundamentals, computing, design, and application. *Journal of Microbiological Methods*, v. 43, pp. 3-31, 2000.
13. BL95 BAUGHMAN, D. R., LIU, Y. A. *Neural networks in bioprocessing and Chemical Engineering*. USA: Academic Press, 1995, 488 p.
14. BPCH00 BENNE, M., GRONDIN-PEREZ, B., CHABRIAT, J.-P., HERVÉ, P. Artificial neural networks for modelling and predictive control of an industrial evaporation process. *Journal of Food Engineering*, v. 46, pp. 227-234, 2000.
15. Beq91 BEQUETTE, B. W. Nonlinear control of chemical processes: a review. *Industrial Engineering Chemical Research*, v. 30, pp. 1391-1413, 1991.
16. BM92 BHAT, N. V., McAVOY, T. J. Determining model structure for neural models by network stripping. *Computers and Chemical Engineering*, v. 16, n. 4, pp. 271-281, 1992.
17. BM90 BHAT, N., McAVOY, T. J. Use of neural nets for dynamic modeling and control of chemical process systems. *Computers and Chemical Engineering*, v. 14, n. 4/5, pp. 573-583, 1990.
18. BCK89 BILLINGS, S. A., CHEN, S. & KORENBERG, M. J. Identification of MIMO non-linear systems using a forward-regression orthogonal estimator. *International Journal of Control*, v. 49, pp. 2157-2189, 1989.
19. Blu92 BLUM, A. *Neural networks in C++: an object-oriented framework for building connectionist systems*. USA: John Wiley & Sons, 1992, 214 p.
20. BLP00 BOLSONI, A., LIMA, E. L., PINTO, J. C. Advanced control of propylene polymerizations in slurry reactors. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 565-573, dec 2000.
21. BS98 BOMBERGER, J. D., SEBORG, D. E. Determination of model order for NARX models directly from input-output data. *Journal of Process Control*, v. 8, nos. 5-6, pp. 459-468, 1998.
22. BN95 BOSKOVIC, J. D., NARENDRA, K. S. Comparison of linear, nonlinear and neural-network-based adaptive controllers for a class of fed-batch fermentation processes. *Automatica*, v. 31, n. 6, pp. 817-840, 1995.
23. BCSV98 BRAAKE, H. A. B., CAN, E. J. L., SCHERPEN, J. M. A., VERBRUGGEN, H. B. Control of nonlinear chemical processes using neural models and feedback linearization. *Computers and Chemical Engineering*, v. 22, n. 7-8, pp. 1113-1127, 1998.
24. BLC00 BRAGA, A. P., LUDERMIR, T. B., CARVALHO, A. C. P. L. F. *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC Editora,

2000, 262 p.

25. BTC91 BREUSEGEM, V. van, THIBAUT, J., CHÉRUUY, A. Adaptive neural models for on-line prediction in fermentation. *The Canadian Journal of Chemical Engineering*, v. 69, pp. 481-487, apr 1991.
26. CTGC99 CADET, C., TOURE, Y., GILLES, G., CHABRIAT, J. P. Knowledge modelling and nonlinear predictive control of evaporators in cane sugar production plants. *Journal of Food Engineering*, v. 40, pp. 59-70, 1999.
27. CBH*97 CAN, H. J. L van, BRAAKE, H. A. B., HELLINGA, C., LUYBEN, K. C. A. M., HEIJNEN, J. J. An efficient model development strategy for bioprocesses based on neural networks in macroscopic balances. *Biotechnology and bioengineering*, v. 54, n. 6, pp. 549-566, jun 1997.
28. CRM71 CARLSON, R. A., RANDALL, J. M., MORGAN JR., A. I. Feedforward-feedback control of a vertical long-tube tomato evaporator. 1. experimental. *Journal of Food Science*, v. 36, pp. 685-687, 1971.
29. CR00 CHAN, H. L., RAD, A. B. Real-time flow control using neural networks. *ISA Transactions*, v. 39, pp. 93-101, 2000.
30. CBBA00 CHEN, L., BERNARD, O., BASTIN, G., ANGELOV, P. Hybrid modelling of biotechnological processes using neural networks. *Control Engineering Practice*, v. 8, pp. 821-827, 2000.
31. CKH95 CHENG, Y., KARJALA, T. W., HIMMELBLAU, D. M. Identification of nonlinear dynamic processes with unknown and variable dead time using an internal recurrent neural network. *Industrial Engineering Chemical Research*, v. 34, n. 5, pp. 1735-1742, 1995.
32. CPM97 CONLIN, J., PEEL, C., MONTAGUE, G. A. Modelling pressure drop in water treatment. *Artificial Intelligence in Engineering*, v. 11, pp. 393-400, 1997.
33. CL95 CUBILLOS, F. A., LIMA, E. L. Model predictive control based on a hybrid neural model. *Brazilian Journal of Chemical Engineering*, v. 12, n. 4, pp. 208-217, dec 1995.
34. CCLV00 CUBILLOS, F., CALLEJAS, H., LIMA, E. L., VEGA, M. P. Control predictivo adaptable de un reactor de polimerizacion usando un modelo hibrido-neuronal. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
35. Cyb89 CYBENKO, G. Approximation by superposition of a sigmoidal function. *Math. Control, Signal and Syst.*, v. 2, pp. 303-314, 1989.
36. DK94 DAOUTIDIS, P., KUMAR, A. Structural analysis and output feedback control of nonlinear multivariable processes. *AIChE Journal*, v. 40, n. 4, pp. 647-669, 1994.

37. DB98 DEMUTH, H., BEALE, M. *Neural network toolbox: user's guide*, The MathWorks Inc., 1998.
38. DMW*92 DI MASSIMO, C., MONTAGUE, G. A., WILLIS, M. J., THAM, M. T., MORRIS, A. J. Towards improved penicillin fermentation via artificial neural networks. *Computers and Chemical Engineering*, v. 16, n. 4, pp. 283-291, 1992.
39. DGW97 DOHERTY, S. K., GOMM, J. B., WILLIAMS, D. Experiment design considerations for non-linear system identification using neural networks. *Computers and Chemical Engineering*, v. 21, n. 3, pp. 327-346, 1997.
40. DNC95 DRISCOLL, R. H., NG, S., CHUAPRASERT, S. Evaporator process control using computer models. *Food Australia*, v. 41, n. 1, pp. 27-31, 1995.
41. DR99 DUTTA, P., RHINEHART, R. R. Application of neural network control to distillation and an experimental comparison with other advanced controllers. *ISA Transactions*, v. 38, pp. 251-278, 1999.
42. Ear?? EARLE, R. L. *Ingeniería de los alimentos*. 2a ed. Zaragoza (Espanha), Editorial Acirbia, pág. 105.
43. EGU99 ELHAQ, S. L., GIRI, F., UNBEHAUEN, H. Modelling, identification and control of sugar evaporation – theoretical design and experimental evaluation. *Control Engineering Practice*, v. 7, pp. 931-942, 1999.
44. EP97 EMMANOUILIDES, C., PETROU, L. Identification and control of anaerobic digesters using adaptive, on-line trained neural networks, *Computers and Chemical Engineering*, v. 21, n. 1, pp. 113-143, 1997.
45. EM00b ENDER, L., MACIEL FILHO, R. Design of multivariable controller aided by computer based on neural networks. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
46. EM00a ENDER, L., MACIEL FILHO, R. Utilização de modelo dinâmico neural em estratégia de controle preditivo multivariável. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
47. FCK00 FERREIRA, T. F., CASTRO, L. A. F., KALID, R. A. Simulação e otimização de um reator de DCPD utilizando redes neurais híbridas. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
48. FP97 FILETI, A. M. F., PEREIRA, J. A. F. R. Adaptive and Predictive Control Strategies for Batch Distillation: Development and Experimental

Testing, *Computers and Chemical Engineering*, v. 21, pp. S1227-S1231, 1997.

49. FOL00 FONSECA, A. P., OLIVEIRA, J. V., LIMA, E. L., Neural networks for predicting mass transfer parameters in supercritical extractions. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 517-524, dec 2000.
50. FB96 FU, P.-C., BARFORD, J. P. A hybrid neural network-first principles approach for modelling of cell metabolism. *Computers and Chemical Engineering*, v. 20, n. 6/7, pp. 951-958, 1996.
51. GWL00 GAO, F., WANG F., LI, M. A simple nonlinear controller with diagonal recurrent neural network, *Chemical Engineering Science*, v. 55, pp. 1283-1288, 2000.
52. GHZ98 GE, S. S., HANG, C. C., ZHANG, T. Nonlinear adaptive control using neural networks and its application to CSTR systems. *Journal of Process Control*, v. 9, pp. 313-323, 1998.
53. GIW*97 GLASSEY, J., IGNOVA, M., WARD, A. C., MONTAGUE, G. A., MORRIS, A. J. Bioprocess supervision: neural networks and knowledge based systems. *Journal of Biotechnology*, v. 52, pp. 201-205, 1997.
54. GRMP00b GONTARSKI, C. A., RODRIGUES, P. R., MORI, M., PRENEM, L. F. Avaliação das condições de operação de um sistema de tratamento de efluentes com auxílio de redes neuronais. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
55. GRMP00a GONTARSKI, C. A., RODRIGUES, P. R., MORI, M., PRENEM, L. F. Simulation of an industrial wastewater treatment plant using artificial neural networks. *Computers and Chemical Engineering*, v. 24, pp. 1719-1723, 2000.
56. GS84 GOODWIN, G.C., & K. S. SIN. *Adaptive Filtering Prediction and Control*, Prentice-Hall, Englewood Cliffs, New Jersey, 1984.
57. GS01 GOVATSMARK, M. S., SKOGESTAD, S. Control structure selection for an evaporation process. *European Symposium on Computer Aided Process Engineering 11*, Kolding, Denmark, 27-30, May, pp. 657-662, 2001.
58. HPC00 HANISCH, W. S., PIRES, E. C., CARVALHO, A. C. P. L. F. Modelo de redes neurais para o processo de lodos ativados de tratamento de esgotos domésticos. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.

59. HMC00 HARADA, L. H. P., MACIEL FILHO, R., COSTA, A. C. Hybrid neural modelling of an alcoholic fermentation process. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
60. HBB96 HARRIS, C. J., BROWN, M., BOSSLEY, K. M., MILLS, D. J., MING, F. Advances in neurofuzzy algorithm for real-time modelling and control. *Engineering Applications of Artificial Intelligence*, v. 9, n. 1, pp. 1-16, 1996.
61. Hay94 HAYKIN, S. *Neural networks: a comprehensive foundation*. USA: Macmillan College Publishing Company, 1994, 696 p.
62. HA93 HE, X., ASADA, H. A new method for identifying orders of input-output models for nonlinear dynamic systems. PROC. OF THE AMERICAN CONTROL CONF., S.F., California, 1993. (citado por NØRGAARD, 2000b)
63. HLS00 HENRIQUE, H. M., LIMA, E. L., SEBORG, D. E. Model structure determination in neural network models. *Chemical Engineering Science*, v. 55, pp. 5457-5469, 2000.
64. HS90 HENSON, M. A., SEBORG, D. E. Input-output linearization of general nonlinear processes. *AIChE Journal*, v. 36, n. 11, pp. 1753-1757, 1990.
65. HS92 HENSON, M. A., SEBORG, D. E. Nonlinear control strategies for continuous fermenters. *Chemical Engineering Science*, v. 47, n. 4, pp. 821-835, 1992.
66. Hen98 HENSON, M. Nonlinear model predictive control: current status and future directions. *Computers and Chemical Engineering*, v. 23, pp. 187-202, 1998.
67. HS97 HENSON, M., SEBORG, D. *Nonlinear process control*. USA: Prentice Hall, 1997, 432 p.
68. HA92 HERNÁNDEZ, E., ARKUN, Y. Study of the control-relevant properties of backpropagation neural network models of nonlinear dynamical systems. *Computers and Chemical Engineering*, v. 16, n. 4, pp. 227-240, 1992.
69. HH92 HOSKINS, J. C., HIMMELBLAU, D. M. Process Control via artificial neural networks and reinforcement learning. *Computers and Chemical Engineering*, v. 16, n. 4, pp. 241-251, 1992.
70. HS91 HUNT, K. J., SBARBARO, D. Neural networks for nonlinear internal model control. *IEE Proceedings – D*, v. 138, n. 5, pp. 431-438, 1991.
71. HSZG92 HUNT, K. J., SBARBARO, D., ZBIKOWSKI, R., GAWTHROP, P. J. Neural networks for control systems – a survey. *Automatica*, v. 28, n. 6, pp. 1083-1113, 1992.

72. Hus99 HUSSAIN, M. A. Review of the applications of neural networks in chemical process control – simulation and online implementation. *Artificial Intelligence in Engineering*, v. 13, pp. 55-68, 1999.
73. JMR97 JOSHI, N. V., MURUGAN, P., RHINEHART, R. R. Experimental comparison of control strategies. *Control Engineering Practice*, v. 5, n. 7, pp. 885-896, 1997.
74. KT00 KAM, K. M., TADÉ, M. O. Case studies on the modelling and control of evaporation systems. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
75. KT99 KAM, K. M., TADÉ, M. O. Nonlinear control of a simulated industrial evaporation system using a feedback linearization technique with a state observer. *Ind. Eng. Chem. Res.*, v. 38, pp. 2995-3006, 1999.
76. KMD*96 KAMBHAMPATI, C., MANCHANDA, S., DELGADO, A., GREEN, G. G. R., WARWICK, K., THAM, M. T. The relative order and inverses of recurrent networks. *Automatica*, v. 32, n. 1, pp. 117-123, 1996.
77. KT00 KAMINSKI, W., TOMCZAK, E. Evaluation of drying and degradation kinetics using neurocomputing. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 955-965, Dec 2000.
78. KR92 KARIM, M. N., RIVERA, S. L. Comparison of feed-forward and recurrent neural networks for bioprocess state estimation. *Computers and Chemical Engineering*, v. 16, pp. S369-S377, 1992.
79. KH94 KARJALA, T. W., HIMMELBLAU, D. M. Dynamic data rectification by recurrent neural networks vs. traditional methods. *AIChE Journal*, v. 40, n. 11, 1994.
80. KB98 KASPARIAN, V., BATUR, C. Model reference based neural network adaptive controller. *ISA Transactions*, v. 37, pp. 21-39, 1998.
81. KB99 KAVCHAK, M., BUDMAN, H. Adaptive neural network structures for non-linear process estimation and control. *Computers and Chemical Engineering*, v. 23, pp. 1209-1228, 1999.
82. KV92 KAVURI, S. N., VENKATASUBRAMANIAN, V. Combining pattern classification and assumption-based techniques for process fault diagnosis. *Computers and Chemical Engineering*, v. 16, n. 4, pp. 299-312, 1992.
83. KHS00 KHANMOHAMMADI, S., HASSANZADEH, I., SHARIFIAN, M. B. B. Modified adaptive discrete control system containing neural estimator and neural controller. *Artificial Intelligence in Engineering*, v. 14, pp. 31-38, 2000.
84. Kli98 KLIMASAUSKAS, C. C. Hybrid modeling for robust nonlinear multivariable control. *ISA Transactions*, v. 37, pp. 291-297, 1998.

85. KK90b KRAVARIS, C & J. C. KANTOR. Geometric Methods for Nonlinear Process Control. 1.Controller Synthesis, *Ind. Eng. Chem. Res.*, v. 29, n.12, pp. 2310-2323, 1990.
86. KK90a KRAVARIS, C & J. C. KANTOR. Geometric Methods for Nonlinear Process Control. 1.Background, *Ind. Eng. Chem. Res.*, v. 29, n. 12, pp. 2295-2310, 1990.
87. KJ00 KRISHNAPURA, V. G., JUTAN, A. A neural adaptive controller. *Chemical Engineering Science*, v. 55, pp. 3803-3812, 2000.
88. LTV99 LANOUEETTE, R., THIBAUT, J., VALADE, J. L. Process modeling with neural networks using small experimental datasets. *Computers and Chemical Engineering*, v. 23, pp. 1167-1176, 1999.
89. LH95 LI, Y., HÄUBLER, A. Artificial evolution of neural networks and its applications to feedback control. *Technical Report: CSC 95011*, Centre for Systems and Control and Department of Electronics and Electrical Engineering, University of Glasgow, Glasgow, UK, 1995.
90. LLZ97 LINKO, S., LUOPA, J., ZHU, Y.-H., Neural networks as 'software sensors' in enzyme production. *Journal of Biotechnology*, v. 52, pp. 257-266, 1997.
91. Lju99 LJUNG, L. *System identification – Theory for the user*. 2nd. ed., Prentice Hall, USA, 1999
92. Lju87 LJUNG, L. *System identification – Theory for the user*. Prentice Hall, USA, 1987
93. Lju98 LJUNG, L. *System Identification toolbox user's guide*. The MathWorks Inc., 1998.
94. LS83 LJUNG, L., & T. SODERSTROM. *Theory and Practice of Recursive Identification*, MIT Press, Cambridge, Massachusetts, 1983.
95. LG94 LJUNG, L., GLAD., T. *Modeling of Dynamic Systems*. Prentice-Hall, 1994.
96. LER84 LOZANO, J. E., ELUSTONDO, M. P., ROMAGNOLI, J. A. Control studies in an industrial apple juice evaporator. *Journal of Food Science*, v. 49, pp. 1422-1427, 1984.
97. LLMS95 LUNDSTRÖM, P., LEE, J. H., MORARI, M., SKOGESTAD, S. Limitations of dynamic matrix control. *Computers and Chemical Engineering*, v. 19, n. 4, pp. 409-421, 1995.
98. Luy89 LUYBEN, W. L. *Process modeling, simulation and control for chemical engineers*, 2nd. ed., McGraw-Hill, USA, 1989.
99. MSK98 MANESIS, S. A., SAPIDIS, D. J., KING, R. E. Intelligent control of wastewater treatment plants. *Artificial Intelligence in Engineering*, v. 12, pp. 275-281, 1998.
100. MC00 MARTINS, F. G., COELHO, M. A. N. Application of feedforward artificial neural networks to improve process control of PID based

artificial neural networks to improve process control of PID-based control algorithms. *Computers and Chemical Engineering*, v. 24, pp. 853-858, 2000.

101. MSH93 McCABE, W. L., SMITH, J. C., HARRIOT, P. *Unit operations of chemical engineering*, 5a ed., McGraw-Hill Intern., 1993. Cap. 16 – Evaporation.
102. MH00 McLAIN, R. B., HENSON, M. A. Principal component analysis for nonlinear model reference adaptive control. *Computers and Chemical Engineering*, v. 24, pp. 99-110, 2000.
103. MC95 MEGAN, L., COOPER, D. J. A neural network strategy for disturbance pattern classification and adaptive multivariable control. *Computers and Chemical Engineering*, v. 19, n. 2, pp. 171-186, 1995.
104. MM00 MELEIRO, L. A. C., MACIEL FILHO, R. State and parameter estimation based on a nonlinear filter applied to an industrial process control of ethanol production. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 991-1001, dec 2000.
105. MMT92 MONTAGUE, G. A., MORRIS, A. J., THAM, M. T. Enhancing bioprocess operability with generic software sensors. *Journal of Biotechnology*, v. 25, pp. 183-201, 1992.
106. MR98 MORARI, M. & RICKER, N. L. *Model predictive control toolbox: user's guide*, The MathWorks Inc., 1998.
107. ML99 MORARI, M., LEE, J. H. Model predictive control: past, present and future. *Computers and Chemical Engineering*, v. 23, pp. 667-682, 1999.
108. Nar90 NARENDRA, K. S. *Neural Networks for Control*. Edited by W. T. Miller, R. S. Sutton, P. J. Werbos. USA: MIT Press. Chap. 5: Adaptive control using neural networks. pp. 115-142, 1990.
109. NP90 NARENDRA, K. S., PARTHASARATHY, K. Identification and control of dynamical systems using neural networks. *IEEE Transactions on Neural Networks*, v. 1, n. 1, pp. 4-27, 1990.
110. NF72 NEWELL, R. B., FISHER, D. G. Model Development, Reduction, and Experimental Evaluation for an Evaporator. *Ind. Eng. Chem. Process Des. Develop.*, v. 11, no. 2, pp. 213-221, 1972.
111. NL88 NEWELL, R. B., LEE, P. L. *Applied process control: a case study*. Victoria, Australia: Prentice Hall, 1988, 146 p.
112. NFS96 NIKKAVESH, M., FARELL, A. E., STANFORD, T. G. Model identification of nonlinear time variant processes via artificial neural network. *Computers and Chemical Engineering*, v. 20, n. 11, pp. 1277-1290, 1996.
113. Nik98 NIKOLAOU, M. Process measurement and control: industry needs. Workshop on Identification and adaptive control. *Computers and*

Chemical Engineering, v. 23, pp. 217-227, 1998.

114. NFS00 NIKRAVESH, M., FARELL, A. E., STANFORD, T. G. Control of nonisothermal CSTR with time varying parameters via dynamic neural network control (DNNC). *Chemical Engineering Journal*, v. 76, pp. 1-16, 2000.
115. NFS97 NIKRAVESH, M., FARELL, A. E., STANFORD, T. G. Dynamic neural network control for non-linear systems: optimal neural network structure and stability analysis. *Chemical Engineering Journal*, v. 68, pp. 41-50, 1997.
116. Nor00a NØRGAARD, M. Neural Network Based Control System Design Toolkit, ver. 2, *Tech. Report.* 00-E-892, Department of Automation, Technical University of Denmark, 2000.
117. Nor00b NØRGAARD, M. Neural Network Based System Identification Toolbox. *Tech. Report.* 00-E-891, Department of Automation, Technical University of Denmark, 2000.
118. NRP00 NØRGAARD, M., RAVN, O., POULSEN, N. K., HANSEN, L. K. *Neural networks for modelling and control of dynamic systems*, London: Springer Verlag, 2000.
119. OR94 OGUNNAIKE, B.A., RAY, W.H. *Process Dynamics, Modeling, and Control*, Oxford University Press, 1994.
120. OMH00 OKUDA, G., MURATA, V. V., HENRIQUE, H. M. O uso de redes neuronais de base radial em estrutura de blocos orientados para identificação de sistemas dinâmicos não lineares. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
121. OMB00 OLIVEIRA, K. P. S., MORI, M. BRUNS, R. E. Modelagem de um sistema de lagoas aeradas utilizando as técnicas de redes neurais e de análise de componentes principais. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
122. Pay89 PAYNE, J. H. *Operações unitárias na produção de açúcar de cana*. São Paulo, Nobel-STAB, 1989.
123. PG97 PERRY, R. H., GREEN, D. W. (Editores) *Perry's chemical engineers' handbook*. USA, McGraw-Hill, 1997.
124. PWL96 POLE-Y. I, WU, W.-T., LIU, Y.-C. Neural network modeling for on-line state estimation in fed-batch culture of L-lysine production. *The Chemical Engineering Journal*, v. 61, pp. 35-40, 1996.
125. PBGS92 POLLARD, J. F., BROUSSARD, M. R., GARRISON, D. B., SAN, K. Y. Process identification using neural networks. *Computers and*

Chemical Engineering, v. 16, n. 4, pp. 253-270, 1992.

126. PTS00 POSSER, M. S., TRIERWEILER, J. O., SECCHI, A. R. Comparação sistemática entre redes de modelos locais e redes neurais. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
127. PSY88 PSALTIS, D., SIDERIS, A., YAMAMURE, A. A. A multilayered neural network controller, *Control System Magazine*, v. 8, n. 2, pp.17-21, 1988. (citado por NØRGAARD, 2000a)
128. PU92 PSICHOGIOS, D. C., UNGAR, L. H. A hybrid neural network-first principles approach to process modeling. *AIChE Journal*, v. 38, n. 10, 1992.
129. QZLY99 QI, H., ZHOU, X.-G., LIU, L.-H., YUAN, W.-K. A hybrid neural network-first principles model for fixed-bed reactor. *Chemical Engineering Science*, v. 54, pp. 2521-2526, 1999.
130. QWH94 QUAACK, P., VAN WIJCK, M. P. C. M., VAN HAREN, J. J. Comparison of process identification and physical modelling for falling-film evaporators. *Food Control*, v. 5, n. 2, pp. 73-82, 1994.
131. RLCM71 RANDALL, J. M., LEVY, R., CARLSON, R. A., MORGAN JR., A. I. Feedforward-feedback control of a vertical long-tube tomato evaporator. 1. analog simulation. *Journal of Food Science*, v. 36, pp. 681-684, 1971.
132. Rau98 RAUCH, H. E. A control engineer's use of artificial intelligence. *Control Engineering Practice*, v. 6, pp. 249-258, 1998.
133. RL00 RODRIGUES, S., LONA, L. M. F. Desenvolvimento de redes neurais para determinação de taxas de reação enzimática, adsorção e dessorção de proteínas em processos biotecnológicos. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
134. RG97 RONCO, E., GAWTHROP, P. J. Neural networks for modelling and control. *Technical Report: SCS 97008*, Centre for System and Control, Department of Mechanical Engineering, University of Glasgow, Glasgow, UK, 1997.
135. RG95 RONCO, E., GAWTHROP, P. Modular neural networks: a state of the art. *Technical Report: CSC-95026*, Centre of Systems and Control, University of Glasgow, Glasgow, UK, 1995.
136. RS00 RUIZ, C. A., SONNET, A. Neural networks applications in the process industry. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil,

Setembro, 24-27, 2000.

137. RRM91 RUNYON, C. H., RUMSEY, T. R., McCARTHY. Dynamic simulation of a nonlinear model of a double effect evaporator. *Journal of Food Engineering*, v. 14, pp. 185-201, 1991.
138. RB97 RUSSEL, N. T., BAKKER, H. C. Modular modelling of an evaporator for long-range prediction. *Artificial Intelligence in Engineering*, v. 11, pp. 347-355, 1997.
139. SNR99 SAFAVI, A. A., NOORAI, A. ROMAGNOLI, J. A. A hybrid model formulation for a distillation column and the on-line optimisation study. *Journal of Process Control*, v. 9, pp. 125-134, 1999.
140. SCS00 SANTOS, V. M. L., CARVALHO, F. R., SOUZA JR., M. B. Predictive control based on neural networks: an application to a fluid catalytic cracking industrial unit. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 897-905, dec 2000.
141. SEM89 SEBORG, D. E., EDGAR, T. F., MELLICHAMP, D. A. *Process dynamics and control*. John Wiley. USA, 1989.
142. SES86 SEBORG, D. E., T. F. EDGAR, S. L. SHAH. Adaptive Control Strategies for Process Control: A Survey, *AIChE Journal*, v. 32, n. 6, pp. 881-913, 1986.
143. SDS97 SHAW, A. M., DOYLE III, F. J., SCHWABER, J. S. A dynamic neural network approach to nonlinear process modeling. *Computers and Chemical Engineering*, v. 21, n. 4, pp. 371-385, 1997.
144. Shi96 SHIMIZU, K. A tutorial review on bioprocess systems engineering. *Computers and Chemical Engineering*, v. 20, n. 6/7, pp. 915-941, 1996.
145. SP00 SHU, H., PI, Y. PID neural networks for time-delay systems. *Computers and Chemical Engineering*, v. 24, pp. 859-862, 2000.
146. SCH*00 SILVA, R. G., CRUZ, A. J. G., HOKKA, C. O., GIORDANO, R. L. C., GIORDANO, R. C. A hybrid feedforward neural network model for the Cephalosporin C production process. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 587-597, dec 2000.
147. SZL*95 SJÖBERG, J., ZHANG, Q., LJUNG, L., BENVENISTE, A., DELYON, B., GLORENNEC, P.-Y., HJALMARSSON, H., JUDITSKY, A. Nonlinear black-box modeling in system identification: a unified overview. *Automatica*, v. 31, n. 12, pp. 1691-1724, 1995.
148. Sør94 SØRENSEN, O. Neural networks in control applications. Ph.D. Thesis. Aalborg University, Department of Control Engineering, 1994. (citado por NØRGAARD, 2000a)
149. SH96 STEPHANOPOULOS, G., HAN, C. Intelligent systems in process engineering: a review. *Computers and Chemical Engineering*, v. 20, n. 6/7, pp. 743-791, 1996.

150. Str88 STRANG, G. Linear álgebra and its applications. 3a ed. San Diego: Harcourt Jovanovich, 505 p., 1988.
151. SMO-97 STUART, G., MACHADO, R., OLIVEIRA, J. V., ULLER, A. C., LIMA, E. L. Hybrid artificial neural network applied to modeling scfe of basil and rosemary oils. *Ciênc. Tecnol. Aliment.*, v. 17, n. 4, pp. 501-505, dez 1997.
152. ST93 SYU, M.-J., TSAO, G. T. Neural network modeling of batch cell growth pattern. *Biotechnology and bioengineering*, v. 42, pp. 376-380, 1993.
153. Tei91 TEIXEIRA, E. P. *Controle de sistemas não lineares através de redes neurais*. Campinas: Faculdade de Engenharia Elétrica, Universidade Estadual de Campinas, 1991. Tese (Doutorado).
154. Tmat98 THE MATHWORKS, *Neural Network Toolbox User's Guide – Version 3.0*, USA, 1998
155. TBC90 THIBAUT, J., BREUSEGEM, V. van, CHÉRUUY, A. On-line prediction of fermentation variables using neural networks. *Biotechnology and bioengineering*, v. 36, pp. 1041-1048, dec 1990.
156. TR96 THOLUDUR, A., RAMIREZ, W. F. Optimization of fed-batch bioreactors using neural network parameter function models. *Biotechnology Progress*, v. 12, pp. 302-309, 1996.
157. TTKP95 TO, L. C., TADÉ, M. O., KRAETZL, M., LE PAGE, G. P. Nonlinear control of a simulated industrial evaporation process. *J. Proc. Cont.*, v. 5, n. 3, pp. 173-182, 1995.
158. TTP98 TO, L. C., TADÉ, M. O., LE PAGE, G. P. Implementation of a differential geometric nonlinear controller on an industrial evaporator system. *Control Engineering Practice*, v. 6, pp. 1309-1319, 1998.
159. TRP90 TONELLI, S. M., ROMAGNOLI, J. A., PORRAS, J. Computer Package for transient analysis of industrial multiple-effect evaporators. *Journal of Food Engineering*, v. 12, pp. 267-281, 1990.
160. Ung90 UNGAR, L. H. *Neural Networks for Control*. Edited by W. T. Miller, R. S. Sutton, P. J. Werbos. USA: MIT Press. Chap. 16: A bioreactor benchmark for adaptive network-based process control . pp. 387-402, 1990.
161. UPK90 UNGAR, L. H., POWELL, B. A., KAMENS, S. N. Adaptive networks for fault diagnosis and process control. *Computers and Chemical Engineering*, v. 14, n. 4/5, pp. 561-572, 1990.
162. Leu93 van LEUNEN, W. T. *Neural networks for control: on knowledge representation and learning*. Ph.D Thesis, Control Laboratory of Electrical Engineering, University of Twente, Enschede, Holanda (citado por NØRGAARD, 2000a)
163. WQH94 VAN WIJCK, M. P. C. M., QUAACK, P., VAN HAREN, J. J. Multivariable supervisory control of a four-effect falling-film evaporator. *Food*

Control, n. 5, v. 2, pp. 83-89, 1994.

164. VLP00 VEGA, M. P., LIMA, E. L., PINTO, J. C. Control of a loop polymerization reactor using neural networks. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 471-481, dec 2000.
165. VM92 VENKATASUBRAMANIAN, V., McAVOY, T. J. Editorial: Neural network applications in Chemical Engineering. *Computers and Chemical Engineering*, v. 16, n. 4, pp. v-vi, 1992.
166. VMH00 VILAÇA, A. C., MURATA, V. V., HENRIQUE, H. M. Uma nova proposta de MPC baseado em modelo de rede neuronal de base radial. In XII CONGRESSO BRASILEIRO DE ENGENHARIA QUÍMICA E XIX INTERAMERICAN CONGRESS OF CHEMICAL ENGINEERING, Águas de São Pedro, SP, Brasil, Setembro, 24-27, 2000.
167. WII90 WILLIAMS, R. *Neural Networks for Control*. Edited by W. T. Miller, R. S. Sutton, P. J. Werbos. USA: MIT Press. Chap. 4: Adaptive state representation and estimation using recurrent connectionist networks. pp. 97-114, 1990.
168. WMM*91 WILLIS, M. J., MASSIMO, C. di, MONTAGUE, G. A., THAM, M. T., MORRIS, A. J. Artificial neural networks in process engineering. *IEE Proceedings – D*, v. 138, n. 3, pp. 256-266, may 1991.
169. WMM*92 WILLIS, M. J., MONTAGUE, G. A., DI MASSIMO, C., THAM, M. T., MORRIS, A. J. Artificial neural networks in process estimation and control. *Automatica*, v. 28, n. 6, pp. 1181-1187, 1992.
170. WZ97 WILSON, J. A., ZORZETTO, L. F. M. A generalised approach to process state estimation using hybrid artificial neural network/mechanistic models. *Computers and Chemical Engineering*, v. 21, n. 9, pp. 951-963, 1997.
171. YN93 YOU, Y., NIKOLAOU, M. Dynamic process modeling with recurrent neural networks. *AIChE Journal*, v. 39, n. 10, pp. 1654-1667, 1993.
172. ZVGF00 ZAMARREÑO, J. M., VEGA, P., GARCÍA, L. D., FRANCISCO, M. State-space neural network for modelling prediction and control. *Control Engineering Practice*, v. 8, pp. 1063-1075, 2000.
173. ZMM00 ZORZETTO, L. F. M., MACIEL FILHO, R., WOLF-MACIEL, M. R. Process modelling development through artificial neural networks and hybrid models. *Computers and Chemical Engineering*, v. 24, pp. 1355-1360, 2000.
174. ZAL00 ZYNGIER, D., ARAÚJO, O. Q. F., LIMA, E. L. Soft sensors with white- and black-box approaches for a wastewater treatment process. *Brazilian Journal of Chemical Engineering*, v. 17, n. 4-7, pp. 433-440, dec 2000.

Pesos da rede neural "forward" utilizada na identificação dos dois reatores em série; estrutura [3,3,1] e 7 neurônios na camada interna; função de ativação da camada interna: *Fast hyperbolic tangent* ($t=1-2./(\exp(2*x)+1)$); função de ativação da camada de saída: linear;

W1f=

175.1556	-40.3875	-22.1760	0.0015	0.0060	0.0014	-0.9001
313.1547	-243.8762	36.3585	0.0015	0.0038	0.0012	-1.4683
-195.7033	330.9697	-110.8481	-0.0024	-0.0034	-0.0016	0.9922
-40.8286	67.2133	56.3247	0.0004	0.0053	0.0001	-0.7771
15.9198	224.5659	-64.1348	0.0001	-0.0028	0.0003	0.8434
50.2744	-191.0614	205.2880	0.0002	0.0004	-0.0021	-0.3155
357.5020	-289.3979	38.3196	0.0020	0.0033	0.0007	-2.6530

W2f = [0.0026 0.0048 0.0025 -0.0022 0.0032 0.0023 0.0062 0.0076]^T

Pesos da rede neural que descreve a dinâmica inversa utilizada no controle dos dois reatores em série; estrutura [3,3,1] e 7 neurônios na camada interna; função de ativação da camada interna: *Fast hyperbolic tangent* ($t=1-2./(\exp(2*x)+1)$); função de ativação da camada de saída: linear;

W1i = 1.0e+003 *

1.5786	-2.4146	0.7582	-0.1085	-0.0000	0.0001	-0.0024
0.0308	0.1864	-0.1483	0.0234	0.0000	-0.0000	-0.0012
-0.2894	0.3000	0.5530	-0.3604	-0.0000	0.0000	-0.0007
-0.3017	0.6202	-0.4886	0.1109	0.0000	-0.0000	-0.0001
0.4488	-0.1615	0.1302	-0.1099	0.0000	0.0000	0.0001
-0.2990	0.4832	0.6509	-0.3420	-0.0000	0.0000	0.0006
0.4083	-0.2398	0.2224	-0.2786	-0.0000	0.0000	0.0011

W2i = [-8.9483 -192.2515 -93.0424 -398.4012 426.6775 -313.9682 51.7632 -87.7793]^T

Pesos da rede neural utilizada no controle linearizante entrada-saída dos dois reatores em série; estrutura [3,3,1] e 7 neurônios na camada interna; função de ativação da camada interna: *Fast hyperbolic tangent* ($t=1-2./(\exp(2*x)+1)$); função de ativação da camada de saída: linear;

W1f=

320.6262	-245.3434	-26.9690	0.0003	0.0006	-1.2183
-47.6568	279.9737	-101.7342	-0.0025	0.0002	0.3285
-262.4422	217.6637	-42.2226	-0.0037	-0.0008	0.8969
-250.7050	194.9886	-68.6589	-0.0033	-0.0007	2.5303
199.6184	128.4450	-10.9155	-0.0043	-0.0015	-0.3669
3.2317	50.5120	-141.7991	0.0040	0.0042	-0.4125
4.2049	-82.4926	-107.4341	0.0068	0.0045	-0.1816

$$W2f = [0.0032 \quad 0.0040 \quad -0.0051 \quad -0.0042 \quad -0.0004 \quad -0.0021 \quad 0.0005 \quad 0.0087]^T$$

$$W1g =$$

-33.2400	-77.1062	29.9250	-0.0065	0.0034	0.7725
-52.1049	-50.0655	-72.5568	0.0030	0.0015	0.7401
32.2473	6.4052	-9.7151	-0.0088	-0.0011	0.7558
13.6952	-1.7236	-1.2420	-0.0104	-0.0025	1.4581
-63.5219	11.2939	-12.4700	-0.0115	0.0006	1.6692
-30.6772	-118.6724	-44.2700	-0.0028	0.0026	0.9333
-59.9986	-20.7546	-111.7728	0.0008	0.0002	0.9806

$$W2g = 1.0e-004 * [-0.5277 \quad 0.3359 \quad 0.3168 \quad -0.3463 \quad 0.3398 \quad 0.3303 \quad -0.4976 \quad 0.0859]^T$$

Modelo ARX 310 utilizado para identificar o evaporador de duplo efeito. Válido somente para os dados escalonados conforme descrito no texto.

This ARX-model was created by the command ARX on 10/8 2001 at 10:54

Loss fcn: 5.6486e-018 The FPE criterion: 7.5402e-018 Sampling interval 1

The arx model parameters with their standard deviations given as imaginary parts are

$$A =$$

Columns 1 through 4

1.0000	0	0	-1.2743 + 0.0085i
0	1.0000	0	-0.2479 + 0.0076i
0	0	1.0000	0.2578 + 0.0107i

Columns 5 through 8

-0.0425 + 0.0155i	0.6050 + 0.0244i	0.3858 + 0.0150i	0.0557 + 0.0255i
-1.0399 + 0.0139i	0.5420 + 0.0218i	0.3487 + 0.0134i	0.0512 + 0.0228i
-0.0320 + 0.0195i	-1.6774 + 0.0306i	-0.3438 + 0.0188i	0.0101 + 0.0320i

Columns 9 through 12

-0.8174 + 0.0404i	-0.1120 + 0.0085i	-0.0142 + 0.0136i	0.2271 + 0.0200i
-0.7343 + 0.0361i	-0.1030 + 0.0076i	-0.0124 + 0.0122i	0.2046 + 0.0179i
0.8581 + 0.0507i	0.0853 + 0.0107i	0.0207 + 0.0170i	-0.1651 + 0.0250i

$$B =$$

-0.0201 + 0.0004i	-0.1089 + 0.0007i	0.0006 + 0.0007i
-0.0181 + 0.0004i	0.0888 + 0.0006i	-0.0481 + 0.0006i

0.0196 + 0.0005i -0.0422 + 0.0008i 0.0016 + 0.0008i

The covariance matrix of the innovations is

lam =

1.0e-005 *

0.9997	0.0366	-0.0007
0.0366	0.0815	-0.0594
-0.0007	-0.0594	0.1145

Modelo ARX 310 utilizado para identificar o evaporador de duplo efeito. Válido somente para os dados escalonados conforme descrito no texto.

This ARX-model was created by the command ARX on 10/8 2001 at 11:9

Loss fcn: 3.402e-019 The FPE criterion: 4.8883e-019 Sampling interval 1

The arx model parameters with their standard deviations given as imaginary parts are

A =

Columns 1 through 4

1.0000	0	0	-0.9996 + 0.0003i
0	1.0000	0	-0.0015 + 0.0003i
0	0	1.0000	-0.0036 + 0.0014i

Columns 5 through 6

0.0001 + 0.0003i	0.0024 + 0.0004i
-1.0002 + 0.0002i	0.0011 + 0.0004i
-0.0044 + 0.0013i	-0.9690 + 0.0021i

B =

Columns 1 through 4

-0.0188 + 0.0001i	-0.1098 + 0.0002i	0.0001 + 0.0002i	-0.0213 + 0.0001i
-0.0169 + 0.0001i	0.0879 + 0.0002i	-0.0485 + 0.0002i	-0.0191 + 0.0001i
0.0185 + 0.0007i	-0.0416 + 0.0011i	-0.0007 + 0.0011i	0.0217 + 0.0008i

Columns 5 through 8

0.0001 + 0.0002i	-0.0002 + 0.0003i	-0.0082 + 0.0001i	0.0000 + 0.0002i
0.0002 + 0.0002i	-0.0002 + 0.0002i	-0.0074 + 0.0001i	0.0001 + 0.0002i
0.0011 + 0.0012i	0.0013 + 0.0013i	0.0091 + 0.0008i	0.0013 + 0.0012i

Columns 9 through 12

```
0.0003 + 0.0003i -0.0039 + 0.0001i 0.0000 + 0.0002i 0.0003 + 0.0002i
0.0002 + 0.0002i -0.0034 + 0.0001i 0.0003 + 0.0002i 0.0002 + 0.0002i
-0.0007 + 0.0013i 0.0071 + 0.0007i 0.0002 + 0.0011i 0.0006 + 0.0011i
```

The covariance matrix of the innovations is

lam =

1.0e-005 *

```
0.9061 -0.0472 0.0540
-0.0472 0.0063 -0.0105
0.0540 -0.0105 0.1155
```

Pesos da rede neural utilizada para identificar a dinâmica do evaporador de duplo efeito. Válidos somente para os dados escalonados conforme descrito no texto; 6 neurônios na camada interna; função de ativação da camada interna: *Fast hyperbolic tangent* ($t=1-2./(\exp(2*x)+1)$); e 3 neurônios lineares na camada de saída.

W1e = Columns 1 through 7

```
0.7874 0.0166 0.0140 -0.0669 -0.1081 -0.0687 0.1182
-0.3092 -0.4554 -0.0785 -0.0205 0.1643 -0.2951 -0.5220
-0.2375 -0.0771 -0.0052 -0.4840 0.0657 -0.6894 0.0760
0.5080 0.7881 0.0273 0.5035 0.4364 1.3253 0.5482
0.4681 -0.4373 -0.2406 0.2036 1.2580 0.2343 -0.8639
-0.1492 0.2727 0.0622 -0.0266 -0.1313 0.0707 0.2909
```

Columns 8 through 14

```
0.0633 -0.1090 -0.0193 0.0179 -0.1256 -0.0941 0.6927
-0.1199 0.3145 0.0725 0.3799 0.2314 0.3561 0.4932
0.4285 -0.4939 -0.0099 0.4005 -0.2689 -0.4155 -0.2801
-0.1161 -0.0828 -0.2936 -1.1949 0.3619 -0.2882 0.7630
-0.1383 0.4093 -0.1434 -0.1430 1.0372 0.3312 0.3212
0.0911 -0.1978 -0.0294 -0.1398 -0.1754 -0.2026 -0.0138
```

Columns 15 through 16

```
-0.1697 0.0983
0.4951 0.0499
-0.4144 -0.5645
0.6675 0.0853
0.0542 -0.0407
1.1414 -0.1244
```

W2e =

0.9360	-0.9864	-0.7413	-0.6440	0.5367	0.7132	-0.2568
0.2890	1.1380	0.5937	0.6568	-0.4460	-0.6687	0.0626
0.1280	-0.0422	-0.2938	-0.2220	0.2069	0.9434	-0.0162