

UNIVERSIDADE FEDERAL DE ALAGOAS
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA

ALEX FERNANDES ROCHA TEIXEIRA

**IDENTIFICAÇÃO DE UMA COLUNA DE DESTILAÇÃO DE METANOL-ÁGUA
ATRAVÉS DE MODELOS PARAMÉTRICOS E REDES NEURAS ARTIFICIAIS.**

Maceió

2011

ALEX FERNANDES ROCHA TEIXEIRA

**IDENTIFICAÇÃO DE UMA COLUNA DE DESTILAÇÃO DE METANOL-ÁGUA
ATRAVÉS DE MODELOS PARAMÉTRICOS E REDES NEURAI ARTIFICIAIS.**

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal de Alagoas, sob orientação da PhD. Cristiane Holanda Sodré, como requisito para obtenção do título de Mestre em Engenharia Química.

Orientador: Profa. Dra. Cristiane Holanda Sodré

Coorientador: Dr. Frede Oliveira Carvalho

Maceió

2011

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecária Responsável: Helena Cristina Pimentel do Vale

- T266i Teixeira, Alex Fernandes Rocha.
Identificação de uma coluna de destilação de metanol-água através de modelos paramétricos e redes neurais artificiais / Alex Fernandes Rocha Teixeira. – 2011.
150 f. : il., tabs., graf.
- Orientador: Profa. Dra. Cristiane Holanda Sodr e
Co-Orientador: Dr. Frede Oliveira Carvalho
Disserta o (mestrado em Engenharia Qu mica) – Universidade Federal de Alagoas. Centro de Tecnologia. Macei , 2011.
- Bibliografia: f. 142-147.
Anexos: f. 148-150;
1. Redes neurais artificiais. 2. Sinais bin rios pseudo-aleat rio.
3. Modelos param tricos discretos lineares. I. T tulo.

CDU: 66.0: 004.4

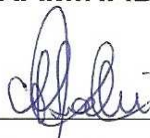
Alex Fernandes Rocha Teixeira

IDENTIFICAÇÃO DE UMA COLUNA DE DESTILAÇÃO DE METANOL-ÁGUA
ATRAVÉS DE MODELOS PARAMÉTRICOS E REDES NEURAIS
ARTIFICIAIS


Dissertação apresentada à Universidade
Federal de Alagoas, como requisito para a
obtenção do Título de Mestre em Engenharia
Química

Aprovada em: Maceió, 04 de Outubro de 2011.

BANCA EXAMINADORA



Prof^a. Dr^a. Cristiane Holanda Sodré
(PPGEQ/UFAL – Orientadora)



Prof. Dr. William Gonçalves Vieira
(PPGEQ/UFAL)



Dr. Júlio Inácio Tavares
(BRASKEM S.A. – Membro Externo)

Trabalho dedicado a minha irmã, meus avós, meus primos, tios e tias, amigos, professores, e em especial a todos os brasileiros que se preocupam com nossa nação e veem a educação como solução para formar um mundo mais digno e humano.

AGRADECIMENTOS

Primeiramente agradeço a Deus que me permitiu ter saúde, me iluminou, e me colocou numa família que me possibilitou ter boas oportunidades na vida e que mediante as minhas tomadas de decisões, foi possível realizar este sonho.

Agradeço também aos meus pais e a meus avós, que foram fatores essenciais em minha educação e para todos os momentos da minha vida.

Agradeço a minha irmã que é pra mim uma fonte de inspiração e motivação.

Tenho muita gratidão a meus professores e amigos Júlio Inácio de Holanda Tavares Neto e Ademir Aiton de Oliveira, que são duas referências de profissionais e seres humanos que eu tento seguir.

Agradeço a todos meus familiares que me acolheram e apoiaram sempre que eu precisei.

Agradeço a meus amigos e colegas de trabalho, pois são exemplos vivos de comprometimento e superação.

E por fim, presto agradecimentos a minha professora orientadora PhD. Christiane Holanda Sodré, que teve a paciência e a boa vontade de me orientar no desenvolvimento deste trabalho, ao professor Willian Gonçalves Vieira e a todos aqueles que de alguma forma contribuíram para a realização deste trabalho.

“Amarás ao senhor teu Deus de todo o teu coração, de toda a tua alma, de todo entendimento e de todas as tuas forças e amarás teu próximo como a ti mesmo”

Marcos 12: 30 e 31

RESUMO

Foi realizado neste trabalho identificação caixa preta do processo de destilação Metanol-Água nas configurações malha aberta e malha fechada, utilizando como sinais de perturbação a função degrau e o Sinal Binário Pseudo-Aleatório (PRBS) para excitar a planta. Os modelos matemáticos candidatos a identificação foram as Redes Neurais Artificiais (RNA), e os modelos paramétricos discretos lineares autorregressivo com entradas externas (ARX do inglês *AutoRegressive with eXogenous Inputs*), autorregressivo com média móvel e entradas exógenas (ARMAX do inglês *AutoRegressive Moving Average with eXogenous Inputs*), modelo do tipo erro na saída (OE do inglês *Output Error*) e a estrutura Box-Jenkins (BJ). Com a disposição dos modelos, foram comparados quais dos modelos matemáticos candidatos à identificação melhor representa o processo coluna de destilação metanol-água. Comparou-se qual configuração do processo no ensaio de identificação para geração de dados apresenta mais vantagens, se em malha aberta ou em malha fechada, nas condições e metodologias utilizadas. Constatou-se a funcionalidade do sinal binário pseudo-aleatório como uma boa opção de excitação na identificação em malha aberta e fechada para sistemas dinâmicos.

Palavras-chave: Redes neurais artificiais. Sinais binários pseudo-aleatório. Modelos paramétricos discretos lineares.

ABSTRACT

This work presents a black box identification for a continuous methanol-water distillation column setting in open loop and closed loop response. Step changes and Pseudo-Random Binary Signal (PRBS) disturbance were used to excite the plant. The mathematical models candidates to identify were the Artificial Neural Networks (ANN) and the parametric models: ARX (autoregressive with exogenous inputs), ARMAX (AutoRegressive Moving Average with eXogenous inputs), OE (Output Error) and the Box-Jenkins (BJ) structure. The closed loop configuration was the R-V. The results showed that for the bottom loop, the best response were given by BJ, OE and RNA for both open and closed loop response. For the top closed loop, the best responses were also given by BJ, OE and RNA while in open loop condition, the RNA was the one that gave satisfactory outcome. It was verified that the pseudo-random binary signal was a good choice of excitation signal in identification for both open loop and closed dynamic systems.

Keywords: Artificial neural networks. Pseudo-random binary Signals. Discrete linear parametric models.

LISTA DE FIGURAS

Figura 3.1 - Circuito RLC, (Resistivo, indutivo e capacitivo).....	33
Figura 3.2 - Resposta ao degrau de sistemas de primeira ordem.....	36
Figura 3.3 - Modelo ARX em diagrama de blocos em duas configurações.....	42
Figura 3.4 - Modelo ARMAX em diagrama de blocos em duas configurações.....	43
Figura 3.5 - Modelo OE em diagrama de blocos.....	44
Figura 3.6 - Modelo BJ em diagrama de blocos.....	45
Figura 3.7 - Funcionamento do sistema nervoso.....	50
Figura 3.8 - Analogia entre um neurônio biológico e matemático.....	50
Figura 3.9 - Modelo de neurônio.....	51
Figura 3.10 - Rede feedforward de camada única.....	53
Figura 3.11 - Estrutura genérica de uma feedforward com uma camada oculta.....	53
Figura 3.12 - Rede MLP com uma camada intermediária.....	54
Figura 3.13 - Rede com função de ativação de base radial.....	56
Figura 3.14 - Rede recorrente com neurônios ocultos.....	57
Figura 3.15 - Treinamento supervisionado.....	59
Figura 3.16 - Treinamento não supervisionado.....	60
Figura 3.17 - Modelo básico de treinamento por reforço.....	61
Figura 3.18 - Diagrama de blocos de uma malha aberta.....	65
Figura 3.19 - Diagrama de blocos de uma malha fechada.....	66
Figura 3.20 - Fluxograma de sinais de excitação usados para identificação em malha Fechada.....	71
Figura 3.21 - Sinal Binário Pseudo-Aleatório.....	73
Figura 3.22 - Circuito eletrônico digital gerador de PRBS.....	75
Figura 4.1 - Fluxograma da planta de destilação Metanol-Água usada nesta dissertação..	77
Figura 4.2 - Foto da planta de destilação Metanol-Água usada nesta dissertação.....	78
Figura 5.1 - Diagrama de blocos das malhas de controle 1 e 2 da coluna de Destilação Metanol-Água.....	82
Figura 5.2 - Fluxograma da metodologia utilizada para identificação em malha aberta e projeto dos controladores PID.....	84
Figura 5.3 - Fluxograma da metodologia utilizada para o planejamento experimental	

através do PRBS para identificação em malha fechada.....	86
Figura 5.4 - Fluxograma da metodologia utilizada para o procedimento de identificação em malha fechada.....	88
Figura 5.5 - Fluxograma da metodologia utilizada para o procedimento de identificação em malha aberta.....	89
Figura 6.1 - Resposta da malha 1 à perturbação degrau positiva de 7% na vazão de vapor.....	90
Figura 6.2 - Resposta da malha 1 à perturbação degrau negativa de 7% na vazão de vapor.....	91
Figura 6.3 - Resposta da malha 2 à perturbação degrau positiva de 7% na vazão de Refluxo.....	92
Figura 6.4 - Resposta da malha 2 à perturbação degrau negativa de 7% na vazão de Refluxo.....	92
Figura 6.5 - Indicação das variações da variável manipulada e de processo para determinação do ganho da malha 1 através de perturbação degrau.....	93
Figura 6.6 - Indicação de como encontrar o tempo de resposta da malha 1 submetida a uma perturbação degrau.....	93
Figura 6.7 - Comparação da resposta do modelo da equação 6.1 em relação aos dados experimentais.....	95
Figura 6.8 - Curva de coeficiente de regressão entre modelo da equação 6.1 e dados experimentais.....	96
Figura 6.9 - Comparação da resposta do modelo da equação 6.2 em relação aos dados experimentais.....	97
Figura 6.10 - Curva de coeficiente de regressão entre modelo da equação 6.2 e dados experimentais.....	98
Figura 6.11 - Comparação da resposta do modelo da equação 6.3 em relação aos dados experimentais.....	99
Figura 6.12 - Curva de coeficiente de regressão entre modelo da equação 6.3 e dados experimentais.....	100
Figura 6.13 - Comparação da resposta do modelo da equação 6.4 em relação aos dados experimentais.....	100
Figura 6.14 - Comparação entre dados experimentais e simulados pela equação 6.4.....	101
Figura 6.15 - Diagrama de bloco da malha 1 aberta representado pela equação gerada	

pelo ensaio da figura 6.1.....	102
Figura 6.16 - Resposta ao degrau da simulação do sistema mostrado na figura 6.15.....	102
Figura 6.17 - Diagrama de bloco da malha 1 fechada.....	104
Figura 6.18 - Resposta ao degrau do sistema mostrado pela figura 6.17.....	105
Figura 6.19 - Resposta da temperatura de base a perturbação degrau no valor desejado....	106
Figura 6.20 - Resposta da temperatura de topo a perturbação degrau no valor desejado....	106
Figura 6.21 - Resposta do ensaio de identificação em malha fechada com perturbação PRBS no valor desejado da temperatura de base.....	110
Figura 6.22 - Conjunto de dados selecionados para identificação da malha 1 fechada.....	111
Figura 6.23 - Comparação da resposta do modelo ARX em relação a resposta experimental da temperatura de base.....	112
Figura 6.24 - Comparação da resposta do modelo ARMAX em relação a resposta experimental da temperatura de base.....	113
Figura 6.25 - Comparação da resposta do modelo OE em relação a resposta experimental da temperatura de base.....	114
Figura 6.26 - Comparação da resposta do modelo BJ em relação a resposta experimental da temperatura de base.....	115
Figura 6.27 - Comparação da resposta da RNA em relação a resposta experimental da temperatura de base no ensaio de malha fechada.....	117
Figura 6.28 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 1 na configuração malha fechada.....	117
Figura 6.29 - Resposta do ensaio de identificação em malha fechada com perturbação PRBS no valor desejado da temperatura de topo.....	118
Figura 6.30 - Conjunto de dados selecionados para identificação da malha 2 fechada.....	119
Figura 6.31 - Comparação da resposta do modelo ARX em relação a resposta experimental da temperatura de topo.....	120
Figura 6.32 - Comparação da resposta do modelo ARMAX em relação a resposta experimental da temperatura de topo.....	121
Figura 6.33 - Comparação da resposta do modelo OE em relação a resposta experimental da temperatura de topo.....	122
Figura 6.34 - Comparação da resposta do modelo BJ em relação a resposta experimental da temperatura de topo.....	123
Figura 6.35 - Comparação da resposta da RNA em relação a resposta experimental da temperatura de topo.....	124

Figura 6.36 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 2 na configuração malha fechada.....	124
Figura 6.37 - Ensaio de identificação através do PRBS na malha 1 aberta.....	125
Figura 6.38 - Comparação entre dados experimentais e simulados pelo modelo ARX para malha 1.....	126
Figura 6.39 - Comparação entre dados experimentais e simulados pelo modelo ARMAX para malha 1.....	127
Figura 6.40 - Comparação entre dados experimentais e simulados pelo modelo OE para malha 1.....	128
Figura 6.41 - Comparação entre dados experimentais e simulados pelo modelo Box Jenkins para malha 1.....	129
Figura 6.42 - Comparação da resposta da RNA em relação a resposta experimental da temperatura de base no ensaio de malha aberta.....	130
Figura 6.43 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 1 na configuração malha aberta.....	131
Figura 6.44 - Ensaio de identificação através do PRBS na malha 2 aberta	131
Figura 6.45 - Comparação entre dados experimentais e simulados pelo modelo ARX para malha 2.....	132
Figura 6.46 - Comparação entre dados experimentais e simulados pelo modelo ARMAX para malha 2.....	133
Figura 6.47 - Comparação entre dados experimentais e simulados pelo modelo OE para malha 2.....	134
Figura 6.48 - Comparação entre dados experimentais e simulados pelo modelo Box Jenkins para malha 2.....	135
Figura 6.49 - Comparação da resposta da RNA em relação a resposta experimental da temperatura de topo no ensaio de malha aberta.....	136
Figura 6.50 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 2 na configuração malha aberta.....	137

LISTA DE TABELAS

Tabela 3.1 - Funções de ativação.....	52
Tabela 6.1 Regra de Cohen Coon para sintonia de controladores PID.....	103
Tabela 6.2 Regra de Ziegler-Nichols para sintonia de controladores PID.....	103
Tabela 6.3 Resultado das sintonias usando a regra de Cohen Coon para malha 1.....	103
Tabela 6.4 - Resultados das sintonias usando a regra de Ziegler-Nichols para malha 1....	104
Tabela 6.5 - Comparação dos erros dos modelos candidatos à identificação para malha 1 fechada.....	115
Tabela 6.6 - Comparação dos erros dos modelos candidatos a identificação para malha 2 fechada.....	123
Tabela 6.7 - Comparação dos erros dos modelos candidatos à identificação para malha 1 aberta.....	129
Tabela 6.8 Comparação dos erros dos modelos candidatos a identificação para malha 2 aberta.....	135

LISTA DE ABREVIATURAS E SIGLAS

ARMAX	Do inglês <i>AutoRegressive Moving Average with eXogenous inputs</i> ;
ARX	Do inglês <i>AutoRegressive with eXogenous inputs</i> , auto-regressivo com média móvel e entradas exógenas;
BJ	Box-Jenkins;
CLP	Controlador Lógico Programável;
DIB	<i>sinal binário de intervalo discreto</i> ;
FT	Função de Transferência;
HAB	<i>sinal binário de hall</i> ;
IPRBS	<i>sinal pseudo-aleatório com repetição inversa</i> ;
MLP	Multilayer Perceptrons (Rede feedforward de múltiplas camadas);
MLPRS	<i>sinal pseudo-aleatório quase-binário, sinal pseudo-aleatório multi-nível</i> ;
MPC	Do inglês <i>Model Predictive Control</i> , ou em português, Controladores Preditivos Baseados em Modelo;
OE	Do inglês <i>output error</i> ;
PI	Controlador Proporcional e Integral;
PID	Controlador Proporcional, Integral e Derivativo;
PRBS	<i>sinal binário pseudo-aleatório</i> ;
QRB	<i>sinal binário de resíduo quadrático</i> ;
QRT	<i>sinal ternário de resíduo quadrático</i> ;
RBB	<i>ruído branco binário</i> ;
RBF	Redes neurais com função de ativação de base radial;
RBG	<i>ruído branco Gaussiano</i> ;
RLC	Circuito elétrico Resistivo, Indutivo e Capacitivo;
RNA	Redes Neurais Artificiais;
SDCD	Sistema Digital de Controle Distribuído;
Set Point	Valor desejado;
SISO	Single Input and Single Output (Do português, simples entrada e simples saída);
SOH	<i>sinal multi-seno</i> ;
TPB	<i>sinal binário primo twin</i> ;

LISTA DE ABREVIATURAS E SIGLAS

- V_N : Função objetivo que deve ser minimizada para que seja encontrado o parâmetros dos modelos via processo de otimização;
- $\hat{y}(t)$: É a predição da saída do sistema dado pelo modelo;
- K_c : Ganho proporcional;
- N_s : Número de chaveamento do PRBS mínimo para que o tamanho da amostra de dados seja suficientemente informativo.
- N_u : Número de entradas;
- R^2 : Média do erro quadrático entre o modelo e o experimento
- T_s : Tempo de estabilização;
- T_{sw} : Tempo entre possíveis chaveamentos;
- b_k : É o bias;
- u_k : É a saída do combinador linear devido aos sinais de entrada;
- $w_{k1}, w_{k2}, \dots, w_{km}$: São os pesos sinápticos do neurônio k ;
- x_1, x_2, \dots, x_m : São os sinais de entrada;
- $x_{experimental}$: Dados experimentais;
- x_{modelo} : Dados gerados pelo modelo
- y_k : É o sinal de saída do neurônio;
- α_s : Razão de resposta entre malha aberta e malha fechada, este fator determina o conteúdo em alta frequência do sinal e é uma medida de quão rápida é a velocidade de resposta em malha fechada em relação à resposta em malha aberta.
- β_s : Fator de tempo de estabilização é o fator relacionado ao tempo de acomodação do processo e especifica quanta informação de baixa frequência estará presente no sinal.
- τ_d : Tempo derivativo;
- τ_{dom}^{ABERTA} : Constante de tempo dominante, estimativa em malha aberta;
- $\tau_{dom}^{FECHADA}$: Constante de tempo dominante, estimativa em malha fechada;
- τ_{dom}^H : Constante de tempo dominante, estimativa máxima;
- τ_{dom}^L : Constante de tempo dominante, estimativa mínima;
- τ_i : Tempo integrativo;

a/b: Sobrelevação, razão entre o valor que ultrapassa o valor de referência e o próprio valor de referência;

c/a: Razão de decaimento, razão entre os valores de picos sucessivos.

e(t): Erro de predição;

N: Número de amostragens dos dados;

P: Período de oscilação Intervalo de tempo entre dois picos consecutivos.

S: variável de Laplace;

tp: Tempo de pico, tempo em que a resposta alcança a maior sobrelevação;

tr: Tempo de Aproximação, tempo no qual a resposta alcança o valor de referência (set point) pela primeira vez;

ts: Tempo de acomodação, tempo no qual a resposta se aproxima do valor de referência com um desvio menor que 5%.

ζ: quociente de amortecimento

θ': Vetor de parâmetros do modelo;

φ(t): Vetor de regressores;

C: Capacitância elétrica;

H(s): Função de transferência de um sistema qualquer;

I(s): Corrente elétrica no domínio de Laplace;

K: É o ganho do sistema;

L: Indutância elétrica;

M: Amplitude do degrau,

R: Resistência elétrica;

T: Tempo total do experimento;

V(s): Tensão elétrica no domínio de Laplace;

Vc(s): Tensão elétrica no capacitor no domínio de Laplace;

X(s): É a variável de entrada do sistema;

Y(s): É a variável de saída do sistema;

dt: Diferencial do tempo;

dvc(t): Diferencial da tensão elétrica do capacitor no domínio do tempo;

f(a): É a função de ativação;

i(t): Corrente elétrica no domínio do tempo;

n: É a ordem de uma FT ou do PRBS;

na: É a ordem do polinômio $A(q)$;

nb : É a ordem do polinômio $B(q)$;

nk : É o tempo morto do sistema (no mínimo 1);

q : É o operador deslocamento para trás;

$u(k)$: É a variável de entrada do sistema;

$v(t)$: Tensão elétrica no domínio do tempo;

$vc(t)$: Tensão elétrica no capacitor no domínio do tempo;

$w(k)$: É um ruído branco;

$y(k)$: É a variável de saída do sistema;

θ : É o tempo morto do sistema.

τ : É a constante de tempo;

φ : É a função de ativação;

SUMÁRIO

1	INTRODUÇÃO.....	19
1.1	Objetivo do Trabalho.....	20
1.2	Justificativa do Trabalho.....	20
2	REVISÃO BIBLIOGRÁFICA.....	22
3	IDENTIFICAÇÃO DE SISTEMAS - FUNDAMENTAÇÃO TEÓRICA.....	27
3.1	Introdução a Identificação de Sistemas.....	27
3.2	Classificação de Modelos.....	28
3.3	Identificação de Sistemas Lineares.....	31
3.3.1	Representação de modelos lineares.....	32
3.3.1.1	Funções de transferência.....	32
3.3.1.1.1	Funções de transferência de primeira ordem.....	34
3.3.1.1.2	Funções de transferência de primeira ordem com tempo morto.....	36
3.3.1.1.3	Sistema Integrador.....	37
3.3.1.1.4	Funções de transferência de segunda ordem.....	38
3.3.1.2	Modelos discretos.....	40
3.3.1.2.1	Modelo ARX.....	41
3.3.1.2.2	Modelo ARMAX.....	42
3.3.1.2.3	Modelo OE.....	44
3.3.1.2.4	Modelo BJ.....	45
3.3.2	Ajuste de modelos.....	46
3.4	Identificação de Sistemas não Lineares.....	48
3.4.1	Modelos utilizando redes neurais artificiais (RNA).....	48
3.4.1.1	Introdução a redes neurais artificiais.....	49
3.4.1.2	Neurônio matemático.....	51
3.4.1.3	Função de ativação.....	52
3.4.1.4	Arquitetura da RNA.....	52
3.4.1.5	Treinamento das RNA's.....	58
3.4.1.6	Algoritmo de retropropagação (backpropagation).....	62
3.4.1.7	Modos de treinamento.....	63

3.4.1.8	Critérios de parada	63
3.5	Planejamento Experimental para Identificação de Sistemas	64
3.5.1	Configuração da malha para identificação.....	64
3.5.2	Tipos de abordagem.....	68
3.5.3	Sinais de excitação.....	69
3.5.3.1	Projeto do PRBS.....	72
3.5.3.2	Geração do PRBS.....	75
3.5.4	Determinação do tempo de amostragem.....	76
4	OBJETO EM ESTUDO.....	77
5	METODOLOGIA.....	82
5.1	Identificação em Malha Aberta com Perturbação Degrau.....	83
5.2	Identificação em Malha Fechada Através do PRBS.....	85
5.3	Identificação em Malha Aberta Através do PRBS.....	83
6	RESULTADOS E DISCUSSÕES.....	90
6.1	Identificação em Malha Aberta Através de Perturbação Degrau.....	90
6.2	Projeto do PRBS.....	105
6.3	Identificação em Malha Fechada com PRBS.....	110
6.4	Identificação em Malha Aberta com PRBS.....	125
7	CONCLUSÕES.....	138
	REFERÊNCIAS.....	142
	ANEXO - A.....	148

1 INTRODUÇÃO

Um dos grandes desafios na história da ciência tem sido obter modelos que representem bem os processos e fenômenos observados no universo. Por isso, há uma crescente mudança no tipo de modelos utilizados. Com o aumento da disponibilidade de computadores, o uso de modelos matemáticos tem aumentado em praticamente todas as áreas do conhecimento humano. Já os modelos fenomenológicos advindos de balanço de massa, energia e quantidade de movimento, apesar de utilizados na engenharia química, para gerar um bom modelo em alguns casos apresentam relativa complexidade para representar o sistema em tempo real. A identificação de sistemas é uma área que estuda técnicas alternativas para modelagem de processos e apresenta como característica principal a necessidade unicamente de dados experimentais da planta do processo. As técnicas para este tipo de modelagem são também referidas como “modelagem caixa preta” ou “modelagem empírica”. Os modelos resultantes fornecem apenas a relação entre as variáveis de entrada e saída do processo, não evidenciam os fenômenos envolvidos no processo. Obviamente pode ser feita também a identificação do sistema utilizando, quando disponível, um modelo fenomenológico validado para gerar os dados do processo. Vale salientar que, de uma forma ou de outra, o sistema identificado pode ser utilizado também no desenvolvimento de estratégias avançadas de controle.

Este trabalho foi desenvolvido utilizando a técnica de identificação de sistemas aplicada a Coluna de Destilação Metanol-Água responsável pela separação do metanol (produto de topo) da água (produto de base).

Na Coluna de Destilação Metanol-Água a concentração de metanol é controlada indiretamente pelas temperaturas de base e de topo. Isto implica dizer que é de interesse para este processo dispor de controles eficientes das temperaturas de base e de topo para manter a concentração dos produtos dentro das especificações.

Os modelos matemáticos candidatos a identificação foram auto-regressivo com entradas externas (ARX do inglês *AutoRegressive with eXogenous inputs*), auto-regressivo com média móvel e entradas exógenas (ARMAX do inglês *AutoRegressive Moving Average with eXogenous inputs*), modelo do tipo erro na saída (OE do inglês *Output Error*) e a estrutura que foi sugerida e tratada por Box e Jenkins em 1970 e é conhecida por seus nomes,

ou seja, Box-Jenkins (BJ). Além destes modelos lineares, foi utilizado outro modelo candidato a identificação, porém, com estrutura não linear, a Rede Neural Artificial (RNA).

Após este capítulo de introdução aborda-se a revisão bibliográfica com o propósito de verificar as pesquisas de temas envolvidos nesta dissertação. Em seguida, no capítulo 3, é apresentada a fundamentação teórica, que disponibiliza noções sobre identificação de sistemas, redes neurais artificiais e planejamento experimental. No capítulo 4 o objeto em estudo é apresentado para que o leitor possa ter conhecimento de algumas características relevantes da planta e dos equipamentos utilizados para realização dos ensaios para desenvolvimento desta dissertação. A metodologia utilizada para elaboração dos modelos de identificação é mostrado antes do capítulo de resultados e discussões e o fechamento das idéias é trazido no capítulo de conclusões.

1.1 Objetivo do Trabalho

Este trabalho tem por objetivo determinar quais dos modelos matemáticos, candidatos à identificação, melhor representa o processo da coluna de destilação metanol-água. Deseja-se também comparar qual configuração do processo no ensaio de identificação para geração de dados informativos apresenta mais vantagens para identificação da coluna de destilação metanol-água, se em malha aberta ou em malha fechada, nas condições e metodologias utilizadas. Comprovar a funcionalidade da utilização do sinal binário pseudoaleatório como uma boa opção de excitação na identificação em malha aberta e fechada para sistemas dinâmicos, é outro objetivo do presente trabalho.

1.2 Justificativa do Trabalho

Devido à complexidade dos processos industriais, prever as consequências de ações vem se tornando uma tarefa cada vez mais necessária. Os modelos matemáticos que descrevem o comportamento dinâmico de um processo industrial é uma ferramenta de bastante importância, pois permite através de simulação, prever tais consequências, encontrar pontos ótimos de operação e projetar controladores.

Desenvolver modelos fenomenológicos teoricamente seria a melhor opção se não fosse a dificuldade para elaborá-los em curto tempo e a necessidade de aproximar relações que não são conhecidas ou difíceis de serem obtidas.

A técnica de identificação é uma alternativa para elaboração de modelos empíricos cuja grande vantagem é o fato de que para elaborar o modelo não é necessário conhecer as leis que regem tal sistema, é necessário apenas ter informações de dados que representem causas e efeitos, o que torna esta metodologia mais rápida e prática quando comparada com a modelagem fenomenológica.

Uma das maiores preocupações da área de identificação, além da missão de obtenção do modelo empírico, é a redução dos investimentos associados ao ensaio de identificação para obtenção de dados, pois nos ensaios a planta é excitada de modo que a resposta a tal excitação pode em alguns casos retirar o produto de especificação ou até mesmo oferecer riscos operacionais. Em virtude destas preocupações, justifica-se o interesse em avaliar a influência da configuração da malha durante o ensaio.

O objetivo de qualquer sistema de controle é manter a variável controlada em valores desejados, admitindo apenas um desvio que seja tolerável e de preferência que o elemento final de controle tenha o mínimo possível de alterações para realização desta missão. O componente responsável por atender estas necessidades são os controladores, por isso, pesquisar ou testar sistemas de controle são de interesse das indústrias, pois quanto mais eficiente é um sistema de controle, melhor será a qualidade de seus produtos e menores serão seus desperdícios.

2 REVISÃO BIBLIOGRÁFICA

Nos anos 90, foram lançadas as bases da identificação de sistemas no controle de processos, embora o conceito básico tenha sido estabelecido nos anos 70. Desde então o problema de identificação passa a ser visto como uma tentativa de se achar um modelo com comportamento semelhante ao do sistema real e o desejo de obter modelos ideais vai sendo abandonado. O problema de identificação de sistemas é um caso particular da otimização, pois é a partir da minimização do erro entre os dados gerados pelo modelo e pelos experimentos que são encontrados os parâmetros dos modelos. Na identificação de sistemas os modelos obtidos são classificados como tipo caixa preta, ou seja, através do simples ajuste de parâmetros de equações com estrutura pré-definida, são replicados o comportamento dinâmico do sistema real sem a necessidade de enfatizar as leis que regem os fenômenos envolvidos no mesmo.

Desta maneira, a identificação passa a ser uma etapa do projeto de controladores em que as variáveis podem ser ajustadas para o fim no qual se deseja o modelo Gevers (2003). Este conceito é importante para trabalhos que buscam o projeto ótimo de experimentos, como Forsell e Ljung (2000) que reconhecem que o melhor projeto nunca será ótimo, porém pode chegar muito próximo. Hjalmarsson, Gevers e De Bruyne (1996) afirmam que uma melhoria do controlador, já instalado, pode ser conseguida através da reidentificação em malha fechada, num processo iterativo.

O teste degrau popularizado por Ziegler e Nichols em 1942, Smith e Corripio (2008), e Cohen Cohn em 1953 Seborg *et al.* (1989) foram os primeiros na área de sintonia de controladores Proporcionais, Integrais e Derivativos (PID) e contribui para metodologia de identificação e projeto de controladores.

Tipicamente, um projeto de Controladores Baseados em Modelo (MPC) terá cerca de 75% dos seus recursos gastos no trabalho de identificação, de acordo com Rivera *et al.* (2003). Este número poderá chegar a 90% em alguns casos, segundo Morari e Lee (1999). Mesmo com todo o esforço e custos empregados, se o procedimento não for adequado à situação, o modelo final pode resultar ineficaz para aplicação de MPC, como afirma Jia *et al.* (2003). Para Huang *et al.* (2000), mesmo que o modelo inicial seja bom, ele sofre degradação com o tempo. Isto pode ocorrer devido às alterações metrológicas sofridas pelo sistema, como

por exemplo, alterações nas dimensões de um determinado equipamento devido a desgaste ou oxidação.

Existem algumas polêmicas sobre a melhor forma de se obter modelos para uso em controladores. Talvez a primeira seja sobre a configuração da malha para o ensaio de identificação, ou seja, se as malhas de controle devem ser abertas ou permanecer fechadas no momento da identificação. Soderstrom, Ljung e Gustavsson (1976) já comprovam que, sob determinadas condições de identificabilidade, a identificação em malha fechada era possível. Zhu e Butoyi (2002) observam que testes em malha fechada permitem o aumento da amplitude dos sinais de entrada (excitação), pois, pela própria natureza da malha à retroalimentação dos controladores, que tende a corrigir as perturbações, mostra-se vantajoso em processos nos quais não são permitidos grandes desvios. Encontram-se alguns artigos sobre testes de identificação usando malha fechada em sistemas multivariáveis, como em Zhu (1998), no qual os resultados são bastante satisfatórios, e em Barreras e Garcia-Sanz (2003), em que os resultados são apenas razoáveis. Neste último artigo, no entanto, as condições de identificabilidade não foram inteiramente atendidas.

Outro problema é a escolha do método de abordagem. Os principais métodos de identificação utilizados para malha fechada são os seguintes de acordo com Miranda (2005): método direto, indireto e conjunto de entrada e saída. O método direto é o mais simples e mais recomendado na maioria dos casos. Variações destes métodos podem ser encontradas em Laksminarayanan *et al.* (2001) ou em Forsell e Ljung (1999), além de Ljung (1999).

As condições de identificabilidade estão bem claras em Ljung (1999) e Tsakalis (1996). Dentre as opções para garantir a identificabilidade de um sistema, é recomendável excitar o processo no valor de referência (ou valor desejado) da variável controlada.

Quando a questão passa a ser o projeto do experimento, a prática usual em testes de identificação em unidades industriais é de perturbar a planta nas variáveis manipuladas para configuração malha aberta. Segundo Zhu e Butoyi (2002), é interessante perturbar o valor desejado das controladas.

O tipo de sinal também tem despertado interesse para elaboração de inúmeros trabalhos. Godfrey *et al.* (2003) apresentam várias opções de sinais de excitação facilmente

disponíveis para uso prático, juntamente com alguns critérios a serem considerados na escolha do sinal.

Alguns pesquisadores, como Aström e Nilsson (1994), Zang *et al.* (1995), Van den Hof e Schrama (1995) e Hjalmarsson *et al.* (1996), começaram a focar no desenvolvimento de procedimentos de identificação com o objetivo de estimar modelos mais simples para serem utilizados no projeto de controladores de alto desempenho.

Em Gevers (1993), foram destacadas as condições experimentais de identificação de modelos para o controle. As condições de experimentos devem ser tão próximas quanto possível das condições nas quais o controlador projetado será aplicado ao sistema real. Devido a esta conclusão, Hjalmarsson *et al.* (1996) observaram que, para a maioria dos objetivos de controle, a identificação deve ser realizada em malha fechada. Isto reativou o interesse por métodos de identificação em malha fechada.

Talvez, de forma intuitiva, surgem os procedimentos de identificação iterativos nos quais controladores são projetados através de modelos e modelos são reajustados pela atualização do controlador. Esta alternância de etapas se repete até que o modelo e o controlador estejam o mais próximo de seus pontos ótimos. Van den Hof e Schrama (1995) mencionam que os procedimentos de identificação iterativos foram rapidamente empregados em aplicações industriais, visando projetar controladores de desempenho superior aos existentes e modelos que simulam de forma mais verdadeira a dinâmica dos processos.

Da mesma forma que o objetivo deste trabalho, Zhu e Butoyi (2002) apresentam comparação entre os resultados de identificação em malha fechada e aberta aplicados em sistema de destilação. O artigo de Silva *et al.* (2006) apresenta uma técnica de identificação em malha fechada baseada na resposta ao degrau de um dado sistema, cuja vantagem é a de poder ser empregada no domínio do tempo.

Tavares Neto (2010), em sua tese de doutorado, apresenta uma contribuição diferenciada na área de identificação de sistemas, pois propõe uma nova metodologia para o projeto de sinais Sinal Binário Pseudo Aleatório (PRBS) incluindo a influência da variável de entrada no processo de modelagem pela técnica de identificação de sistemas. Os métodos convencionais não consideram a dinâmica da variável de entrada no projeto do PRBS. Foram desenvolvidos por Tavares Neto (2010) dois estudos de casos com a finalidade de avaliar e

comparar a metodologia atualmente disponível na literatura com a metodologia proposta, nos quais observou que o sinal aplicado através da metodologia proposta foi capaz de gerar dados que levaram a um modelo mais representativo do sistema estudado.

Cheung *et al.* (1992) usando dados de planta modelaram uma coluna fracionadora de uma refinaria utilizando redes neurais artificiais e posteriormente compararam estes modelos com modelos levantados usando técnicas estatísticas convencionais.

Margaglio, Uria e Rodríguez (1995) fizeram comparações de modelos tipo ARX e modelos tipo redes neurais aplicados a colunas de destilação de três componentes.

Assaf *et al.* (1996) utilizaram redes para modelar a campanha de um reator de oxidação de eteno.

Nascimento e Guidici (1998) aplicaram otimização em processos modelados com redes neurais.

Existem também estudos de redes neurais aplicados a analisadores virtuais, a controles multivariáveis lineares, a controle inferencial e a controle adaptativo. Bulsari (1993) aplicou redes neurais num controlador multivariável linear.

Fileti e Pereira (1997) propuseram controladores preditivos usando redes neurais.

Em Zuben (1993) observa-se que a evolução das redes neurais artificiais passou por várias etapas, sendo uma época iniciada por um período de grande atividade, seguido por anos de estagnação nas pesquisas para, logo a seguir, permitir um momento de ressurgimento do interesse científico como consequência do desenvolvimento de novas tecnologias e fundamentos teóricos.

Segundo Huamaní (2003), a primeira tentativa de construir um modelo conexionista foi na década de 40 por W. S. McCulloch e W. Pitts, cujo trabalho fazia uma analogia entre células vivas e o processamento eletrônico, simulando o comportamento do neurônio natural, em que o neurônio possuía apenas uma saída, dada por uma função (*threshold*) da soma ponderada das suas diversas entradas.

Henrique *et al.* (2000) propuseram uma metodologia para determinar a estrutura de modelo em redes neurais *feedforward*.

Vieira *et al.* (2005) propõem soluções de implementação de redes neurais para identificação e controle do processo de craqueamento catalítico. Esta pesquisa surgiu mediante a necessidade de melhorias neste processo, que é bastante complexo e lucrativo no seguimento das indústrias petroquímicas.

3 IDENTIFICAÇÃO DE SISTEMAS - FUNDAMENTAÇÃO TEÓRICA

Identificação de sistemas é um ramo da ciência que estuda técnicas para obtenção de modelos matemáticos que representem comportamentos dinâmicos através de dados experimentais, ou seja, é a ciência que estuda a obtenção de modelos empíricos.

3.1 Introdução a Identificação de Sistemas

Segundo Monteiro (2002), um sistema pode ser definido como “um conjunto de objetos agrupados por alguma interação ou interdependência, de modo que existam relações de causa e efeito nos fenômenos que ocorrem com os elementos deste conjunto.”

Em Ogata (2000) define-se um sistema como “uma combinação de componentes que atuam em conjunto e cumprem certo objetivo. Um sistema não é limitado apenas a algo físico. O conceito de sistemas pode ser aplicado a fenômenos abstratos, dinâmicos, como os encontrados em Economia”.

Para estudos quantitativos de sistemas, como os feitos na engenharia, é necessário que estes sistemas sejam representados por modelos matemáticos adequados aos objetivos pretendidos. Fala-se em modelo adequado, pois é praticamente impossível obter um modelo matemático ideal que represente um sistema de forma exata. Filho (2003), em sua dissertação de mestrado, afirma que um modelo que represente todas as características de um sistema de forma exata seria tão complexo, que seria mais fácil lidar com o próprio sistema e ignorar o modelo.

Visto que não há um único modelo capaz de representar um sistema em todas suas dimensões, utilizam-se modelos aproximados, sendo a aproximação boa ou não, de acordo com a aplicação prevista para este modelo.

Coelho (2004) cita alguns usos possíveis para os modelos obtidos, são eles:

- **Previsão:** São tentativas de “prever” o comportamento futuro do sistema com base no seu estado atual e na entrada do sistema.
- **Análise e projeto de sistemas de controle:** Os modelos são, nesse caso, utilizados para a síntese de controladores usando as ferramentas da Teoria de Controle. Em geral,

os modelos utilizados para projeto de sistemas de controle não são de grande complexidade.

- **Supervisão:** Utilizados para a detecção de erros de medição e diagnósticos do processo, através de comparação entre a dinâmica esperada (saída do modelo validado) com o comportamento do sistema real.
- **Otimização:** Usados como ferramenta de tomada de decisão, visando à maximização/minimização de alguma variável. Para o propósito de otimização, exigem-se modelos matemáticos precisos.
- **Treinamento:** Utilizados para treinamento de operadores. Como exemplo desta categoria de modelos pode-se citar os simuladores de voo, que são baseados em modelos matemáticos do sistema real (um avião).
- **Soft Sensor:** modelo matemático que utiliza como entrada valores das variáveis de fácil medição para estimar valores de variável de difícil e/ou onerosa medição.

3.2 Classificação de Modelos

Os modelos podem ser classificados em três grandes categorias, a depender do conhecimento que se tem do sistema: através de uma modelagem fenomenológica, através de uma modelagem empírica ou através da junção entre modelagem fenomenológica e empírica.

A modelagem fenomenológica é derivada das equações que regem um dado fenômeno, sendo também conhecida por modelagem pela natureza do processo, conceitual ou ainda modelagem caixa branca. Nesse tipo de modelagem, faz-se necessário conhecer a fundo o sistema em análise e as equações que o regem, o que nem sempre é possível ou viável. Nestes casos é comum para sistemas industriais a necessidade de elaborar o balanço de massa, de energia e quantidade de movimento, o qual recai normalmente em problemas de equações diferenciais ordinárias e/ou parciais de difícil manipulação.

A modelagem empírica, também conhecida por modelagem (ou identificação) caixa preta, requer pouco conhecimento do funcionamento interno do sistema, baseando a análise somente no estudo dos dados provenientes de observações do sistema, ou seja, as relações entre causa e efeito. Tais características fazem da área de identificação caixa preta uma solução viável para determinar modelos em tempos reais em aplicações industriais. Modelos que utilizam redes neurais artificial e modelos neuro-fuzzy fazem parte desta classe.

Já na modelagem fenomenológica e empírica, são originados os modelos caixa cinza ou híbrido, nos quais parte do modelo será fenomenológico e o restante empírico.

O processo pode ser representado por diversas abordagens matemáticas que irá depender da sua finalidade, sendo assim, a seguir são mencionadas algumas classificações de modelos de acordo com a nomenclatura comumente usada na Teoria de Sistemas Dinâmicos Aguirre (2007).

- **Modelos estáticos ou dinâmicos:** Modelos dinâmicos são aqueles nos quais o estado de um sistema num dado instante de tempo depende do estado do sistema em instantes anteriores. Tais modelos são normalmente descritos por equações diferenciais. Já modelos estáticos (ou instantâneos) são aqueles em que, para calcular o estado do sistema num dado instante de tempo, o estado do sistema em instantes anteriores não é relevante. Em outras palavras, modelos estáticos não têm memória, sendo normalmente representados por equações algébricas. Na prática, os sistemas reais são todos dinâmicos, mas, para uma dada análise, a dinâmica do sistema pode ser desprezível por ser muito rápida ou muito lenta comparada com a escala de tempo utilizada.
- **Modelos contínuo ou discreto:** Um modelo é contínuo quando pode-se encontrar o valor de uma dada variável do sistema em qualquer instante de tempo t pertencente ao conjunto de números reais positivos. A temperatura de uma sala, por exemplo, pode ser representada por um modelo de tempo contínuo, já que para qualquer instante de tempo pode-se encontrar um valor de temperatura correspondente. O preço de fechamento de uma ação na bolsa de valores é bem representado num modelo a tempo discreto, visto que este dado só é obtido uma vez por dia, no final do pregão. Sistemas amostrados também são bem representados por modelos a tempo discreto, sendo este tipo de sistema muito utilizado na Identificação de Sistemas.
- **Modelos lineares ou não lineares:** Formalmente um modelo é dito linear se ele satisfaz o princípio da superposição. Para entender esse princípio, considere um sistema que ao ser excitado pela entrada $u_1(t)$ produz uma saída $y_1(t)$ e quando excitado por $u_2(t)$ produz $y_2(t)$. Se tal sistema satisfaz o princípio da superposição, então quando excitado por $a.u_1(t) + b.u_2(t)$, sua saída será $a.y_1(t) + b.y_2(t)$, sendo a e b variáveis possivelmente complexas. Caso contrário é chamado de não linear. De forma prática, um modelo é dito linear se as variáveis que o definem não

aparecem na equação sob a forma de funções não lineares ou pode-se dizer também que são aqueles que têm o mesmo tipo de comportamento independente do ponto de operação. A consideração de linearidade normalmente simplifica bastante o modelo a ser desenvolvido.

- **Modelos causais ou antecipativos:** Um modelo é dito causal (ou não antecipativo) quando a saída do sistema no instante t não depende das entradas aplicadas ao sistema após o instante de tempo t . Um modelo é dito antecipativo (ou não causal) quando a saída do sistema no instante t depende do valor da entrada após o instante de tempo t . Ainda que seja possível representar matematicamente um modelo antecipativo, nenhum sistema físico tem esta característica. Portanto, os modelos estudados serão sempre causais.
- **Modelos Autônomos ou não Autônomos:** Modelos que não contém sinais de entrada dependendo explicitamente do tempo são chamados de autônomos. As entradas do modelo são frequentemente chamadas de entradas exógenas, pois exógena significa que é algo determinado fora do sistema considerado.
- **Modelos Monovariáveis ou Multivariáveis:** São chamados de monovariáveis os modelos que representam a relação entre uma entrada e uma saída. Na literatura são conhecidos também por modelos SISO (*single input single output*). Caso haja mais de uma entrada ou mais de uma saída os modelos passam a ser chamados de multivariáveis. Dentre estes, é comum classificá-los em: MISO (*multiple input single output*) quando há várias entradas e somente uma saída; SIMO (*single input multiple output*) para o caso em que há uma única entrada e mais de uma saída; e finalmente MIMO (*multiple input multiple output*) quando há várias entradas e várias saídas. Deve ser notado que o uso de modelos monovariáveis não implica em que o sistema real tenha apenas uma entrada e uma saída. De fato, a maioria dos sistemas reais tem várias entradas e saídas, muitas delas possivelmente desconhecidas.
- **Modelos Determinísticos ou Estocásticos:** Um modelo será determinístico se ele trabalha com uma relação exata entre as variáveis em análise e se expressa sem incertezas. Por outro lado, um modelo é estocástico se ele contém conceitos de incerteza e probabilidade. Desta forma, a saída de um modelo estocástico é uma variável aleatória. Em outras palavras, um modelo é estocástico se sua saída no instante t não pode ser exatamente determinada a partir de dados referentes ao passado. Na prática, sempre teremos algum grau de contaminação dos dados por ruído

ou incerteza na medição, de forma que os modelos estocásticos são mais adequados à identificação de sistemas.

- **Modelos paramétricos e não paramétricos:** A distinção entre esses dois tipos de modelos não é totalmente universal. Na maioria dos casos, serão denominados paramétricos aqueles modelos que tiverem parâmetros, ou seja, números, coeficientes que os caracterizem. Por outro lado, modelos não paramétricos serão apresentações gráficas, (que não tem parâmetros) tais como a resposta ao impulso e a resposta em frequência.

Uma prática muito utilizada ao realizar identificação de sistemas dinâmicos é primeiramente tentar representá-lo através de modelos lineares, devido a este fato, serão revisadas algumas possíveis representações de modelos lineares.

3.3 Identificação de Sistemas Lineares

Ter um modelo fenomenológico é de grande valia para o trabalho de qualquer profissional envolvido com o processo, pois suas extrapolações para pontos de operação normalmente não utilizados são muito mais confiáveis do que modelos empíricos. Entretanto, um modelo desse tipo tem um custo elevado para ser desenvolvido e ajustado. Por exemplo, em sistemas de polimerização o número de equações e constantes cinéticas é da ordem de centenas. O ajuste de todas as constantes do modelo é um trabalho muito árduo. Muitas vezes as indústrias interessadas em modelar seus processos não dispõem de recursos para desenvolver um modelo desse tipo. Além do que, muitas vezes não têm a necessidade de todas as informações que um modelo completo pode oferecer.

Do ponto de vista de controle precisa-se apenas conhecer os ganhos e as dinâmicas dominantes do processo para poder realizar um bom projeto de controle. Para obter essas informações podem ser utilizados modelos mais simples, ajustados a partir de dados dinâmicos, coletados diretamente do processo em interesse. Esse procedimento, como já foi dito, é chamado de identificação. Tais modelos identificados podem ser representados de várias maneiras.

3.3.1 Representação de Modelos Lineares

Há diversas maneiras de representar um mesmo modelo matemático, ou seja, há várias formas em que as equações que descrevem o comportamento do sistema podem ser descritas. Será chamada de representações a forma em que um modelo matemático é expresso.

Segundo Aguirre (2007), uma das representações mais importantes na modelagem de sistemas dinâmicos lineares é a função de transferência (FT).


3.3.1.1 Funções de transferência

Funções de transferência são funções que modelam o comportamento dinâmico de um par entrada-saída de um sistema, ou seja, descrevem como uma determinada entrada é dinamicamente “transferida” para a saída do sistema. Estas funções são muito utilizadas na modelagem de controle de processos.

A função de transferência de um sistema é, por definição, a transformada de Laplace da sua resposta ao impulso. A função de transferência de um sistema pode ser obtida dividindo-se a transformada de Laplace da saída pela da entrada. Assim, funções de transferência são normalmente representadas como a razão de dois polinômios no domínio dos números complexos “s”. Vale enfatizar que funções de transferência no domínio de Laplace são baseadas no conceito de variável desvio. Esse desvio é dado em relação a um estado estacionário qualquer em relação a um estado dinâmico, de forma que se possa utilizar a função de transferência ao redor de qualquer ponto operacional particular que se queira analisar o problema físico.

Para exemplificar a aplicação de FT será realizada a modelagem fenomenológica de um circuito elétrico resistivo, indutivo e capacitivo (RLC) conforme Figura 3.1, no qual se deseja obter a função de transferência entre tensão de alimentação $v(t)$ e a corrente no circuito $i(t)$, ou seja, deseja-se obter $H(s) = I(s)/V(s)$.

Figura 3.1 - Circuito RLC, (Resistivo, indutivo e capacitivo)



As equações que descrevem o circuito mostrado na Figura 3.1 são as seguintes:

$$v(t) = L \cdot \frac{di(t)}{dt} + R \cdot i(t) + v_c(t) \quad (3.1)$$

$$i(t) = C \cdot \frac{dv_c(t)}{dt} \quad (3.2)$$

Aplicando-se a transformada de Laplace nas equações 3.1 e 3.2 tem-se, respectivamente,

$$V(s) = L \cdot I(s) \cdot s + R \cdot I(s) + V_c(s) \quad (3.3)$$

$$I(s) = C \cdot V_c(s) \cdot s \quad (3.4)$$

Da equação 3.4, tem-se $V_c(s) = I/(C \cdot s)$. Substituindo-se esse resultado na equação 3.3, teremos,

$$\frac{I(s)}{V(s)} = \frac{C \cdot s}{C \cdot L \cdot s^2 + R \cdot C \cdot s + 1} \quad (3.5)$$

As funções de transferências podem também ser obtidas diretamente a partir de dados produzidos pelo sistema usando-se métodos de identificação.

Considere a seguinte função de transferência:

$$H(s) = \frac{Y(s)}{X(s)} = \frac{b_0 + b_1.s + \dots + b_q.s^q}{a_0 + a_1.s + \dots + a_n.s^n} = \frac{I(s)}{V(s)} = \frac{C.s}{C.L.s^2 + R.C.s + 1} \quad (3.6)$$

Os zeros de $H(s)$ são valores de $s = z_1, z_2, \dots, z_q$, para os quais o polinômio $Y(s)$ é nulo, em outras palavras, são as raízes de $Y(s)$.

Os polos de $H(s)$ são valores de $s = p_1, p_2, \dots, p_n$, para os quais o polinômio $X(s)$ é nulo, em outras palavras, são as raízes de $X(s)$.

A ordem de uma FT é dada pelo número de polos, ou seja, igual a n .

A multiplicidade de um polo ou zero é igual ao número de vezes que tal singularidade aparece repetida na FT. Por exemplo, se $z_2 = z_3 = z_4 = -2$, então a multiplicidade do zero em $s = -2$ é igual a três.

Por motivos de exatidão numérica, modelos de sistemas reais normalmente não possuem polos com multiplicidade maior que um. Uma exceção talvez sejam os polos na origem.

3.3.1.1.1 Funções de transferência de primeira ordem

A função de transferência de primeira ordem representa grande parte dos fenômenos reais e, por outra parte, podemos aproximar o comportamento de vários sistemas reais por uma função de transferência de primeira ordem. De modo que é importante conhecer bem as características dinâmicas de sistemas de baixa ordem, uma vez que sistemas mais complexos podem, normalmente, ser decompostos em tais componentes mais simples.

Considere a função de transferência de primeira ordem.

$$H(s) = \frac{Y(s)}{X(s)} = \frac{K}{\tau.s + 1} \quad (3.7)$$

onde:

K é o ganho;

τ é a constante de tempo;

$Y(s)$ é a saída;

$X(s)$ é a entrada;

$H(s)$ é a função de transferência.

A constante de tempo τ caracteriza a velocidade com que o sistema responde a certa entrada, para ser mais específico, τ é o tempo necessário para que um sistema de primeira ordem atinja 63,21% da variação total após ser excitado por uma perturbação degrau.

Quando se pretende aproximar à dinâmica de um sistema real a função de transferência de primeira ordem através de técnicas de identificação, é necessário excitar a entrada do sistema com um sinal conhecido para, através da coleta de dados de saída, tornar possível encontrar os parâmetros do modelo. Nestes casos é comum utilizar perturbação degrau, cuja representação no domínio de Laplace é mostrada na equação 3.8.

$$X(s) = \frac{M}{s} \quad (3.8)$$

Aplicando a equação 3.8 na equação 3.7 teremos:

$$Y(s) = \frac{K}{\tau.s+1} \cdot X(s) \quad (3.9)$$

Logo para uma perturbação degrau na entrada $X(s)$ com amplitude M , teremos a seguinte resposta da variável de saída $Y(s)$:


$$Y(s) = \frac{K}{(\tau.s+1)} \cdot \frac{M}{s} \quad (3.10)$$

Aplicando a Transformada Inversa de Laplace iremos obter a saída $Y(s)$ no domínio do tempo:

$$y(t) = K.M.(1 - e^{-t/\tau}) \quad (3.11)$$

A Figura 3.2 mostra a resposta ao degrau unitário da função de transferência de $H(s) = 1/\tau \cdot s + 1$ para $\tau = 2, 4, 6, 8$ e 10 s. Observe como a constante de tempo τ determina a velocidade de resposta do sistema. Quanto maior for a constante de tempo mais lenta será a resposta dinâmica a uma perturbação degrau na entrada.

Figura 3.2 - Resposta ao degrau de sistemas de primeira ordem.



Fonte: AGUIRRE, 2007

3.3.1.1.2 Funções de transferência de primeira ordem com tempo morto

Muitos sistemas dinâmicos reais apresentam um atraso puro de tempo, conhecido também como tempo morto. A modelagem matemática desse fenômeno é de suma importância, pois atrasos de tempo têm efeito desestabilizador em malhas de controle.

Quando se pretende utilizar funções de transferência de primeira ordem para projetar controladores Proporcional, Integral e Derivativo (PID) através das técnicas de Ziegler-Nichols e Cohen Coon, é necessário que os modelos considerem a influência do tempo morto do sistema, pois estes métodos de sintonia (ou projeto) de controladores só podem ser utilizados caso o tempo morto seja maior que zero.

Um sistema de primeira ordem com tempo morto é representado da forma:

$$H(s) = \frac{Y(s)}{X(s)} = \frac{K}{\tau \cdot s + 1} \cdot e^{-\theta \cdot s} \quad (3.12)$$

onde:

θ é o tempo morto do sistema.

Logo, para uma perturbação degrau na entrada $X(s)$ com amplitude M , teremos a seguinte resposta da variável de saída $Y(s)$:

$$Y(s) = \frac{K}{(\tau \cdot s + 1)} \cdot e^{-\theta \cdot s} \cdot \frac{M}{s} \quad (3.13)$$

Aplicando a Transformada Inversa de Laplace iremos obter a saída $Y(s)$ no domínio do tempo:

$$y(t) = K \cdot M \cdot (1 - e^{-(t-\theta)/\tau}) \quad (3.14)$$

3.3.1.1.3 Sistema Integrador

Alguns sistemas reais apresentam respostas continuamente crescentes quando submetidos a uma perturbação degrau, isto é, não alcançam um novo estado estacionário. Um bom exemplo deste tipo de sistema é nível de tanques controlados através da vazão de entrada, cuja saída do fluido é forçada por uma bomba, e não por gravidade. Neste exemplo, uma perturbação degrau positiva, poderia fazer com a vazão de entrada fosse maior que a vazão de saída, com isto, o nível do tanque aumentaria continuamente.

Para a modelagem desses sistemas existem duas formas de modelos que podem ser adequados.

O modelo mostrado na equação 3.15 representa bem um sistema puramente integrador, no qual o ganho K pode ser obtido a partir da resposta ao degrau.

$$H(s) = \frac{K}{s} \quad (3.15)$$

Para sistemas que apresentam comportamento integrador, mas que a presença de tempo morto é observada, é possível aproximar o sistema pelo modelo mostrado pela equação 3.16. Semelhantemente ao caso anterior, os parâmetros podem ser obtidos a partir dos testes em degrau.

$$H(s) = \frac{Y(s)}{X(s)} = \frac{K}{s \cdot (\tau \cdot s + 1)} \cdot e^{-\theta \cdot s} \quad (3.16)$$

Logo, para uma perturbação degrau na entrada $X(s)$ com amplitude M , teremos a seguinte resposta da variável de saída $Y(s)$:

$$Y(s) = \frac{K}{s \cdot (\tau \cdot s + 1)} \cdot e^{-\theta \cdot s} \cdot \frac{M}{s} \quad (3.17)$$

Cuja resposta no domínio do tempo será:

$$y(t) = K \cdot M \cdot (1 - \theta - \tau(1 - e^{-(t-\theta)/\tau})) \quad (3.18)$$

3.3.1.1.4 Funções de transferência de segunda ordem

Os sistemas de segunda ordem podem ser entendidos como dois sistemas de primeira ordem em série. Também se pode entender que um sistema de segunda ordem é aquele descrito por uma equação diferencial de segunda ordem.

Tais processos podem ser expressos matematicamente através da equação 3.19:

$$H(s) = \frac{K_1}{(\tau_1 \cdot s + 1)} \cdot \frac{K_2}{(\tau_2 \cdot s + 1)} \quad (3.19)$$

onde:

K_1 e K_2 são respectivamente os ganhos dos processos 1 e 2;

τ_1 e τ_2 são respectivamente as constantes de tempo dos processos 1 e 2.

É usual simplificar a representação de um sistema de segunda ordem como indicado pela equação 3.20:

$$H(s) = \frac{Y(s)}{X(s)} = \frac{K_1.K_2}{(\tau_1.s+1).(\tau_2.s+1)} = \frac{K}{(\tau_1.s+1).(\tau_2.s+1)} \quad (3.20)$$

Ou ainda na forma padrão como descrito na equação 3.21:

$$H(s) = \frac{Y(s)}{X(s)} = \frac{K}{(\tau_1.s+1).(\tau_2.s+1)} = \frac{K}{(\tau^2.s^2+2.\zeta.\tau.s+1)} \quad (3.21)$$

onde:

$$K = K_1.K_2 \quad (3.22)$$

$$\tau^2 = \tau_1.\tau_2 \quad (3.23)$$

$$\tau = \sqrt{\tau_1.\tau_2} \quad (3.24)$$

$$\zeta = \frac{\tau_1+\tau_2}{2.\sqrt{\tau_1.\tau_2}} \quad (3.25)$$

Sendo que o quociente de amortecimento ζ , a constante de tempo τ e o ganho K são os parâmetros que determinam as características dinâmicas do sistema.

A resposta transitória de um sistema de segunda ordem subamortecido pode ser caracterizado pelos seguintes parâmetros:

- Tempo de Aproximação (t_r): tempo no qual a resposta alcança o valor de referência (*set point*) pela primeira vez.
- Tempo de pico (t_p): tempo em que a resposta alcança a maior sobrelevação.
- Sobrelevação (a/b): razão entre o valor que ultrapassa o valor de referência e o próprio valor de referência.
- Razão de decaimento (c/a): razão entre os valores de picos sucessivos.

- Tempo de acomodação (t_s): tempo no qual a resposta se aproxima do valor de referência com um desvio menor que 5%.
- Período de oscilação (P): Intervalo de tempo entre dois picos consecutivos.

Algumas considerações são relevantes para um sistema de segunda ordem:

- Semelhantemente aos sistemas de primeira ordem, K e τ tem o mesmo significado, sendo, portanto o ganho do sistema e a constante de tempo do sistema, respectivamente.
- O novo parâmetro ζ (*Zeta*) é adimensional e mede a quantidade de dumping do sistema, isto é, o grau de oscilação da resposta do processo após uma perturbação.
- Pequenos valores de ζ implicam em grandes oscilações da saída do processo.

3.3.1.2 Modelos discretos

De acordo com Aguirre (2007), modelos discretos são representações matemáticas especialmente adequadas à identificação de sistemas, cujos parâmetros são estimados através de algoritmos conhecidos.

Com o advento dos sistemas de controle digitais houve um grande desenvolvimento de técnicas de identificação de modelos discretos uma vez que os dados nesses sistemas apresentam-se na forma de amostragens periódicas.

Um sistema linear de tempo discreto pode ser representado sob a forma geral:

$$A(q) \cdot y(k) = \frac{B(q)}{F(q)} \cdot u(k) + \frac{C(q)}{D(q)} \cdot w(k) \quad (3.26)$$

onde:

$u(k)$ é a entrada do sistema, $y(k)$ é a saída do sistema e $w(k)$ é um ruído branco. q é o operador deslocamento para trás, e pode ser expresso pela equação 3.27:

$$q^n \cdot y(t) = y(t - n) \quad (3.27)$$

Os polinômios $A(q)$, $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são definidos a seguir:

$$A(q) = 1 + a_1 \cdot q^{-1} + \dots + a_{ny} \cdot q^{-ny} \quad (3.28)$$

$$B(q) = b_0 + b_1 \cdot q^{-1} + \dots + b_{nu} \cdot q^{-nu} \quad (3.29)$$

$$C(q) = 1 + c_1 \cdot q^{-1} + \dots + a_{nw} \cdot q^{-nw} \quad (3.30)$$

$$D(q) = 1 + d_1 \cdot q^{-1} + \dots + a_{nd} \cdot q^{-nd} \quad (3.31)$$

$$F(q) = 1 + f_1 \cdot q^{-1} + \dots + a_{nf} \cdot q^{-nf} \quad (3.32)$$

Existem algumas estruturas básicas de modelos discretos utilizados na identificação de modelos dinâmicos. Veremos a seguir as principais delas.

3.3.1.2.1 Modelo ARX

O modelo autorregressivo com entradas externas (ARX) pode ser obtido a partir do modelo geral da equação 3.26, tornando-se $C(q) = D(q) = F(q) = 1$ sendo $A(q)$ e $B(q)$ polinômios arbitrários. Essa é a estrutura mais comum e também a mais usada na identificação de modelos discretos. Ela supõe que os dados de saídas do sistema a ser identificados são corrompidos apenas por um ruído branco. Um ruído branco é um sinal que possui a mesma magnitude para todas as frequências.

A forma da estrutura ARX é a seguinte:

$$y(t) + a_1 \cdot y(t - 1) + \dots + a_{na} \cdot y(t - na) = b_1 \cdot u(t - nk) + \dots + b_{nb} \cdot u(t - nk - nb + 1) + w(t) \quad (3.33)$$

ou

$$A(q) \cdot y(t) = B(q) \cdot u(t) + w(t) \quad (3.34)$$

onde:

na = ordem do polinômio $A(q)$

nb = ordem do polinômio $B(q)$

nk = tempo morto do sistema (no mínimo 1)

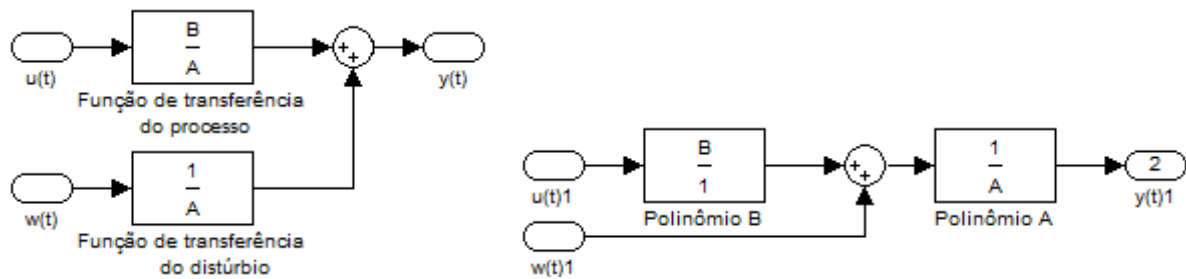
q = operador deslocamento para trás.

A equação 3.34 pode ser reescrita da seguinte forma:

$$y(t) = \frac{B(q)}{A(q)} \cdot u(t) + \frac{1}{A(q)} \cdot w(t) \quad (3.35)$$

Desta forma ficam evidenciadas as funções de transferência do processo $\frac{B(q)}{A(q)}$ e do distúrbio $\frac{1}{A(q)}$, essa estrutura pode ser representada pelo diagrama de blocos mostrado na Figura 3.3:

Figura 3.3: Modelo ARX em diagrama de blocos em duas configurações.



Fonte: Autor, 2012.

A estrutura ARX é útil quando o sistema a ser modelado apresenta pouco distúrbio externo ou esse distúrbio é composto em sua maioria por ruído branco, normalmente originado de ruídos de instrumentos.

3.3.1.2.2 Modelo ARMAX

O modelo autorregressivo com média móvel e entradas exógenas (ARMAX) pode ser obtido a partir do modelo geral da equação 3.26, tornando-se $D(q) = F(q) = 1$ e $A(q)$, $B(q)$ e $C(q)$ polinômios arbitrários.

O principal problema da identificação de modelos lineares é a presença de distúrbios não medidos nos dados de saída. Para contornar essa dificuldade existem algumas estruturas de modelos que tentam compensar esses distúrbios criando um modelo para o distúrbio cuja entrada é um sinal tipo ruído branco. A maneira mais simples de se fazer isso é dizer que o distúrbio não medido é uma média móvel ponderada de um sinal tipo ruído branco $w(t)$.

Essa estrutura pode ser representada pela seguinte expressão:

$$y(t) + a_1 \cdot y(t - 1) + \dots + a_{na} \cdot y(t - na) = b_1 \cdot u(t - nk) + \dots + b_{nb} \cdot u(t - nk - nb + 1) + w(t) + C_1 \cdot w(t - 1) + C_{cn} \cdot w(t - nc) \quad (3.36)$$

ou

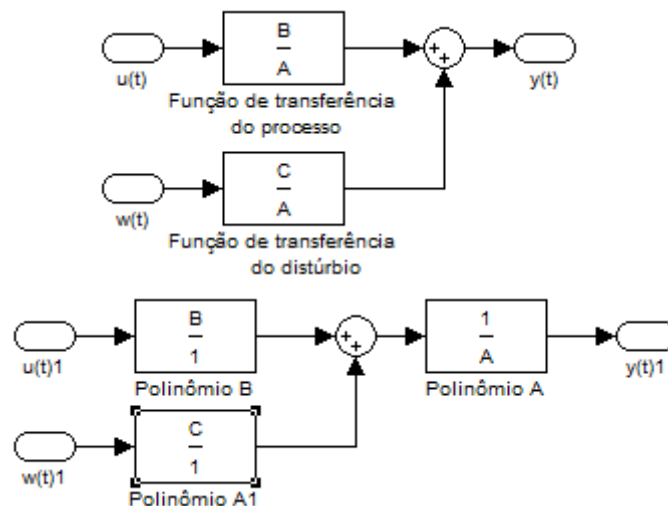
$$A(q) \cdot y(t) = B(q) \cdot u(t) + C(q) \cdot w(t) \quad (3.37)$$

A equação 3.37 pode ser reescrita da seguinte forma:

$$y(t) = \frac{B(q)}{A(q)} \cdot u(t) + \frac{C(q)}{A(q)} \cdot w(t) \quad (3.38)$$

Desta forma ficam evidenciadas as funções de transferência do processo $\frac{B(q)}{A(q)}$ e do distúrbio $\frac{C(q)}{A(q)}$. Essa estrutura pode ser representada pelo diagrama de blocos mostrado na Figura 3.4:

Figura 3.4 - Modelo ARMAX em diagrama de blocos em duas configurações.



Fonte: Autor, 2011.

Observando essa estrutura vemos que a dinâmica do modelo de distúrbio (denominador A) é a mesma dinâmica do modelo principal. Isso significa que essa estrutura considera os distúrbios não medidos como sendo distúrbios na carga do processo, o que em

muitos casos é o que acontece em processos reais. As estruturas ARX e ARMAX fazem parte de uma família de estruturas conhecida como erro na equação. A principal característica dessa família é que o modelo principal e o modelo do distúrbio estão correlacionados pelo polinômio A. Do ponto de vista físico é mais interessante modelar esses dois termos de forma independente. Existe outra família de estruturas que contempla essa ideia. Essa família é conhecida como erro na saída.

3.3.1.2.3 Modelo OE

Modelo do tipo erro na saída (OE) pode ser obtido a partir do modelo geral da equação 3.26, tornando-se $A(q) = C(q) = E(q) = 1$ e $B(q)$ e $F(q)$ polinômios arbitrários.

Essa estrutura considera, de forma similar a ARX, que os dados de saída são corrompidos apenas por um sinal tipo ruído branco. A diferença é que o ruído branco é somado diretamente na saída sem passar antes por um filtro. A estrutura OE pode ser representada pela seguinte expressão:


$$z(t) + f_1 \cdot z(t - 1) + \dots + f_v \cdot z(t - v) = b_1 \cdot u(t - 1) + \dots + b_m \cdot u(t - m) \quad (3.39)$$

$$y(t) = z(t) + w(t) \quad (3.40)$$

$$y(t) = \frac{B(q)}{F(q)} \cdot u(t) + w(t) \quad (3.41)$$

Que pode ser representado pelo diagrama de blocos mostrado na Figura 3.5:

Figura 3.5 - Modelo OE em diagrama de blocos.



Fonte: Autor, 2011.

3.3.1.2.4 Modelo BJ

Modelo de Box-Jenkins (BJ) pode ser obtido a partir do modelo geral da equação 3.26, tornando-se $A(q) = 1$ e $B(q)$, $C(q)$, $D(q)$ e $F(q)$ polinômios arbitrários.

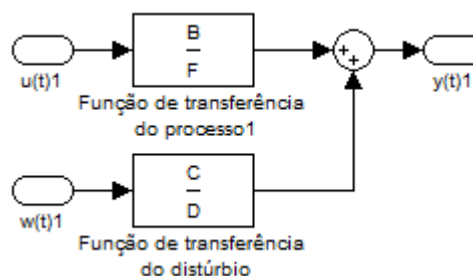
Um desenvolvimento natural da estrutura OE é a modelagem do erro de predição. Isso pode ser feito introduzindo um termo tipo ARMA, autorregressão e média móvel, para modelar o erro de predição $e(t)$ em função de um sinal tipo ruído branco $w(t)$. Fazendo isso temos a seguinte estrutura de modelos.

$$y(t) = \frac{B(q)}{F(q)} \cdot u(t) + \frac{C(q)}{D(q)} \cdot w(t) \quad (3.42)$$

Como no caso dos modelos de erro na saída, nos modelos Box-Jenkins as funções de transferência do sistema $\frac{B(q)}{F(q)}$ e do ruído $\frac{C(q)}{D(q)}$ não têm parâmetros comuns, ou seja, são independentemente parametrizadas.

Essa estrutura é a mais natural do ponto de vista físico, uma vez que os modelos do processo e do distúrbio são parametrizados de forma independente. Essa estrutura foi sugerida e tratada por Box e Jenkins em 1970 e é conhecida por seus nomes, ou seja, Box-Jenkins (BJ). Essa estrutura pode ser representada na forma de diagrama de blocos como apresentado na Figura 3.6:

Figura 3.6: Modelo BJ em diagrama de blocos.



Fonte: Autor, 2011.

3.3.2 Ajuste de modelos

Uma das etapas do processo de identificação de modelos é a escolha da estrutura do modelo a ser identificado, conforme foi mencionado na seção anterior. Outra etapa é o ajuste dos parâmetros dessa estrutura de forma que a saída do modelo reproduza da melhor maneira as saídas do sistema real. Normalmente o critério utilizado para ajuste desses modelos é o quadrado do erro de predição, ou seja, a função objetivo do processo de identificação tem a seguinte forma genérica.

$$V_N(\theta', \varphi(t)) = \frac{1}{2 \cdot N} \sum_{t=1}^N e^2(\theta', \varphi(t)) \quad (3.43)$$

onde:

θ' = vetor de parâmetros do modelo;

$\varphi(t)$ = vetor de regressores;

N = número de amostragens dos dados;

e = erro de predição dados por:

$$e(t) = \hat{y}(t) - y(t) \quad (3.44)$$

onde:

$\hat{y}(t)$ é a predição da saída do sistema dado pelo modelo.

Vamos analisar primeiramente a estrutura ARX. Neste caso a predição do modelo, sem influência de distúrbios, é dada por:

$$\hat{y}(t) = -a_1 \cdot y(t-1) - \dots - a_{na} \cdot y(t-na) + b_1 \cdot u(t-1) + \dots + b_{nb} \cdot u(t-nb) \quad (3.45)$$

Nesse caso o vetor de parâmetros e o vetor de regressores são dados respectivamente por:

$$\theta' = [a_1 \ a_2 \ \dots \ a_n \ b_1 \ \dots \ b_m]^T \quad (3.46)$$

$$\varphi(t) = [-y(t-1) \ \dots \ -y(t-n) \ u(t-1) \ \dots \ u(t-1)] \quad (3.47)$$

Podemos reescrever a equação de predição utilizando esses vetores da seguinte forma:

$$\hat{y}(t) = \hat{\theta}' \cdot \varphi(t)^T \quad (3.48)$$

A estrutura ARX caracteriza-se por ser uma regressão linear. Dessa forma o erro de predição é dado por:

$$e(t) = y(t) - \hat{\theta}' \cdot \varphi(t)^T \quad (3.49)$$

Inserindo-se essa na função objetivo, temos:

$$V_N(\theta', \varphi(t)) = \frac{1}{2 \cdot N} \cdot [y(t) - \hat{\theta}' \cdot \varphi(t)^T]^T \cdot [y(t) - \hat{\theta}' \cdot \varphi(t)^T] \quad (3.50)$$

Derivando a equação 3.50 temos:

$$\frac{dV_N(\theta', \varphi(t))}{d\hat{\theta}} = \varphi(t)^T \cdot y(t) - \varphi(t)^T \cdot \varphi(t) \cdot \hat{\theta}' \quad (3.51)$$

Igualando a equação 3.51 a zero temos a solução para o vetor de parâmetros que é dada por:

$$\hat{\theta}' = [\varphi(t)^T \cdot \varphi(t)]^{-1} \cdot \varphi(t)^T \cdot y(t) \quad (3.52)$$

A grande vantagem do método dos mínimos quadrados aplicado para regressão linear é que sua função é quadrática e, portanto, possui solução analítica. No caso das demais estruturas, pelo fato do erro de predição entrar na própria predição, essas deixam de ser regressores lineares obrigando o ajuste dos parâmetros do modelo ser feito através de um processo de busca iterativa. Não foram abordadas essas técnicas neste trabalho, pois foram utilizadas as funções de ajuste já prontas no software MATLAB.

3.4 Identificação de Sistemas não Lineares

Uma identificação é dita não linear quando são representadas por modelos não lineares. Apesar da maioria dos processos industriais apresentarem comportamento não linear, é comum tentar aproximar este comportamento por modelos lineares, porém quando esta aproximação não é suficiente, faz-se necessário a utilização de modelos não lineares.

Um modelo é não linear se ele não satisfaz o princípio da superposição. Também é certo afirmar que um modelo é não linear se as variáveis que o definem aparecem na equação sob a forma de funções não lineares.

Um modelo com representação não linear que está sendo bastante utilizado, e vem apresentando resultados muito satisfatórios na área de identificação de processos industriais, são as redes neurais artificiais.

3.4.1 Modelos utilizando redes neurais artificiais

Por várias décadas cientistas têm buscado entender e modelar a estrutura do cérebro, acreditando que o processo de aprendizagem humana pode ser reproduzido por um algoritmo equivalente. Assim, surgiram diversas propostas baseadas no conhecimento biológico.

A Inteligência Artificial é o ramo da ciência que estuda possibilidades de replicar a inteligência humana em computadores ou sistemas micro processados através de algoritmos matemáticos. Uma das características dos sistemas inteligentes é a capacidade de aprender, de adaptar-se a um ambiente desconhecido ou a uma situação nova, como verifica Bauchspiess (2004).

Em 1956 surgiram os dois paradigmas da Inteligência Artificial: a simbólica e a conexionista. A simbólica procura simular o comportamento inteligente humano, desconsiderando os mecanismos responsáveis por ele. A conexionista acredita que, construindo-se um sistema que simule a estrutura do cérebro, este sistema apresentará inteligência, ou seja, será capaz de aprender, assimilar, errar e aprender com seus erros.

Algoritmo Genético, Fuzzy e Redes Neurais Artificiais (RNA) são exemplos de sistemas inteligentes. Estes sistemas se enquadram na categoria de modelos empíricos, uma vez que, são encontrados a partir do conhecimento de dados dos processos. Neste trabalho será utilizado apenas a RNA para representar o sistema.

3.4.1.1 Introdução a redes neurais artificiais

Uma das grandes vantagens desta abordagem é a possibilidade de treinamento das RNA's a partir dos dados obtidos do processo, de modo que é desnecessário conhecer as leis envolvidas para que se obtenha o modelo, pois as RNA's simplesmente "aprendem" (BAUCHSPIESS, 2004), ou seja, criam uma relação entre entrada e saída a partir destes dados.

Do ponto de vista do controle de processos industriais, a principal característica das RNA's é a capacidade de aproximar comportamentos não lineares extremamente complexos. Bhat *et al.* (1990) e Billings *et al.* (1992) demonstram que essa habilidade pode ser incorporada em algoritmos de controle e Doherty (1999) apresenta aplicações bem sucedidas de redes neurais em diferentes estratégias de controle. Maiores detalhes sobre esta representação e aplicações podem ser encontradas em Braga *et al.* (2000), Haykin (2001) e Amaral (2001).


As ideias iniciais dos estudos de redes neurais surgiram com os trabalhos de MacCulloch e Pitts (1943), em que sugeriram a construção de uma máquina baseada ou inspirada no cérebro humano. Hebb (1949) traduziu matematicamente a sinapse dos neurônios biológicos. Minski (1951) construiu o primeiro neurocomputador com capacidade de aprendizado, ou seja, que ajustava automaticamente os pesos entre as sinapses.

Nos últimos anos, o campo de aplicação das RNA's tem-se expandido notavelmente em engenharia (RAFIQ *et al.*, 2001), em ciências biológicas (CAI *et al.*, 2000 e CAI e ZHOU, 2000), em economia (TIMMERMAN, 1997; PEAT, 1996), em computação (FÉRAUD e CLÉROT, 2002), em medicina (BAXT, 1990 e 1991), sobressaindo-se em aplicações como classificação de padrões, aproximação de funções e previsão de séries temporais (BALLINI, 2000), entre outros setores. As RNA's também têm sido usadas com muito sucesso em controle de processos, modelagem, simulação e identificação de sistemas (ALDRICH e SLATER, 2001).

Em relação aos paradigmas surgidos em 1956, mencionados anteriormente, as RNA's fazem parte do grupo de sistemas conexionistas, pois são inspirados no sistema nervoso biológico, que consiste num grande número de células nervosas ou neurônios funcionando paralelamente. O sistema nervoso humano obtém informações do meio ambiente através de

sensores que são combinados com informações armazenadas para produzir as ações do corpo. Apenas uma pequena parte das informações obtidas é relevante para o funcionamento do corpo (BAUCHSPIESS, 2004). A Figura 3.7 mostra um esquema representando o funcionamento do sistema nervoso.


Figura 3.7: Funcionamento do sistema nervoso



Fonte: BAUCHSPIESS, 2004.

No neurônio biológico, as informações são recebidas pelo neurônio através dos dendritos, que são terminações nervosas. Em seguida estas informações são processadas pelo corpo celular que transmite o resultado do processamento através do axônio e ramificações. As conexões entre neurônios são efetuadas pelas sinapses, que são pontos de contato entre dendritos e axônios controlados por impulsos elétricos e reações químicas. A Figura 3.8 sugere uma representação do neurônio biológico por diagrama de bloco.

Figura 3.8: Analogia entre um neurônio biológico e matemático.




Fonte: GONZAGA, 2003, p. 53.

O neurônio matemático é uma representação deste sistema, como demonstrado em Haykin (2003). Uma RNA é constituída por grande número de elementos computacionais primitivos (neurônio matemático) arranjados em uma estrutura paralela. Estes elementos são conectados por sinapses artificiais, caracterizadas por uma matriz de pesos ou valores numéricos que podem ser ajustados por um processo de aprendizagem.

3.4.1.2 Neurônio matemático

Essencialmente, uma rede neural é uma rede de elementos primitivos de processamento (também chamados nós computacionais ou neurônios), como mostrados na Figura 3.9:

Figura 3.9: Modelo de neurônio.



Fonte: HAYKYN, 2001.

O conjunto de sinapses caracterizadas por pesos w_{kj} pondera os sinais x_j na entrada da sinapse j conectada ao neurônio k . Os sinais ponderados são somados e entram na função de ativação para que esta seja aplicada para gerar a saída.

O modelo apresentado na Figura 3.9 tem também um *bias*, aplicado externamente b_k , que tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação (HAYKIN, 2001).

Matematicamente, pode-se descrever um neurônio k através das seguintes equações:

$$u_k = \sum_{j=1}^m w_{kj} \cdot x_j \quad (3.53)$$

$$y_k = \varphi(u_k + b_k) \quad (3.54)$$

Onde x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada; b_k é o *bias*; φ é a função de ativação e y_k é o sinal de saída do neurônio.

A forma da função de transferência (ou ativação), que define o sinal de saída do neurônio, pode ser linear, degrau ou sigmoidal, entre outras.

3.4.1.3 Função de ativação

A saída de cada neurônio é obtida passando-se a sua atividade para uma função de ativação (ou função de transferência) responsável pela projeção do corrente estado de ativação num sinal de saída. Contudo, a princípio não existe um critério bem definido para a escolha de tais funções, sendo as mais empregadas mostradas na Tabela 3.1:

Tabela 3.1 - Funções de ativação

NOME	FÓRMULA
Sigmoidal	$\varphi = f(a) = 1/(1 + \exp(-a))$
Tangente hiperbólica	$\varphi = f(a) = \tanh(a)$
Gaussianana	$\varphi = f(a) = \exp(-a^2)$
Linear	$\varphi = f(x) = a$


Fonte: Autor, 2011.

3.4.1.4 Arquitetura da RNA

O modo como os neurônios são conectados e suas estruturas determinam a arquitetura da RNA (VIEIRA *et al.*, 2005). Segundo Haykyn (2001), as arquiteturas comuns de RNA são:

- *Feedforward* de camada única: Nesta rede uma camada de entrada se projeta sobre uma camada de saída (o termo “camada única” refere-se à camada de saída). A Figura 3.10 representa esta estrutura.


Figura 3.10 - Rede feedforward de camada única



Fonte: HAYKYN, 2001.

- *Feedforward* de múltiplas camadas. Esta RNA tem uma camada de entrada, uma de saída e uma ou mais camadas escondidas.

Figura 3.11 - Estrutura genérica de uma *feedforward* com uma camada oculta.



Fonte: ALDRICH ; SLATER, 2001.

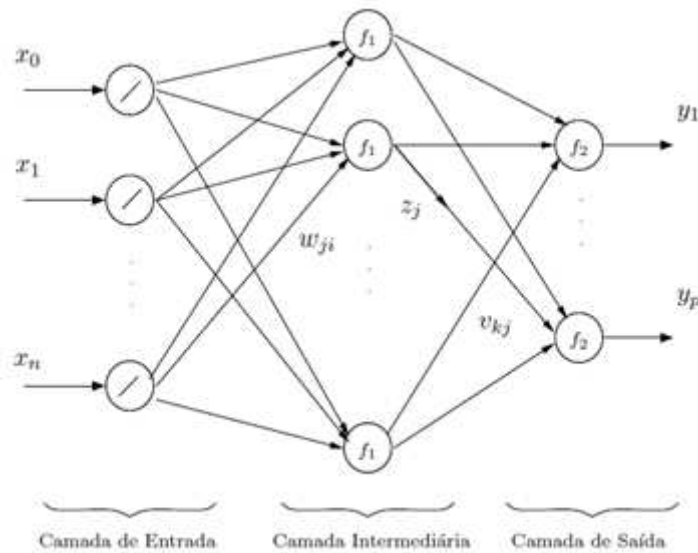
Duas subclassificações de estruturas de redes *Feedforward* de múltiplas camadas bastante popularizadas são do inglês *Multilayer Perceptrons* (MLP) e Redes Neurais com Funções de Ativação de Base Radial (RBF).

As MLP's têm uma camada de entrada, uma ou várias camadas intermediárias e uma camada de saída. Os neurônios da camada de entrada são os responsáveis pela transmissão do sinal de entrada para a camada intermediária e, geralmente, possuem uma função de ativação

linear. As camadas intermediárias transmitem informações entre a camada de entrada e a camada de saída. As saídas dos neurônios intermediários são processadas pelos neurônios das camadas de saída, fornecendo sinais de saída correspondentes.

A Figura 3.12 mostra a arquitetura de uma rede MLP com uma camada intermediária e entradas de polarização, onde $x=[x_0, x_1, \dots, x_n]'$; $y=[y_0, y_1, \dots, y_p]'$; w_{ji} e v_{kj} são os pesos das camadas intermediárias e de saída, respectivamente, para $i = 0, \dots, n$; $j = 0, \dots, M$; $k = 1, \dots, p$; sendo M o número de neurônios da camada intermediária.

Figura 3.12 - Rede MLP com uma camada intermediária.



Fonte: HUAMANÍ, 2003.

Considerando uma entrada fixa denominada de polarização na rede MLP e funções de ativação lineares na camada de entrada, define-se a saída z_j do j – ésimo neurônio da camada intermediária como:

$$z_j = f_1\left(\sum_{i=0}^n w_{ji} \cdot x_i\right) \quad (3.55)$$

onde:

$x_0 = +1$ e f_1 é a função de ativação na camada intermediária. A k – ésima saída da rede y_k é calculada como:

$$y_k = f_2\left(\sum_{j=0}^M v_{kj} \cdot z_j\right) \quad (3.56)$$

sendo:

$z_0=1$ e f_2 a função de ativação dos neurônios da camada de saída da rede.

Já as redes neurais com funções de ativação de base radial (RBF) são modelos com uma camada intermediária, cujos neurônios na camada de saída formam uma combinação linear das funções de base computadas pelos neurônios da camada intermediária. As funções de ativação dos neurônios da camada intermediária são as funções de base (SCARSELLI e TSOI, 1998), sendo a mais difundida e utilizada a função Gaussiana.

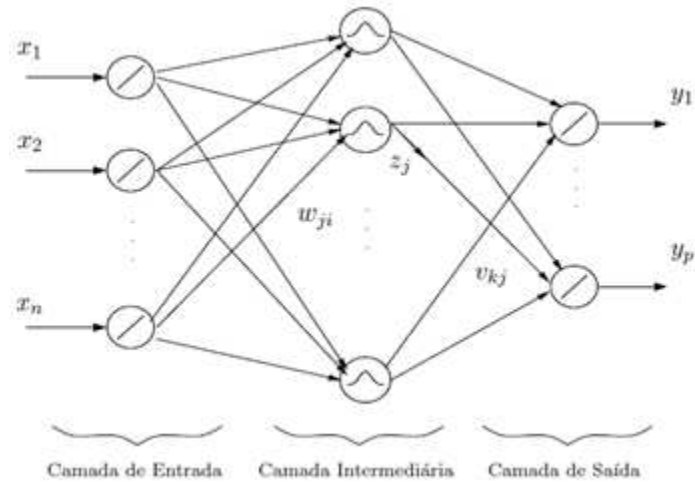
Deste modo, utilizando funções de base Gaussianas, cada neurônio da camada intermediária produz uma saída idêntica para entradas que se encontram a uma mesma distância do centro da função base correspondente ao neurônio (HUSH e HORNE, 1993). É por este motivo que estas funções são denominadas de *base radial*. A Figura 3.13 mostra uma rede RBF.

Assim, a saída z_j do neurônio j da camada intermediária com funções de base Gaussianas é definida como:

$$z_j = \exp\left(-\frac{\sum_{i=1}^n (x_i \cdot w_{ji})^2}{2\sigma_j^2}\right) \quad (3.57)$$

Para $j = 1, \dots, M$, sendo o número de neurônios da camada intermediária, n o número de entradas da rede, w_{ji} os pesos da camada de entrada que, ao mesmo tempo, fazem o papel de centros das funções de ativação Gaussianas na camada intermediária e σ_j são os parâmetros de dispersão.

Figura 3.13 - Rede com função de ativação de base radial



Fonte: HUAMANÍ, 2003.

Finalmente, a saída y_k desta rede é dada por:

$$y_k = \sum_{j=1}^M v_{kj} \cdot z_j \quad (3.58)$$


onde:

v_{kj} são os pesos da camada de saída, com $k = 1, \dots, p$, sendo p o número de saídas da rede. Deste modo, a rede RBF executa um mapeamento não linear através de uma combinação linear de funções de base não lineares.

As redes MLP utilizam a função base sigmoideal como funções de ativação. A principal diferença entre uma rede MLP com funções de ativação sigmoideais e uma rede RBF com funções de ativação Gaussianas é a natureza das próprias funções de ativação. Enquanto os neurônios intermediários de uma rede MLP com funções de ativação sigmoideais cobre uma ampla região do espaço de entrada, os neurônios intermediários da rede RBF cobrem pequenas regiões específicas. Desta forma, as redes MLP são mais eficientes que as redes RBF para certas aplicações, como é o caso no problema de aproximação de funções. Já para a resolução de problemas de classificação de padrões, as redes RBF resultam ser mais eficientes que as redes MLP. Tal fato é observado por Hush e Horne (1993).

- Recorrente. Distingue-se de uma rede *feedforward* por ter, pelo menos, um laço de realimentação. A presença de laços de realimentação tem um impacto profundo na capacidade de aprendizagem da rede e em seu desempenho. A Figura 3.14 representa uma RNA recorrente.

Figura 3.14 - Rede recorrente com neurônios ocultos



Fonte: HAYKYN, 2001.

Usualmente as camadas são classificadas em três grupos, independentemente do tipo da arquitetura da RNA:

- **Camada de entrada:** onde os padrões são apresentados à rede;
- **Camadas intermediárias ou escondidas:** onde é feita a maior parte do processamento, através das conexões ponderadas. Podem ser consideradas como extratoras de características;
- **Camada de saída:** onde o resultado final é concluído e apresentado.

A estrutura multicamada é a mais conhecida e utilizada, de acordo com Hush e Horne (1993), devido à propriedade de aproximação universal e de generalização para uma ampla classe de problemas, utilizando um mesmo algoritmo de aprendizado (IYODA, 2000). Além do mais, Quantrille e Liu (1991) sugerem em seu trabalho que as conexões intercadas são

particularmente importantes em aplicações de engenharia. Já Cybenko (1989) vai mais adiante e sugere que no máximo duas camadas intermediárias seriam necessárias para a maioria dos problemas de engenharia, tendo em vista o menor esforço computacional exigido. Ele também afirma que este tipo de rede pode aproximar de uma forma compacta qualquer tipo de função contínua.

3.4.1.5 Treinamento das RNA's

A topologia da RNA juntamente com as funções de ativação são os fatores que determinam a exatidão e o grau de representação do comportamento do sistema estudado. Contudo, para a utilização das RNA's os fatores ponderais e a ativação residual (ou bias) devem ser determinados por algum mecanismo de treinamento, ajustando-se estes parâmetros até que a resposta calculada, baseada nos dados de entrada, alcance a relação causa-efeito desejada. Esta tarefa consiste basicamente numa otimização não linear.

Segundo Haykin (1994), aprendizado ou treinamento de redes neurais é o processo pelo qual os parâmetros livres ou adaptáveis da rede são ajustados via um processo contínuo de simulação do ambiente no qual a rede é inserida. Este processo pode ser classificado dentro de três grandes grupos:

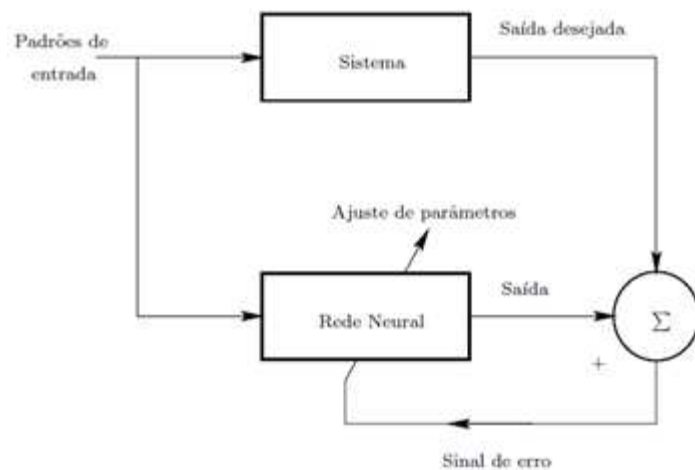
- Treinamento supervisionado
- Treinamento não supervisionado
- Treinamento por reforço

O treinamento supervisionado caracteriza-se pela disponibilidade de conhecimento ou informação sobre um sistema na forma de padrões entrada-saída (HAYKYN, 1994). Estes padrões formam o conjunto de treinamento. Para cada entrada é gerada uma saída da rede neural que é comparada com a saída correspondente do conjunto de treinamento. Os parâmetros da rede são ajustados tendo como base o sinal de erro e os padrões de treinamento. O sinal de erro é definido como a diferença entre a saída da rede e a saída desejada do conjunto de treinamento. Estes ajustes são feitos de forma iterativa que prossegue até que o erro seja pequeno o suficiente. O mecanismo de treinamento supervisionado é ilustrado na Figura 3.15.

Aplicando um algoritmo de treinamento supervisionado, uma rede neural adquire conhecimento ou informação relevante sobre um problema a ser resolvido de forma análoga àquela utilizada pelo ser humano e outros animais, ou seja, a partir de exemplos, como apresenta Von Zuben (1993).

Uma desvantagem deste tipo de treinamento consiste no fato de que a rede neural não pode aprender novas estratégias para situações particulares que não foram consideradas na escolha do conjunto de treinamento.

Figura 3.15 - Treinamento supervisionado.



Fonte: HUAMANÍ, 2003.

Em Nerrand *et al.* (1994) treinamento não adaptativo é definido como sendo o processo pelo qual a rede neural é treinada, inicialmente, utilizando um conjunto finito de padrões entrada-saída e logo utilizada mantendo os parâmetros fixos. O treinamento adaptativo refere-se ao processo de treinamento pelo qual a rede é treinada de forma permanente enquanto está sendo utilizada (conjunto infinito de padrões de treinamento).

Denomina-se como treinamento *off-line* o treinamento supervisionado não adaptativo e treinamento supervisionado adaptativo o treinamento *on-line*.

Um algoritmo de treinamento supervisionado altamente popular é baseado no método do gradiente, comumente denominado algoritmo de retropropagação, proposto pela primeira vez por P. J. Werbos (1974) e redescoberto e popularizado por Rumelhart e McClelland

(1986). O nome de retropropagação deve-se ao fato do sinal de erro ser retropropagado camada por camada através da rede. O método supervisionado de retropropagação é um dos mais utilizados na literatura (WABER e MISRA, 1996).

No treinamento não supervisionado ou auto organizado não existe um elemento externo que inspecione o processo, ou seja, não existe um conjunto específico de padrões a serem aprendidos pela rede neural, mas sim uma medida da qualidade de representação que a rede requer para o aprendizado. O modo de treinamento não supervisionado está representado pela Figura 3.16. Os parâmetros da rede neural são ajustados em função desta medida. Uma vez que a rede consegue extrair algumas características dos dados de entrada esta será capaz de gerar representações internas para classificar as características.

Métodos de treinamento não supervisionados e aplicações são propostos em Kohonen *et al.* (2000) e Kohonen (1982).

Figura 3.16 - Treinamento não supervisionado.



Fonte: HUAMANÍ, 2003.

Os métodos não supervisionados são também utilizados numa primeira etapa de treinamento das redes RBF. Como outro exemplo de métodos de treinamento não supervisionado tem-se os distintos métodos de clusterização que, neste caso, são utilizados para definir os cenários das funções de ativação sigmóides dos neurônios da camada intermediária de uma rede RBF (HUSH e HORNE, 1993). Diversos algoritmos de clusterização encontram-se detalhados em Lin e Lee (1996).

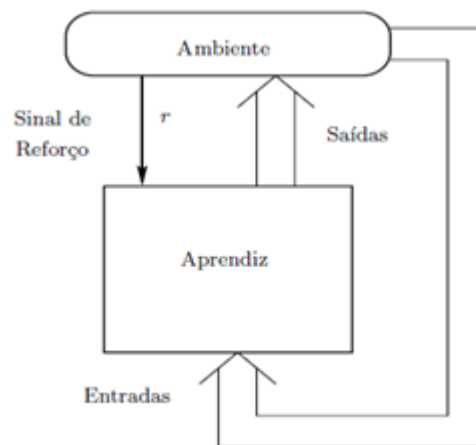
O treinamento por reforço é um problema discreto e dinâmico, segundo Jouffe (1998), no qual um sistema de aprendizagem ou agente deve aprender um comportamento desejado através de tentativas, admitindo-se acertos e erros durante a interação com um determinado ambiente (ONAT *et al.*, 1998 e KAELBING *et al.*, 1996).

O treinamento por reforço é um método de treinamento do tipo “avaliador” e não do tipo “instrutor”, como no caso dos métodos supervisionados. No treinamento por reforço, a informação disponível para o treinamento geralmente é pobre e grossa, o sinal de avaliação é um escalar e no caso extremo, existe uma única informação para indicar se a saída da rede esta certa ou errada (LIN e LEE, 1996).

Segundo Haykin (1994), o aprendizado por reforço pode ser não associativo ou associativo. No treinamento por reforço não associativo, o sistema de aprendizagem escolhe uma determinada ação ao invés de associar diferentes ações com diferentes estímulos, ou seja, o sinal de reforço é a única entrada que o sistema recebe do ambiente. No treinamento por reforço associativo, um mapeamento ou associação ações-estímulos é produzido, de forma a maximizar um valor que caracterize o desempenho do sistema de aprendizagem ou o sinal de reforço. Dado que o aprendiz não sabe *a priori* a ação que deve ser tomada, este deve descobrir quais são as ações que produzem uma maior recompensa.

No modelo básico de aprendizado ou treinamento por reforço, o sistema de aprendizagem comunica-se com o ambiente via ações (saídas do sistema) e percepções (entradas ao sistema e o sinal de reforço), como mostra a Figura 3.17:

Figura 3.17 - Modelo básico de treinamento por reforço.



Fonte: HUAMANÍ, 2003.

Em cada iteração, o sistema de aprendizagem recebe como entrada algum sinal indicando o estado atual do ambiente. A seguir, o sistema escolhe a ação a ser tomada, gerando assim a saída a ser avaliada. Esta ação gera uma mudança no estado do ambiente e a

transição de estado é comunicada ao aprendiz via sinal de reforço r através de um processo interativo de recompensa e punição, o sistema escolhe a ação que acrescente o valor do sinal de reforço com o passar do tempo.

Existem várias diferenças entre o treinamento supervisionado e o treinamento por reforço, sendo que a mais importante é a ausência de padrões de treinamento. Assim que o aprendiz escolhe a ação ser tomada, é informado do sinal de reforço (recompensa ou punição) e do estado atual do ambiente e não é informado em momento algum sobre a ação ótima para os respectivos interesses, é necessário para o aprendiz reunir experiência sobre o ambiente, estados, ações ou punições para, a partir de um certo momento, tomar a decisão correta (KAELBING *et al.*, 1996).

3.4.1.6 Algoritmo de retropropagação (*backpropagation*)

A mais simples técnica de otimização para o treinamento de uma RNA, com conexões intercamadas, usa o Jacobiano de uma função objetivo para determinar a direção de busca. A soma dos quadrados dos erros entre os valores reais e aqueles preditos pela RNA é normalmente usada como função objetivo.

Um termo chamado taxa de aprendizagem que influencia a taxa de ajuste dos fatores ponderais (ou pesos) é usado como a base para retropropagar o erro ao longo da RNA conforme a técnica do gradiente descendente, buscando conduzir a função objetivo a um mínimo. Esta técnica foi então chamada de Retropropagação (ou *Backpropagation*). Para utilizá-la, inicializam-se todos os pesos da RNA com valores randômicos, estes valores são utilizados para que um vetor de entrada seja propagado através da rede e forneça a predição do vetor de saída. Nesta etapa são determinadas todas as saídas dos neurônios da rede. Com o vetor de saída predito pela RNA, calcula-se a soma do erro quadrático total. Em seguida, os termos de declínio das diversas camadas são calculados, conhecendo-se os termos de declínio e as saídas de cada neurônio da RNA, os pesos são ajustados, então, repetem-se as etapas para todos os vetores de entrada/saída utilizados no treinamento, até que o erro quadrático total alcance o critério de convergência desejado.

Quando a função objetivo aproxima-se de um mínimo local, o algoritmo pode não conseguir distingui-lo de um mínimo global e considerá-lo como o ponto ótimo. Nesses casos é necessário reiniciar o treinamento, ou seja, executar o algoritmo por outro ponto de partida.

Existem muitos tipos de algoritmos específicos para estimação de parâmetros de RNA, dentre eles *Batch training with weight and bias learning rules*, *Bayesian regularization*, *Cyclical order incremental update*, *Powell-Beale conjugate gradient*, etc. O método do gradiente é o algoritmo utilizado com maior frequência (embora não seja o mais eficiente), segundo Meleiro (2002).

3.4.1.7 Modos de treinamento

Quando todo o conjunto de treinamento é apresentado a uma rede neural, obtém-se o que se denomina de *época*. O processo de treinamento continua até que seja alcançado um número máximo de épocas ou até quando o erro quadrático médio atinge um valor suficientemente pequeno. Para um determinado conjunto de treinamento, o algoritmo de retropropagação pode ser aplicado de dois modos diferentes (BALLINI, 2000):

- **Padrão a padrão:** no aprendizado por retropropagação padrão a padrão, os pesos da rede são atualizados a cada padrão entrada-saída apresentado, ou seja, apenas o gradiente do correspondente padrão é calculado, então este é utilizado imediatamente para atualizar os pesos, considerando assim um único padrão por vez para o treinamento. Deste modo, por cada época, os pesos são ajustados algumas vezes, sendo cada ajuste baseado unicamente no gradiente do erro de um único padrão por vez.
- **Em lote ou batelada:** neste modo de treinamento, um único ajuste dos pesos é feito por cada época. Todos os padrões de treinamento são propagados pela rede e os correspondentes erros são calculados, sendo que o gradiente utilizado para ajustar os pesos será a soma dos gradientes para cada padrão apresentado na época.

3.4.1.8 Critérios de parada

Não existe critério de parada para o algoritmo de retropropagação que garanta a obtenção de uma solução. Contudo, existem alguns critérios que podem ser utilizados para dar término ao processo de treinamento. Segundo Haykin (1994), dois critérios de parada são comumente utilizados:

- Considerando as propriedades dos mínimos locais ou globais da superfície de erro entre os dados experimentais e dados do modelo, sendo um ponto um mínimo local ou global, o vetor gradiente calculado para este mínimo será aproximadamente zero. Deste modo, considera-se que a convergência tenha sido alcançada quando a norma Euclidiana do vetor gradiente seja menor que um valor especificado suficientemente pequeno;
- Um segundo critério de parada é quando os valores do erro quadrático médio ou da função objetivo tornam-se estacionários.

No capítulo 6 são mostradas as configurações das RNA's usadas neste trabalho.

3.5 Planejamento Experimental para Identificação de Sistemas

Para realizar a identificação do sistema, faz-se necessário um planejamento experimental para levar em consideração decisões como configuração da malha, tipo de abordagem, tipo de sinal de excitação, entre outras.

A identificação de processos é uma atividade complexa e pode ser tratada muitas vezes como um problema de otimização no qual se busca estimar, com a melhor exatidão possível, qual modelo matemático melhor representa o processo. A seleção destes modelos e os ajustes de seus parâmetros são influenciados por muitos fatores como: conhecimento a priori do sistema, propriedades do modelo, presença de ruídos, sinal de excitação escolhido, etc. Qualquer das técnicas existentes pode facilmente falhar na estimação do modelo caso estes e alguns outros fatores não sejam respeitados ao longo do ensaio de identificação. E a primeira escolha a ser tomada para o planejamento experimental é a configuração da malha para realização do ensaio de identificação.

3.5.1 Configuração da malha para identificação

Na linguagem de controle de processos existem basicamente duas configurações de malhas para realização do ensaio de identificação, malha aberta ou malha fechada, de modo que cabe ao projetista definir qual configuração deverá ser usada para este experimento. A configuração mais fácil e utilizada nas indústrias é identificação em malha aberta, que é

justificada quando os sistemas são estáveis em malha aberta. A maior vantagem desta configuração é a praticidade e tempo de ensaio.

A Figura 3.18 mostra a representação de uma malha aberta através de diagrama de blocos. É importante salientar que nesta configuração o controlador não terá ação, de maneira que, caso não se disponha do modelo matemático que represente a dinâmica do processo ao modificar a variável manipulada através de uma ação manual, não será possível prever o comportamento da variável de processo ou variável controlada. Este fato implica numa desvantagem na utilização da identificação em malha aberta, pois por não haver a capacidade de prever o comportamento da variável de processo, o ensaio de identificação pode pôr em risco a segurança da planta e qualidade dos produtos.

Figura 3.18 - Diagrama de blocos para malha aberta.



Fonte: Autor, 2011.


A identificação de sistemas em malha fechada foi bastante discutida nos anos 70 como solução alternativa para área de identificação. Neste contexto de identificação em malha fechada, questionamentos sobre o problema de identificabilidade é alvo de bastante discussão, pois o conceito pode ser definido como as condições necessárias (dados suficientemente informativos) que permitam à estimação de parâmetros dos modelos candidatos à identificação, de maneira que estes representem fielmente o comportamento dinâmico do processo real.

No início dos anos 90, a necessidade de se obter melhores modelos para projeto de Controle Preditivo Baseado em Modelos (MPC), aliado aos estudos de controle robusto, trouxe este assunto de volta.

A Figura 3.19 mostra a representação de uma malha fechada através de diagrama de blocos. Nesta configuração a variável manipulada será influenciada pela variável de processo, devido ação do controlador. O controlador tem como objetivo alterar a variável manipulada através de um elemento final de controle, de modo que a variável de processo mantenha-se

igual (ou dentro de uma faixa de tolerância) ao *set point* (valor desejado ou de referência) quando perturbada, em outras palavras, o controlador terá objetivo de fazer com que o erro sempre tenda a zero.

Figura 3.19 - Diagrama de blocos de uma malha fechada.



Fonte: Autor, 2011.

O comportamento da dinâmica de uma planta é diferente quando o consideramos em malha aberta ou em malha fechada, é mais interessante tentar identificar o processo com uso do próprio controlador já instalado na planta, que fornecerá dados mais relevantes para a definição de um novo modelo para o controlador (VAN DEN HOF, 2004).

Ljung (1999) relata que a identificabilidade pode ser garantida desde que pelo menos uma das seguintes condições seja satisfeita:

- O sinal injetado é persistentemente excitante (a possibilidade da entrada do processo já ser persistentemente excitante por si só não é garantia de experimento informativo, pois o controlador pode ser simples demais);
- O controlador é não linear, variante no tempo ou de ordem suficientemente alta (a não linearidade do controlador pode ser obtida pela presença de restrições ativas);
- O sistema é submetido a dois controladores diferentes.

A melhor forma de garantir a identificabilidade é inserindo um sinal persistentemente excitante, pois a atividade do controlador nem sempre é muito previsível quanto às alterações efetuadas na variável manipulada, pelo que as condições necessárias podem não ser atingidas.

Segundo Miranda, F. C. P. R. (2005) a identificação em malha fechada é indispensável nos casos de sistemas que apresentam comportamento instável em malha aberta. Estudos relatam que a configuração malha fechada implica na redução da incerteza do modelo identificado na faixa de frequências que são críticas para o projeto de controladores. No

contexto de sistemas lineares, Hjalmarsson *et al.* (1996) afirma que a identificação em malha fechada é ideal para minimização da variação do erro do controlador a ser projetado.

Outro aspecto importante é que a realização do experimento de identificação em malha fechada permite que esquemas iterativos sejam realizados, ou seja, alternando etapas de identificação (com o mais novo controlador projetado controlando a planta) com etapas de projeto do controlador (usando o modelo identificado). Desta forma, modelos e controladores são ajustados até que o controlador ótimo seja projetado, visando atender a estabilidade e o desempenho desejados do processo. Além disso, a presença do controlador durante o experimento em malha fechada evitará que o processo atinja regiões inseguras. Normalmente, o experimento de identificação é realizado durante a operação normal da planta, e deseja-se minimizar os impactos negativos na produção. Isto pode ser alcançado desde que alguns critérios sejam seguidos, conforme mostra Rivera (2003):

- Limitar a variação da variável controlada para minimizar a variabilidade na qualidade dos produtos,
- Implementar um sinal de curta duração para minimizar a quantidade de produtos não conformes e reduzir o tempo de engenharia requerido para o acompanhamento do teste de identificação,
- Minimizar o deslocamento de partes mecânicas, para evitar desgastes, diminuição do tempo de vida útil e danos dos equipamentos móveis.

A busca pela minimização dos impactos negativos no processo causados pelo ensaio de identificação levou ao surgimento do conceito de *plant-friendly system identification*, que pode ser definido como sistema de identificação amigável à planta. Em outras palavras, pode-se definir como ensaios que não causam grandes alterações ao comportamento da planta, duram tão pouco tempo quanto aceitável e mantêm a variação dos sinais de entrada e saída dentro de faixas definidas pelo engenheiro de processo Rivera (2003).

Como consequência, o projeto de experimentos de identificação amigáveis frequentemente envolverá um compromisso entre a necessidade teórica (que é muitas vezes hostil ao processo) e as demandas dos engenheiros do processo, que normalmente não são simpáticos às interferências no processo causadas pelos experimentos de identificação.

Enquanto as perturbações em malha aberta costumam ser introduzidas nas variáveis manipuladas, em malha fechada o melhor ponto para estes sinais serem adicionados é no valor de referência das variáveis controladas.

Outro fator bastante discutido é como e onde serão coletados os dados de entrada e saída, ou seja, qual será a abordagem utilizada para o ensaio de identificação.

3.5.2 Tipos de Abordagem

O ensaio de identificação é realizado excitando a entrada do sistema para obter dados de saída referentes a esta excitação, obtendo, assim, relações entre causa e efeito. Para identificação em malha aberta a única opção é excitar a variável manipulada (entrada) para obter resposta da variável de processo (saída). Já para identificação em malha fechada, existem várias possibilidades para realização do ensaio. Os principais métodos de identificação utilizados para malha fechada são os seguintes:

- Método direto: o controlador e o valor de referência (valor desejado ou *set point*) são ignorados, utilizam-se as variações na variável manipulada e variável de processo para cálculo do modelo.
- Método indireto: a identificação é realizada como se o valor de referência fosse a entrada do processo, em conjunto com a saída. A partir deste sistema em malha fechada, calcula-se o modelo da planta a partir do conhecimento do controlador.
- Método conjunto de entrada e saída: tanto a entrada e a saída são consideradas como as saídas de um sistema cuja entrada é o valor de referência e o ruído.

As principais características destes métodos são:

- Método direto
 - Funciona independentemente da natureza do controlador;
 - Não necessita de algoritmos ou softwares específicos;
 - Fornece consistência e exatidão ótima, independentemente da natureza da retroalimentação (*feedback*), desde que a estrutura dos modelos da planta e do ruído contenha o sistema real;

- Sistemas instáveis ou com restrições podem ser tratados sem problemas, desde que o sistema seja estável em malha fechada.
- Método indireto
 - Requer perfeito conhecimento do controlador;
 - Pode ser de difícil solução analítica;
 - Não funciona se o controlador apresentar não linearidades (por exemplo, restrições ativas);
 - É equivalente ao método direto aplicado com um modelo do ruído que contenha o controlador.
- Método conjunto de entrada e saída
 - Fornece estimativa consistente do sistema independente dos modelos de ruído usados, desde que o controlador tenha *feedback* com uma determinada estrutura linear;
 - Permite realizar a identificação não só dos modelos da planta e do ruído como também do controlador.

Existem outros métodos mais recentes, como a parametrização *taylor-made* e o método de dois estágios ou a parametrização Youla dual, por exemplo, descritos extensivamente em Van den Hof (2004), além do método da projeção, descrito em Forsell e Ljung (1999).

Em condições normais de ruído não muito alto, o método direto é a escolha natural para a identificação em malha fechada, dadas as propriedades estatísticas, simplicidade e aplicabilidade geral deste método. O problema principal com o método direto é que às vezes os modelos obtidos podem ter bias. Para evitar este problema, pode-se identificar com um modelo de alta ordem (a estrutura do modelo não precisa permanecer a mesma).

3.5.3 Sinais de Excitação

Segundo Aguirre, (2007), o sinal de excitação ideal é aquele que possui ordem suficientemente alta para excitar um número elevado de frequências dominantes da planta, ou seja, possui um amplo espectro de potência na faixa de frequências desejadas. Em outras palavras, as características dinâmicas e estáticas que não forem excitadas não aparecerão nos dados e o que não estiver nos dados não será identificado.

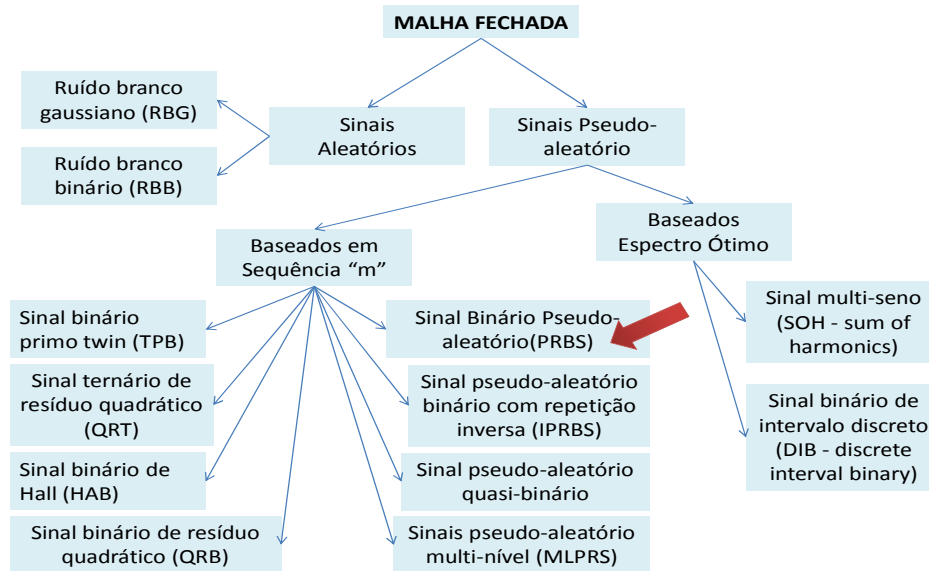
Quando se utiliza técnicas de identificação com estruturas lineares, é importante verificar se esta característica pode ser aplicada em toda a faixa de operação da planta. Caso seja confirmado que o processo tenha comportamento não linear, uma saída é considerar faixas de operação menores que podem ser linearizadas. Conseqüentemente, se foram criadas novas faixas de operação, cada uma delas deverá ser considerada como um processo diferente e experimentos de identificação deverão ser realizados.

O sinal de excitação escolhido deverá provocar variações no processo que permitam a coleta de dados de entrada e saída para encontrar um modelo que seja capaz de reproduzir as características dinâmicas e estáticas necessárias para a aplicação desejada.

Sinais aleatórios ou brancos são comumente escolhidos porque seu espectro de potência está uniformemente distribuído numa ampla faixa de frequência. Porém, sinais aleatórios não são necessariamente fáceis de serem gerados e utilizados. Uma classe de sinais largamente utilizada, e que possui características semelhantes, são os chamados sinais pseudoaleatórios.

Durante revisão bibliográfica foram encontrados os sinais de excitação que atendem o critério de identificabilidade, ou seja, adequados para identificação em malha fechada. Tais sinais são divididos em dois grupos, *sinais aleatórios* e *sinais pseudoaleatórios*. O *sinal aleatório* é subdividido em *ruído branco Gaussiano* (RBG) e *ruído branco binário* (RBB). O *sinal pseudoaleatório* é subdividido naqueles que são baseados em *espectro ótimo* e os que são baseados em *seqüência m*. Nos que se baseiam em *espectro ótimo* existem os *sinal multisseno* (SOH) e *sinal binário de intervalo discreto* (DIB). Nos que se baseiam em *seqüência m* existem *sinal binário primo twin* (TPB), *sinal ternário de resíduo quadrático* (QRT), *sinal binário de hall* (HAB), *sinal binário de resíduo quadrático* (QRB), *sinal pseudoaleatório com repetição inversa* (IPRBS), *sinal pseudoaleatório quase-binário*, *sinal pseudoaleatório multinível* (MLPRS) e *sinal binário pseudoaleatório* (PRBS). A Figura 3.20 mostra um fluxograma dos tipos de sinais comentados.

Figura 3.20 - Fluxograma de sinais de excitação usados para identificação em malha fechada.



Fonte: Autor, 2011.

Não é objetivo deste trabalho detalhar cada um destes sinais, pois optou-se por utilizar o Sinal Binário Pseudoaleatório (PRBS) para excitar o objeto em estudo, porque são mais fáceis de serem gerados e são mais adequados para atender ao conceito de identificação amigável.

A escolha do sinal a ser utilizado na entrada do sistema que se deseja identificar é um fator que define criticamente a qualidade dos modelos obtidos. O sinal de entrada do sistema é responsável por excitar as dinâmicas internas do sistema na faixa de operação desejada. Um sinal mal projetado pode, por um lado, não revelar o comportamento do sistema num dado regime de operação ou, por outro lado, trazer informações indesejadas de fora deste regime.

Segundo Brosilow (2002), algumas vantagens de usar sinais do tipo PRBS são:

- Um sinal PRBS perturba o sistema em torno de um ponto de operação em regime permanente sem desviá-lo significativamente deste valor. Esta é uma vantagem, pois permite que o sistema continue funcionando na sua região de operação enquanto é feita a

identificação, o que é particularmente importante em processos lentos, nos quais a execução dos testes requer um tempo longo;

- O conteúdo de frequência de um sinal PRBS pode ser ajustado facilmente para atender às especificações sobre qual faixa de frequências se deseja excitar;
- Sinais PRBS podem ser repetidos muitas vezes (e vários ensaios podem ser feitos), o que pode aumentar a exatidão das estimativas dos modelos;
- O tempo requerido para a identificação é menor quando comparado com o tempo necessário para sinais aleatórios.

3.5.3.1 Projeto do PRBS

Um sinal de perturbação para identificação de um sistema linear deve ter duas características: ser pequeno o suficiente para minimizar distorções não lineares e grande o suficiente para minimizar os efeitos do ruído. Na identificação em malha fechada, a primeira característica tem uma importância relativa menor, em virtude da presença do *feedback* do controlador, pelo que acaba sendo mais importante tentar aplicar-se a maior amplitude possível nos sinais de perturbação.

Outra característica desejável deste sinal é ser facilmente aplicável no processo. Sinais determinísticos tipo PRBS são fáceis de serem gerados e programados em sistemas digitais de controle.


A duração total de um experimento de identificação deveria ser a maior possível, ou a menor possível, a depender do ponto de vista. Um experimento maior fornece mais dados para identificação, melhorando a estimativa dos parâmetros, por outro lado, ele permite a inclusão de distúrbios que terão maior possibilidade de se manifestar com um tempo maior, gerando não linearidades, além do fato de que qualquer experimento tem custo. Na prática, a duração de um experimento é tão grande quanto necessário para ser suficientemente informativo dentro do menor tempo possível.

Outro ponto importante quanto ao experimento é prever uma determinada quantidade de dados a mais para se poder realizar validação cruzada (validar o modelo com dados não usados para identificação). Idealmente, é interessante conseguir uma quantidade de dados

igual àquela usada para identificação, e isso pode ser conseguido simplesmente com uma sequência PRBS de idêntico tamanho e subsequente à primeira.

O PRBS é um sinal que oscila pseudoaleatoriamente entre duas intensidades apenas, valor maior e valor menor, cuja largura dos pulsos é definida aleatoriamente com limitação de frequência mínima e máxima de oscilação, a Figura 3.21 mostra o formato de um PRBS.

Figura 3.21 - Sinal Binário Pseudoaleatório.



Fonte: Autor, 2011.

Para propósitos de controle do processo pode não ser importante modelar os modos mais rápidos do sistema, que corresponde à região de frequência alta. Portanto, interessa modelar o processo até a frequência de corte, que corresponde à frequência em que o módulo da resposta em frequência de malha fechada é 3 dB abaixo de seu valor na frequência zero, na qual o processo atinge sua largura de faixa.

Ljung (1994) sugere inicialmente aplicar uma entrada do tipo degrau no sistema para obter uma impressão geral sobre as constantes de tempo do sistema. Desta forma evita-se aplicar um sinal que seja tão “rápido” que o sistema não tenha tempo de responder a ele.

Para o projeto do sinal relevante para controle é necessária uma estimativa da seguinte informação priori: a velocidade de resposta em malha fechada, as constantes de tempo dominantes e as amplitudes do sinal que sejam apropriadas para os atuadores. Com esta informação podem ser calculados os parâmetros de projeto listados a seguir:

Um conjunto possível de critérios para definir os sinais PRBS é o seguinte:

$$T \geq 2 \cdot N_u \cdot T_s \quad (3.59)$$

$$T_{sw} = \left(\frac{1}{10} \dots 1 \right) \cdot \tau_{dom} \quad (3.60)$$

$$T_{sw} \leq \frac{2,78 \cdot \tau_{dom}^L}{\alpha_s} \quad (3.61)$$

$$N_s = 2^n - 1 \geq \frac{2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H}{T_{sw}} \quad (3.62)$$

$$N_s \geq \frac{2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H}{T_{sw}} \quad (3.63)$$

$$N_s \cdot T_{sw} \geq 2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H \quad (3.64)$$

onde:

$T \rightarrow$ Tempo total do experimento;

$T_s \rightarrow$ Tempo de estabilização;

$N_u \rightarrow$ Número de entradas;

$T_{sw} \rightarrow$ Tempo entre possíveis chaveamentos;

$\tau_{dom}^L \rightarrow$ Constante de tempo dominante, estimativa mínima;

$\tau_{dom}^H \rightarrow$ Constante de tempo dominante, estimativa máxima;

$n \rightarrow$ Ordem do PRBS;

$N_s \rightarrow$ Número de chaveamento do PRBS mínimo para que o tamanho da amostra de dados seja suficientemente informativo.

$\beta_s \rightarrow$ Fator de tempo de estabilização: é o fator relacionado ao tempo de acomodação do processo e especifica quanta informação de baixa frequência estará presente no sinal. Valores de β_s iguais a 3, 4 ou 5 correspondem a 95%, 98% ou 99% do tempo de acomodação, respectivamente. Por exemplo, um valor de $\beta_s = 5$ enfatizará informação de frequência mais baixa.

$\alpha_s \rightarrow$ Razão de resposta entre malha aberta e malha fechada, este fator determina o conteúdo em alta frequência do sinal e é uma medida de quão rápida é a velocidade de


resposta em malha fechada em relação à resposta em malha aberta. Por exemplo, um valor de $\alpha_s = 2$ implica que a velocidade de resposta em malha fechada é duas vezes mais rápida que a de malha aberta. Valores típicos destes parâmetros são $\alpha_s = 2$ ou 3 e $\beta_s = 5$.

Este conjunto de critérios é uma compilação de recomendações que podem ser encontradas em Zhu e Butoyi (2002), Klerk e Craig (2003), Rivera e Flores (2000) e McFarlane e Rivera (1992).

3.5.3.2 Geração do PRBS

Tais sinais são facilmente gerados usando um registrador de deslocamento, uma porta lógica “E” e outra porta lógica “OU-Exclusivo”. Sendo n o número de bits do registrador de deslocamento e T_{sw} o intervalo entre bits, ou temporização. É visto na Figura 3.22 um exemplo de circuito eletrônico digital gerador de PRBS para $n = 6$ e, portanto, $N = 2^n - 1 = 2^6 - 1 = 63$.

Figura 3.22 - Circuito eletrônico digital gerador de PRBS.



Fonte: Autor, 2011.

Conforme é apresentado no capítulo 4, é utilizado neste trabalho o modelo fenomenológico de Sodr  (2001) para gerar dados atrav s dos ensaios de identifica o. Portanto,   interesse neste modelo gerar o PRBS em linguagem de programa o FORTRAN, ao inv s de gerar como proposto pela Figura 3.22. Sendo assim,   elaborada neste trabalho uma forma alternativa para gera o do PRBS.

A linguagem desenvolvida para gera o do PRBS foi escrita conforme apresentado no anexo A.

Como foi utilizada esta forma alternativa para gerar o PRBS, o parâmetro n (ordem do PRBS ou número de bits do registrador de deslocamento) é projetado apenas para determinação do N_s , pois, por não haver o registrador de deslocamento, não seria necessário determinar o n .

3.5.4 Determinação do Tempo de Amostragem

O período de amostragem de um sistema corresponde ao intervalo de tempo decorrido entre duas amostras e sua escolha tem grande impacto na qualidade dos modelos identificados. Um período de amostragem muito grande significa que ao amostrar um sinal, uma parte da dinâmica do sistema não está sendo registrada. Já um período de amostragem muito pequeno resulta em mau condicionamento numérico no problema de identificação. A razão deste mau condicionamento numérico é que há pouca variância no valor entre dois instantes de tempo discreto, sucessivos.

Na prática, entretanto, costuma-se utilizar o tempo de amostragem de $\frac{1}{10}$ da menor constante de tempo do sistema.

Como Aguirre (2007) fornece uma heurística sugerindo que após definir o tempo de amostragem do sistema, manter constante cada valor aleatório por 3 a 5 períodos de amostragem, no caso de sinais PRBS, deve-se fazer com que o menor patamar do sinal dure de 3 a 5 períodos de amostragem. Para atender esta recomendação, o tempo de amostragem deve ser no mínimo de $\frac{1}{13}$ a $\frac{1}{15}$ da menor constante de tempo do sistema. Neste trabalho o tempo de amostragem adotado foi o de $\frac{1}{15}$ da menor constante de tempo do sistema.

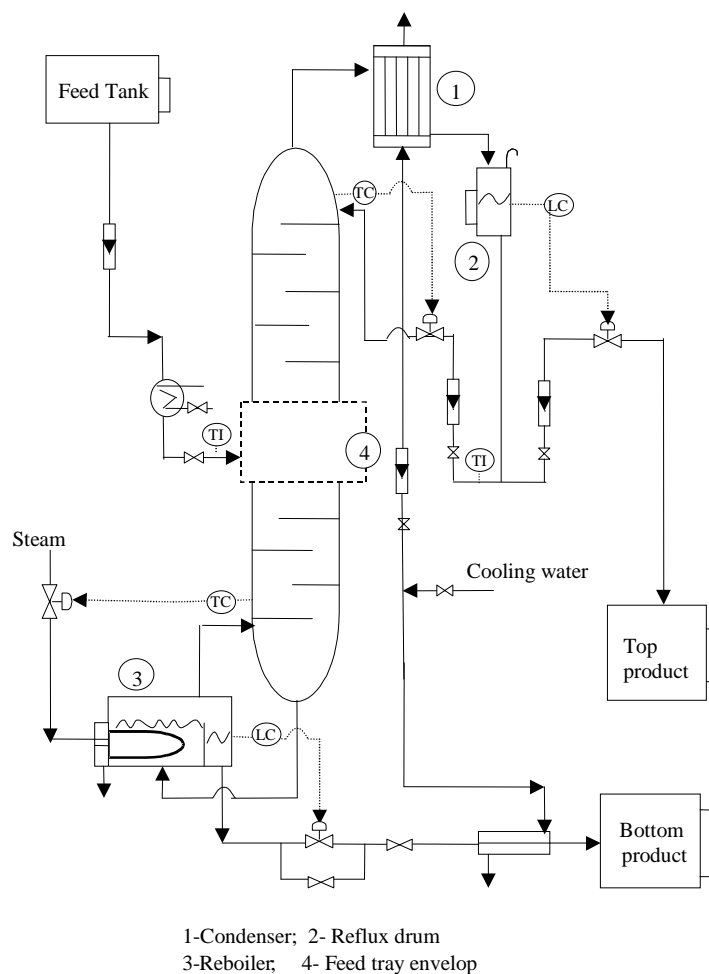
4 OBJETO EM ESTUDO

A coluna de destilação Metanol-Água utilizada opera de modo contínuo e tem a função de separar o metanol da água, sendo o metanol produto de topo e a água produto de base.

O processo de destilação é uma das operações unitárias mais importantes utilizadas na indústria química quando é necessária a separação de componentes. Em Foust (1982) são abordados vários métodos de separação.

Através da interpretação do fluxograma mostrado na Figura 4.1 é possível entender o princípio de funcionamento da coluna de destilação estudada nesta dissertação.

Figura 4.1 - Fluxograma da planta de destilação Metanol-Água usada nesta dissertação



Fonte: Sodr , 2001.

A foto da coluna de destilação Metanol-Água é mostrada na Figura 3.24.

Figura 4.2 - Foto da planta de destilação Metanol-Água usada nesta dissertação



Fonte: Sodré, 2001.

No tanque de alimentação é depositada a mistura binária metanol e água, esta mistura passa por um pré-aquecedor para em seguida alimentar a coluna de destilação. Este pré-aquecedor aquece a mistura através de uma serpentina com vapor interno em contracorrente com a mistura; a mistura metanol-água flui no tubo de alimentação por fora da serpentina. O pré-aquecedor tem a função de tornar a destilação mais rápida e o controle das temperaturas de base e topo mais robustas aos distúrbios provocados pela alimentação da coluna de destilação.

Apesar de não estar explícito na Figura 4.1, a vazão de vapor que flui por dentro da serpentina do pré-aquecedor é manipulada de modo a garantir que a temperatura da mistura metanol-água entre na coluna de destilação na temperatura desejada pelo operador. Esta malha de controle será influenciada principalmente pela vazão de alimentação da mistura, composição da alimentação, pressão e temperatura do vapor.

Na linha de vapor, a vazão é manipulada para controlar a temperatura de base da coluna de destilação. O vapor entra no refeedor por dentro de uma serpentina que troca calor com a mistura metanol-água. O refeedor pode ser assumido como uma mini caldeira, logo, se faz necessário o controle de nível para que não haja superaquecimento nem arraste de líquido através de borbulhamentos. Apesar de não está sendo evidenciado na Figura 3.23, o refeedor é equipado com válvula de alívio para garantir a segurança na operação da planta e não permitir que a pressão no refeedor ultrapasse 2 Bar.

Existe uma transferência de massa da mistura metanol-água do refeedor para a base da coluna através dos vapores gerados no refeedor. Existe também a circulação de mistura metanol-água da base da coluna para o refeedor por pressão hidráulica.

A válvula que manipula a vazão da mistura que sai do refeedor para o seu controle de nível irá ditar a quantidade de produto de base que, em condições ideais, espera-se que seja apenas água. Esta mistura será resfriada através de troca térmica com uma linha de água refrigerada.

A coluna de destilação é feita de cobre e tem dez bandejas. Cada bandeja possui duas tampas/*caps* de bolhas, com exceção da bandeja de alimentação que é fornecida com *downcomer* circular e possui quatro *bubble-caps*. A numeração das bandejas foi sequenciada de cima para baixo. A alimentação é feita na sexta bandeja.

Com o controle da temperatura na base da coluna, será adotada uma temperatura acima de 64 °C e menor que 100 °C para que o metanol, por ser mais volátil que a água, seja evaporado e suba vencendo as barreiras de cada bandeja. À proporção que o vapor de metanol sobe, vencendo as bandejas, espera-se que este vapor esteja com concentração de metanol cada vez maior, de modo que o local onde o metanol estará mais concentrado será no topo da coluna.

Este vapor de metanol será resfriado no condensador, no qual circula água de refrigeração internamente a serpentina, e transferido para o tambor de refluxo devido à diferença de pressão. A partir daí, o metanol pode retornar para coluna para ser redistilado, com o objetivo de aumentar sua concentração ou, caso esteja dentro de especificação, pode ser liberado como produto de topo. A vazão de refluxo do metanol é manipulada para controlar a temperatura do topo da coluna.

Pensando nesta planta como um processo de produção de metanol, o ideal é obter o produto de topo de modo a atender um critério de especificação. Desta forma, a variável que é necessário controlar é a concentração de metanol no topo da coluna, porém esta planta não é equipada com um analisador em linha capaz de medir continuamente a concentração do metanol e, sem a medição, não é possível o controle. Contudo, uma vez que o controle das temperaturas na base e no topo da coluna é obtido, a concentração desejada é atendida.

Sodré (2001), em sua tese de doutorado, elaborou um modelo fenomenológico desta planta e o escreveu em linguagem FORTRAN. Seu modelo foi validado comparando os dados coletados do processo com os gerados em simulação computacional no FORTRAN. Uma vez que este modelo foi validado, pode ser usado para simular o comportamento dinâmico desta planta. Existem algumas vantagens em utilizar modelos matemáticos para simular processos industriais, conforme é mostrado a seguir:

- O tempo de resposta do processo real será mais lento que o tempo para um computador atual simular o mesmo fenômeno;
- O custo associado com a simulação é bem mais barato que a operação de uma planta, pois na simulação não será necessário gastos com matéria prima, insumos e mão de obra;
- O risco de acontecer algum acidente operacional não existirá em simulação;
- Na simulação há maior liberdade para testar novas condições operacionais.

Porém, vale salientar que nenhum modelo é ideal e que em processos complexos, ou seja, que envolvem muitas variáveis, componentes e equipamentos para serem representados por equações, é necessário que o engenheiro tenha conhecimento das leis que regem cada fenômeno envolvido no processo, inclusive considerando a influência dos equipamentos e das

diferentes condições operacionais. De modo que, na grande maioria dos casos, são necessárias algumas considerações e aproximações.

Segundo Sodré (2001), existe alguns problemas em especificar alguns parâmetros de entrada do sistema, pois propriedades físicas, eficiência das bandejas e os coeficientes de transferências de massa raramente estão disponíveis com exatidão, o que implica numa maior incerteza para a resposta do modelo.

As considerações feitas para desenvolvimento deste modelo podem ser observadas detalhadamente em Sodré (2001).

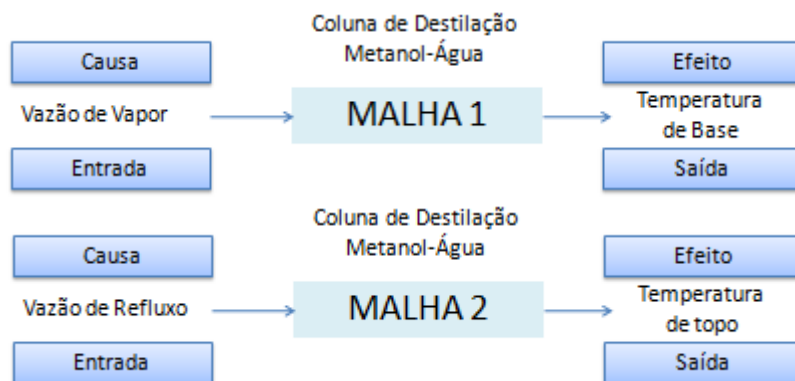
5 METODOLOGIA

Neste capítulo são mostradas as metodologias utilizadas para realizar a identificação da coluna de destilação metanol-água na configuração de operação malha aberta e fechada através do PRBS. É mostrada também a metodologia utilizada para identificação em malha aberta através de perturbação degrau e projeto dos controladores PID.

Como foi mencionada no Capítulo 4, a coluna em estudo tem a finalidade de separar o metanol da água e, devido a dificuldades em sua medição, a concentração de metanol produzido é controlada indiretamente através do controle das temperaturas de base e de topo. Por este fato optou-se neste trabalho em interpretar este caso de estudo da coluna de destilação metanol-água como dois sistemas (SISO), ou seja, entrada e saída simples.

A temperatura de base e vazão de vapor são respectivamente as variáveis de saída e entrada da malha 1 e a temperatura de topo e vazão de refluxo são, respectivamente, as variáveis de saída e entrada da malha 2, conforme é mostrado na Figura 5.1:

Figura 5.1 - Diagrama de blocos das malhas de controle 1 e 2 da coluna de Destilação Metanol-Água.



Fonte: Autor, 2011.

Como o objeto em estudo foi interpretado como duas malhas SISO, entende-se que o problema de identificação resume-se em encontrar os modelos matemáticos capazes de descrever a relação causa/efeito das malhas 1 e 2. Para isto é necessário perturbar as duas malhas para realizar a identificação. Duas das principais metodologias de projeto de perturbações estabelecidas na literatura aplicam usualmente os sinais do tipo degrau e PRBS

(MACHADO, 2004). Cada sinal apresenta aspectos peculiares e excita o sistema de maneira diferente, podendo proporcionar diferentes modelos a depender da riqueza da resposta do sistema frente a cada perturbação. Estas perturbações podem ser executadas em dois modos de operação: em malha aberta ou malha fechada.

Neste trabalho optou-se em excitar as malhas 1 e 2 através de perturbação degrau e PRBS para identificação em malha aberta. Para identificação em malha fechada foi utilizado apenas PRBS.

5.1 Identificação em Malha Aberta com Perturbação Degrau

A identificação em malha aberta através de perturbação degrau normalmente é a primeira metodologia tentada para encontrar um modelo que represente o comportamento dinâmico do processo quando o objetivo deste modelo é obter o projeto de controladores PID. Isso se deve à facilidade na implantação deste tipo de excitação na planta, pois basta alterar os pontos operacionais da variável manipulada para realizar a perturbação degrau.

O fato da equação que representa a perturbação degrau ser disponível em diversas literaturas viabiliza ainda mais a utilização deste tipo de sinal para identificação de sistemas.

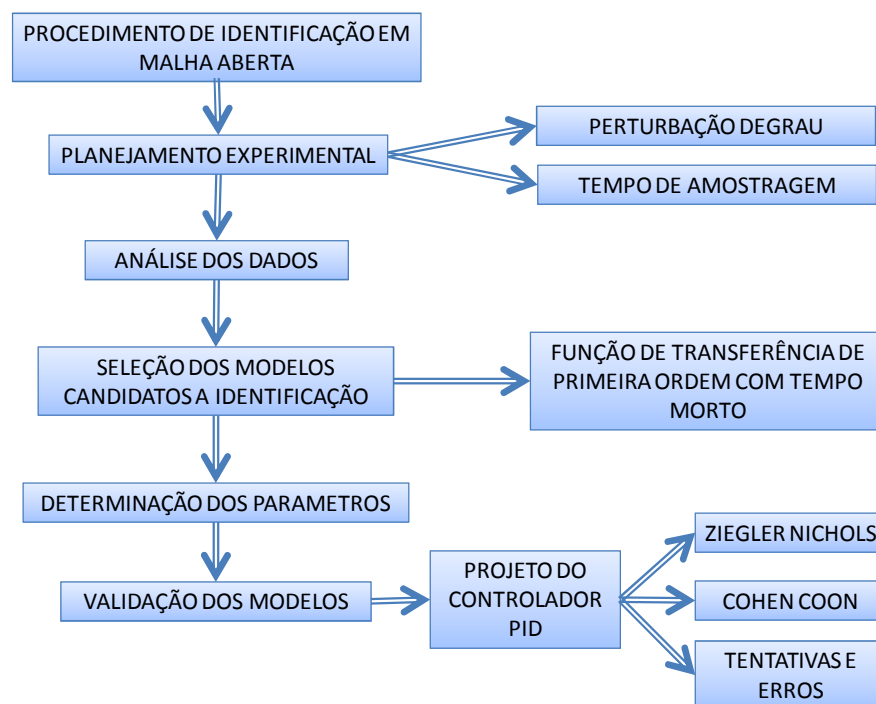
Em alguns processos este tipo de excitação pode ser um inconveniente ou até mesmo um impeditivo para realização do ensaio de identificação. Uma precaução necessária a ser tomada é em relação à amplitude do degrau aplicado na planta e se ela responderá a esta excitação de forma estável ou instável.

Projetar uma perturbação degrau é simplesmente escolher a amplitude do degrau, que não pode ser pequena a ponto de ser confundida com os ruídos, ou seja, a perturbação tem que ter destaque na influência da saída da planta em relação aos ruídos. Por outro lado, a amplitude do sinal não pode ser grande a ponto de tirar a planta de operação devido a algum instrumento de segurança e/ou ir para muito distante do ponto de operação onde a dinâmica do processo apresente comportamento não linear. Caso o degrau tenha amplitude muito grande, haverá uma maior probabilidade de excitar regiões de não linearidades, o que geraria modelos não representativos. Outro possível inconveniente do degrau elevado é a possibilidade de retirar um produto de especificação.

Não existe regra exata para determinar a amplitude do degrau da variável manipulada, porém uma boa prática usada na indústria é determinar que a amplitude do degrau seja entre 2% a 7% do valor operacional, em alguns casos podendo chegar a 10%. Esta boa prática não garante sucesso na escolha da amplitude do degrau.

A Figura 5.2 mostra o fluxograma do procedimento de identificação em malha aberta utilizado nesta dissertação.

Figura 5.2 - Fluxograma da metodologia utilizada para identificação em malha aberta e projeto dos controladores PID.



Fonte: Autor, 2011.

O sinal de excitação foi aplicado nas variáveis de entrada (variáveis manipuladas) das malhas 1 e 2 com amplitude de 7% positivo e negativo em relação ao ponto operacional. As respostas coletadas nestes ensaios são mostradas nas Figuras 6.1, 6.2, 6.3 e 6.4 do Capítulo 6:

Para determinar o tempo de amostragem ou período de amostragem de um sistema é interessante conhecer sua constante de tempo. Ao aplicar uma perturbação degrau na entrada de um sistema dinâmico, a constante de tempo é o tempo necessário para que a saída atinja 63,21% de seu valor final ou de estabilização.

Como foi visto no Capítulo 3, seção 3.2, uma prática comum na engenharia é aproximar através de funções lineares os comportamentos dos sistemas não lineares. De modo que, mediante aos ensaios de identificação, foram identificadas as malhas 1 e 2 através de aproximação de suas dinâmicas às funções de transferência de 1ª ordem com tempo morto.

As funções de transferência com tempo morto são utilizadas com o intuito de aplicar as técnicas de sintonia de controladores PID de Ziegler-Nichols e Cohen Coon. Em seguida estes modelos são aplicados no aplicativo Simulink do *software* MATLAB® para constatar que independente da ferramenta utilizada o modelo apresenta o mesmo comportamento dinâmico.

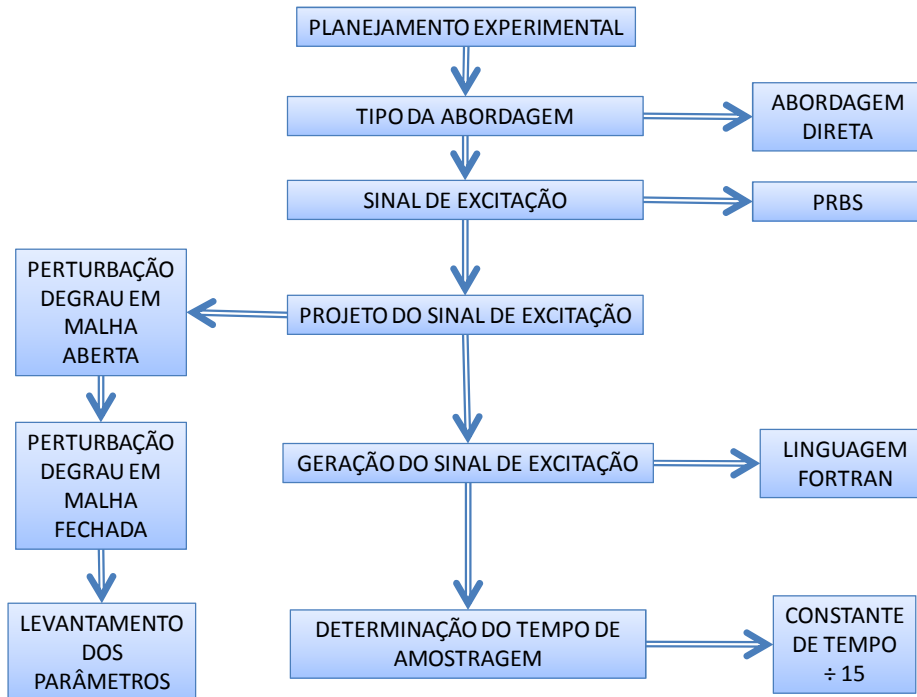
Os resultados das identificações em malha aberta das malhas 1 e 2 são mostradas nas Figuras 6.7, 6.8, 6.9 e 6.10.

Então, a partir destes modelos são calculados os parâmetros dos controladores PID através das técnicas de Ziegler Nichols e Cohen Coon. Em Ogata (2000) é mostrado que estas duas técnicas resultam em parâmetros muito próximos do ótimo, estes valores podem ser lapidados a partir da técnica de tentativa e erro. Vale salientar que, quanto mais próximo do comportamento real do processo o modelo estiver, mais adequado será o projeto dos controladores.

5.2 Identificação em Malha Fechada Através do PRBS

Na sequência será realizada a identificação em malha fechada. O ensaio de identificação é um item crítico para realizar a identificação de forma satisfatória. A elaboração de um planejamento experimental é necessária para definir este ensaio de identificação. A Figura 5.3 apresenta em forma de diagrama de blocos a sequência da metodologia utilizada para planejamento experimental.

Figura 5.3 - Fluxograma da metodologia utilizada para o planejamento experimental através do PRBS para identificação em malha fechada.



Fonte: Autor, 2011.

Para uma identificação em malha fechada a primeira etapa é escolher a abordagem utilizada para coleta dos dados.

Pelo fato de ser a abordagem mais fácil de ser utilizada, optou-se neste trabalho por usar a abordagem direta, ou seja, independente do local que a planta sofra a excitação, os dados coletados serão as variáveis manipuladas (entrada) e variáveis controladas (saída).

Nas identificações em malha fechada outra escolha a ser tomada é o local onde a planta será excitada. O local mais recomendável de excitar um processo industrial para identificação em malha fechada é no valor desejado (*Set Point* ou valor de referência). Portanto, preferiu-se excitar as malhas 1 e 2 em seus respectivos valores desejados.

Boa parte dos pesquisadores da área de identificação vem manifestando interesse pelo PRBS devido à facilidade em sua geração, optou-se então, nesta dissertação, em excitar as malhas 1 e 2 através deste sinal.

Para utilizar o PRBS é necessário projetá-lo. Para levantar os dados necessário para o projeto do PRBS é necessário realizar perturbações de degrau em malha aberta e fechada, para

conhecer as dinâmicas das malhas 1 e 2 nas duas configurações de operação. Como a identificação em malha aberta é uma etapa anterior neste trabalho, nesta etapa já se conhece a dinâmica das malhas 1 e 2 para configuração de malha aberta. Neste caso é necessário apenas realizar perturbação nas malhas 1 e 2 para configuração de operação malha fechada.

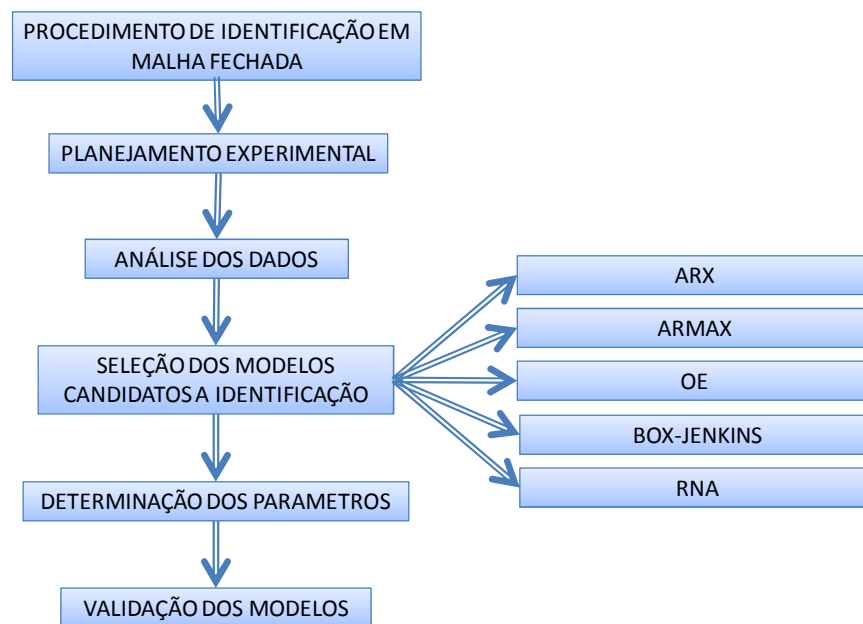
No projeto do PRBS são calculados os tempos mínimos e máximos de oscilação, o tempo mínimo de ensaio necessário para obter dados suficientes para que o ensaio de identificação seja bem informativo e a determinação dos níveis lógicos ou, em outras palavras, qual valor representa o “0” e o “1” do PRBS, ou quais são os valores maiores e menores do PRBS. Detalhes do projeto do PRBS são mostrados no Capítulo 6, na sessão 6.2.

Com o PRBS projetado, é necessário definir como o mesmo será gerado. O PRBS foi gerado em linguagem FORTRAN conforme programa mostrado no Capítulo 3 seção 3.5.3.2.

É adotado nesta dissertação um tempo de amostragem maior ou igual a quinze vezes mais rápido que a dinâmica das malhas 1 e 2 para configuração malha fechada.

O ensaio é realizado mediante o planejamento experimental, donde são coletados os dados para realização da identificação em malha fechada conforme procedimento mostrado na Figura 5.4.

Figura 5.4 - Fluxograma da metodologia utilizada para o procedimento de identificação em malha fechada



Fonte: Autor, 2011.

Após a realização do ensaio de identificação é realizada uma análise dos dados de entrada e saída. Esta análise serve para retirar pontos ruidosos nas medições das variáveis. Outra possibilidade seria, por exemplo, retirar alguns pontos de indicação falsa de temperatura absurdamente alta provocada pelo mau contato entre um pt-100 e seu transmissor de temperatura.

Na sequência são escolhidas algumas representações matemáticas, ou seja, os modelos candidatos à identificação para a realização da identificação em malha fechada. O processo de identificação consiste em encontrar os parâmetros dos modelos através de algum algoritmo de otimização para que o modelo, ao receber o conjunto de dados de entradas, em interação com os parâmetros encontrados, forneça um conjunto de saída compatível com a do processo identificado. Os modelos escolhidos como candidatos à identificação foram os modelos ARX, ARMAX, BJ, OE e RNA.

Mediante a escolha dos modelos candidatos à identificação, os parâmetros destes são encontrados, para em seguida testá-los e validá-los. Os parâmetros dos modelos são

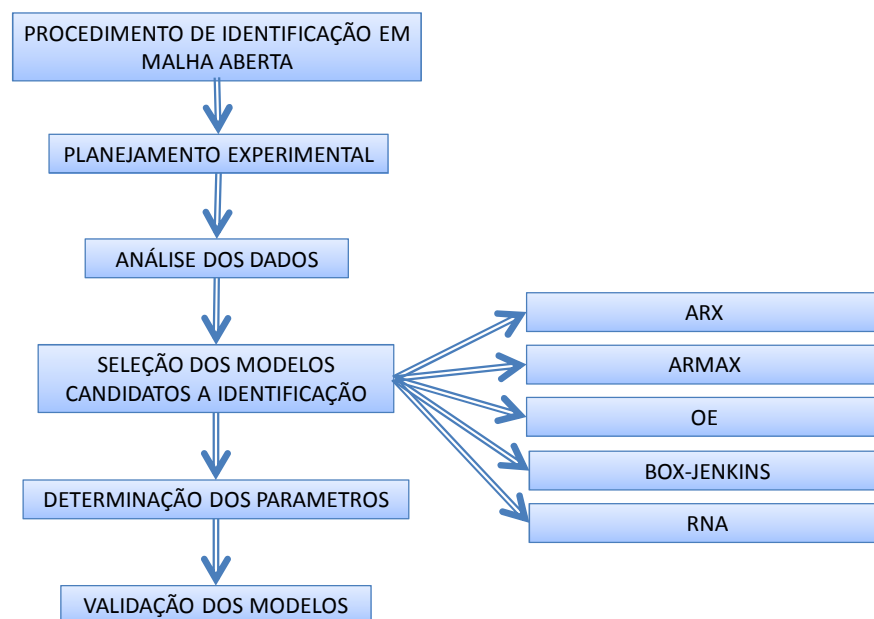
encontrados através da ferramenta IDENT do software MATLAB. Os resultados são mostrados no capítulo a seguir.

5.3 Identificação em Malha Aberta Através do PRBS

Como este é um trabalho acadêmico, optou-se em realizar também a identificação em malha aberta, para possibilitar a comparação das identificações nas configurações malha aberta e fechada. Numa condição industrial não seria necessária a identificação em malha aberta, visto a obtenção dos modelos através da configuração malha fechada.

A Figura 5.5 mostra o procedimento de identificação em malha aberta utilizado neste trabalho.

Figura 5.5 - Fluxograma da metodologia utilizada para o procedimento de identificação em malha aberta



Fonte: Autor, 2011.

Para identificação em malha aberta as malhas 1 e 2 só podem ser excitadas nas variáveis manipuladas, por tanto não é necessário definir o local da excitação e o tipo de

abordagem. Logo o planejamento experimental pula para a etapa da escolha do sinal de excitação, na qual também se optou em utilizar o PRBS pelas mesmas razões.

O projeto e geração do PRBS já estão definidos devido ao procedimento de identificação em malha fechada. É adotado também um tempo de amostragem quinze vezes mais rápido que a dinâmica das malhas 1 e 2 para configuração malha aberta.

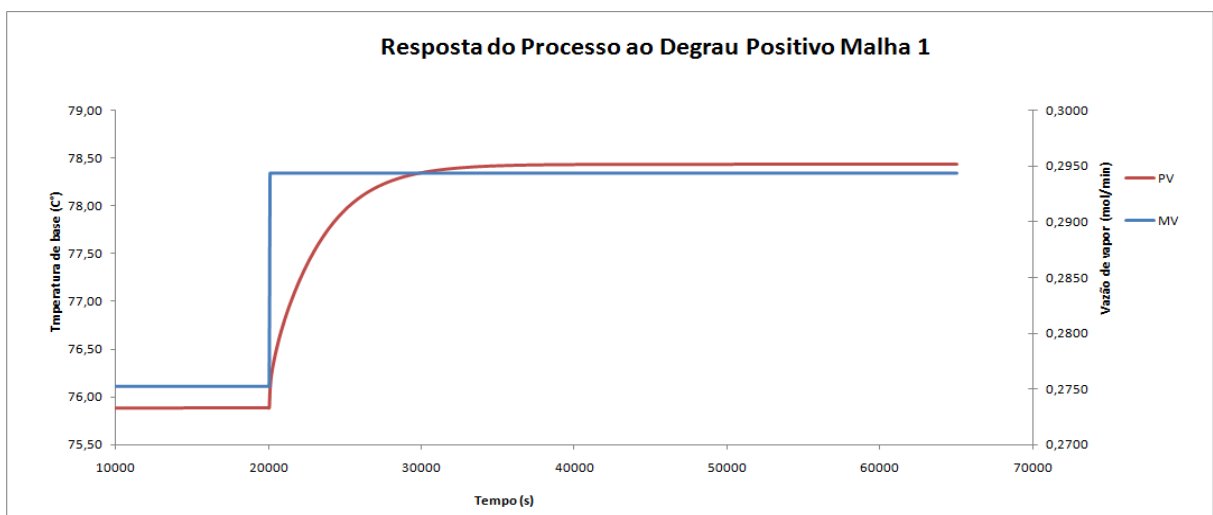
6 RESULTADOS E DISCUSSÕES

Neste capítulo serão mostrados os resultados e discussões provenientes das execuções das metodologias aplicadas citadas no Capítulo 5 para identificação do objeto em estudo.

6.1 Identificação em Malha Aberta Através de Perturbação Degrau

Como dito no capítulo 5, a malha 1 é perturbada com um degrau de 7% positivo e negativo. A Figura 6.1 mostra a resposta da malha 1 à perturbação degrau positiva de 7% de seu ponto operacional. A malha 1 tem como ponto normal de operação 0,2752 mol/min para vazão de vapor que tende a estabilizar a temperatura de base da coluna em 75,88 °C.

Figura 6.1 - Resposta da malha 1 à perturbação degrau positiva de 7% na vazão de vapor.




Fonte: Autor, 2011

As curvas de cor azul das Figuras 6.1, 6.2, 6.3 e 6.4 representam a perturbação degrau na vazão de vapor ou na vazão de refluxo. As curvas de cor vermelha das figuras 6.1, 6.2, 6.3 e 6.4 representam as respostas das variáveis temperaturas de base ou de topo às perturbações

provocadas nas vazões de vapor ou refluxo. Em outras palavras, as curvas azuis representam as variáveis manipuladas e as curvas vermelhas representam as variáveis de processo ou controlada.

A Figura 6.2 mostra a resposta da temperatura de base da coluna de destilação à perturbação degrau na vazão de vapor de 7% negativo de seu ponto operacional.

Figura 6.2: Resposta da malha 1 à perturbação degrau negativa de 7% na vazão de vapor.




Fonte: Autor, 2011

A malha 2 também é perturbada com um degrau de 7% positivo e negativo de seu ponto operacional e tem como ponto normal de operação 0,1654 mol/min para vazão de refluxo que tende a estabilizar a temperatura de topo da coluna em 65,0796 °C.

A Figura 6.3 mostra a resposta da temperatura de topo da coluna de destilação à perturbação degrau na vazão de refluxo de 7% positivo de seu ponto operacional.


Figura 6.3 - Resposta da malha 2 à perturbação degrau positiva de 7% na vazão de refluxo.



Fonte: Autor, 2011.

A Figura 6.4 mostra a resposta da temperatura de topo da coluna de destilação à perturbação degrau na vazão de refluxo de 7% negativo de seu ponto operacional.

Figura 6.4- Resposta da malha 2 à perturbação degrau negativa de 7% na vazão de refluxo.




Fonte: Autor, 2011.

Através dos dados mostrados nas Figuras 6.1, 6.2, 6.3 e 6.4 são determinados os parâmetros como o ganho, constante de tempo e tempo morto das funções de transferência de 1ª ordem com tempo morto.

O ganho de um sistema é a razão entre as variações das variáveis de saída (em processos industriais são denominadas de variável de processo ou controlada) pela variação

das variáveis de entrada (em processos industriais são denominadas variáveis manipuladas). Através da figura 6.5 pode-se definir ganho do processo como sendo $K = \frac{\Delta Y}{\Delta X}$.


Figura 6.5 - Indicação das variações da variável manipulada e de processo para determinação do ganho da malha 1 através de perturbação degrau



Fonte: Autor, 2011.

A constante de tempo é o tempo necessário para que um sistema de 1º ordem atinja 63,21% de sua variação total após receber uma perturbação degrau. É mostrado na Figura 6.6 como obter esta informação através da curva de resposta à perturbação degrau.

Figura 6.6 - Indicação de como encontrar o tempo de resposta da malha 1 submetida a uma perturbação degrau



Fonte: Autor, 2011.

O tempo morto é o tempo que a variável de processo gasta para responder a algum estímulo. Para este caso de estudo pode-se dizer que tempo morto é o tempo que a variável de processo gasta para sofrer alguma variação após sofrer uma perturbação degrau.

Visualmente nota-se através da Figura 6.6 que o tempo morto é muito próximo de zero, porém, como é necessário inserir o tempo morto com valor maior que zero na função de transferência de primeira ordem para ser possível usá-la no projeto de controladores PID a partir das técnicas de Ziegler-Nichols e Cohen-Coon, considerou-se neste trabalho que o tempo morto é igual ao tempo de amostragem, pois a variação de alguma variável é notada somente após a atualização do tempo de amostragem. Adotou-se nesta dissertação um tempo de amostragem de 1s.

Logo após analisar as Figuras 6.1, 6.2, 6.3 e 6.4 são desenvolvidas as funções de transferências de primeira ordem com tempo morto para cada situação gerada pelos ensaios de identificação realizados. Desta forma obtiveram-se as equações 6.1, 6.2, 6.3 e 6.4.

$$G(S) = \frac{132,48.e^{-1.S}}{2880.S+1} \quad (6.1)$$

$$G(S) = \frac{66,44.e^{-1.S}}{2880.S+1} \quad (6.2)$$

$$G(S) = \frac{-6,79.e^{-1.S}}{720.S+1} \quad (6.3)$$

$$G(S) = \frac{-11,79.e^{-1.S}}{840.S+1} \quad (6.4)$$

As equações 6.1 e 6.2 são os modelos da malha 1. As equações 6.3 e 6.4 são os modelos da malha 2. Nota-se que, como os modelos da malha 1 tem ganhos positivos, a vazão de vapor e a temperatura de base são variáveis diretamente proporcionais. Ao contrário da malha 1, a malha 2 tem ganho negativo, isto significa que vazão de refluxo e temperatura de topo são variáveis inversamente proporcionais. Nota-se também que a malha 1 é aproximadamente quatro vezes mais lenta que a malha 2.


A partir da análise destas equações fica evidente a influência da região de excitação para obtenção dos modelos, pois equações que representam a dinâmica das mesmas malhas podem apresentar ganho, constante de tempo e tempo morto, diferentes. De modo que nota-se a necessidade de excitar os sistemas na região de interesse, ou seja, se o objetivo do modelo é

permitir o projeto de controladores pelas técnicas mencionadas, é fundamental excitar as malhas 1 e 2 em torno dos pontos normais de operação.

Ao analisar as técnicas de Ziegler-Nichols e Cohen Coon, percebe-se que os parâmetros de sintonia dos controladores PID dependem do ganho, constante de tempo e do tempo morto da malha controlada, isto significa que um controlador projetado para manter uma malha em um ponto operacional pode ter eficiência comprometida caso opere em outros pontos.

As respostas simuladas pelas equações 6.1, 6.2, 6.3 e 6.4 são mostradas respectivamente pelas Figuras 6.7, 6.8, 6.9 e 6.10 comparadas com os dados reais.

Figura 6.7 - Comparação da resposta do modelo da equação 6.1 em relação aos dados experimentais.



Fonte: Autor, 2011.

É notável visualmente na Figura 6.7 que a resposta do modelo representado pela equação 6.1 apresenta comportamento dinâmico semelhante ao do processo real. Porém,


avaliar modelos matemáticos visualmente não é o método mais adequado, pois a engenharia sente a necessidade de quantificar os resultados.

Nesta dissertação os modelos de identificação em malha aberta através de perturbação degrau são avaliados quantitativamente através da média dos erros quadráticos entre os dados estimados pelos modelos e os dados experimentais, conforme mostra a equação 6.5.

$$R^2 = 1 - \left[\frac{1}{n} \sum_{i=1}^n (x_{modelo} - x_{experimental})^2 \right] \quad (6.5)$$

Quanto mais próximo do valor um 1 for o R^2 , melhor é o desempenho do modelo em relação às condições experimentais utilizadas.

Figura 6.8 - Curva de coeficiente de regressão entre modelo da equação 6.1 e dados experimentais.




Fonte: Autor, 2011.

Desta forma tem-se uma avaliação quantitativa deste modelo, de modo que permite uma comparação mais adequada em relação a outros modelos. Em aplicações industriais

pode-se estabelecer um critério para aceitação do modelo, por exemplo, caso o modelo apresente um $R^2 \geq 0,95$, o mesmo deve ser aceito, caso contrário este não serve para aplicação desejada.

A Figura 6.9 mostra a resposta do modelo representado pela equação 6.2. Este modelo apresenta comportamento dinâmico semelhante ao do processo real.


Figura 6.9 - Comparação da resposta do modelo da equação 6.2 em relação aos dados experimentais.



Fonte: Autor, 2011.

A Figura 6.10 mostra o desempenho do modelo representado pela equação 6.2. Nota-se que o desempenho deste modelo foi inferior ao do modelo 6.1, porém, se considerar-se o critério de aceitação de $R^2 \geq 0,95$, pode-se afirmar que este modelo é válido para região de excitação utilizada.


Figura 6.10 - Curva de coeficiente de regressão entre modelo da equação 6.2 e dados experimentais.



Fonte: Autor, 2011.

A Figura 6.11 mostra o desempenho do modelo 6.3.


Figura 6.11: Comparação da resposta do modelo da equação 6.3 em relação aos dados experimentais.



Fonte: Autor, 2011.

Conforme é visto na Figura 6.11, o R^2 apresenta um valor muito próximo de 1, isto significa que a malha 2 pode ter o comportamento replicado pelo modelo 6.3 com bom desempenho.


Figura 6.12 - Curva de coeficiente de regressão entre modelo da equação 6.3 e dados experimentais



Fonte: Autor, 2011.

A Figura 6.13 mostra a comparação de comportamentos entre malha 2 e o modelo 6.4.


Figura 6.13 - Comparação da resposta do modelo da equação 6.4 em relação aos dados experimentais.



Fonte: Autor, 2011.

Conforme é mostrado na Figura 6.13, o modelo apresenta desempenho bastante satisfatório para região excitada.

Figura 6.14 - Comparação entre dados experimentais e simulados pela equação 6.4.

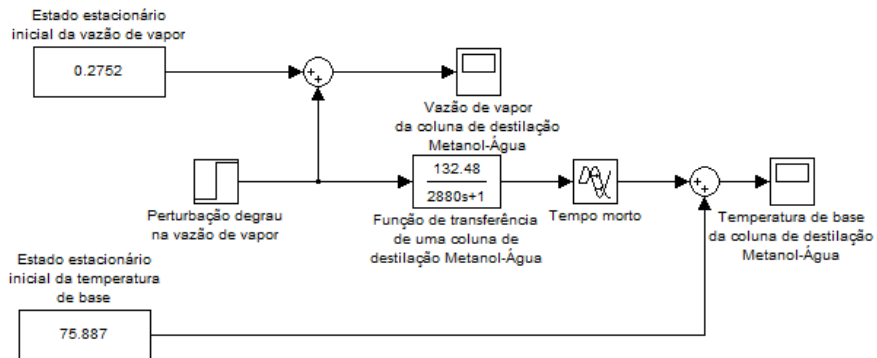


Fonte: Autor, 2011.

Após estas identificações, fica notório a influência que a região de operação da planta exerce nas dinâmicas das malhas 1 e 2, ou no modelo encontrado. É importante salientar que o ensaio de identificação deve ser realizado para região de operação de interesse, visto que estes modelos encontrados são aproximações lineares de sistemas não lineares e apenas serão eficientes para faixas estreitas de operação, cujo sistema terá comportamento mais próximo da linearidade. Caso os pontos operacionais do processo sejam alterados, suas dinâmicas podem mudar, com isto será necessário uma nova identificação e, quando usados para projeto de controladores, será necessária também uma nova sintonia do controlador PID para que seja mantida a mesma eficiência.

A Figura 6.15 apresenta o diagrama de bloco montado no aplicativo Simulink do *software* MATLAB para simular o comportamento da malha 1 na configuração malha aberta. Esta simulação tem como objetivo constatar a eficiência do modelo nesta ferramenta de simulação usada vastamente pelos pesquisadores e profissionais das áreas de modelagem, otimização e controle de processos industriais.

Figura 6.15 - Diagrama de bloco da malha 1 aberta representado pela equação gerada pelo ensaio da figura 6.1.



Fonte: Autor, 2011.

A Figura 6.16 mostra a resposta do modelo representado pela equação 6.1 e montado em forma de diagrama de blocos no Simulink, conforme Figura 6.15, a uma perturbação degrau positiva de 7%.

Figura 6.16 - Resposta ao degrau da simulação do sistema mostrado na figura 6.15.



Fonte: Autor, 2011.

Segundo é mostrado na Figura 6.16, fica evidente que, independente do aplicativo usado para simular o sistema em estudo, o modelo apresenta o mesmo desempenho, porém o SIMULINK/MATLAB é uma ferramenta que dispõe de um ambiente mais amigável para simulação de processos industriais.

Optou-se neste trabalho por projetar os controladores PID utilizando os modelos a partir das perturbações degrau positiva. Foram utilizadas as técnicas de Ziegler-Nichols e Cohen Coon para projetar os controladores das malhas 1 e 2.

As Tabelas 6.1 e 6.2 mostram como obter os parâmetros dos controladores PID mediante conhecimento dos modelos das malhas 1 e 2.

Tabela 6.1: Regra de Cohen Coon para sintonia de controladores PID.

Controlador	K_c	τ_i	τ_d
P	$\left[1,03 + 0,35 \cdot \left(\frac{\theta}{\tau} \right) \cdot \frac{\tau}{\theta \cdot K} \right]$		
PI	$\left[0,9 + 0,083 \cdot \left(\frac{\theta}{\tau} \right) \cdot \frac{\tau}{\theta \cdot K} \right]$	$\left[0,9 + 0,083 \cdot \left(\frac{\theta}{\tau} \right) \right]$	
PID	$\left[1,35 + 0,25 \cdot \left(\frac{\theta}{\tau} \right) \cdot \frac{\tau}{\theta \cdot K} \right]$	$\left\{ \left[\frac{1,35 + 0,25 \cdot \left(\frac{\theta}{\tau} \right)}{0,54 + 0,33 \cdot \left(\frac{\theta}{\tau} \right)} \right] \cdot \theta \right\}$	$\left[\frac{0,5 \cdot \theta}{1,35 + 0,25 \cdot \left(\frac{\theta}{\tau} \right)} \right]$

Fonte: Autor, 2011.

Tabela 6.2: Regra de Ziegler-Nichols para sintonia de controladores PID.

Controlador	K_c	τ_i	τ_d
P	$\left(\frac{\tau}{\theta \cdot K} \right)$		
PI	$\left[0,9 \cdot \left(\frac{\tau}{\theta \cdot K} \right) \right]$	$(3,33 \cdot \theta)$	
PID	$\left[1,2 \cdot \left(\frac{\tau}{\theta \cdot K} \right) \right]$	$(2 \cdot \theta)$	$(0,5 \cdot \theta)$

Fonte: Autor, 2011.

As Tabelas 6.1 e 6.2 são geradas a partir dos parâmetros do modelo representado pela equação 6.1.

Tabela 6.3 - Resultado das sintonias usando a regra de Cohen Coon para malha 1.

Controlador	K_c	τ_i	τ_d
P	0,375818		
PI	0,326703	0,901729	
PID	0,491001	2,478095	0,368947

Fonte: Autor, 2011.

Tabela 6.4 - Resultados das sintonias usando a regra de Ziegler-Nichols para malha 1.

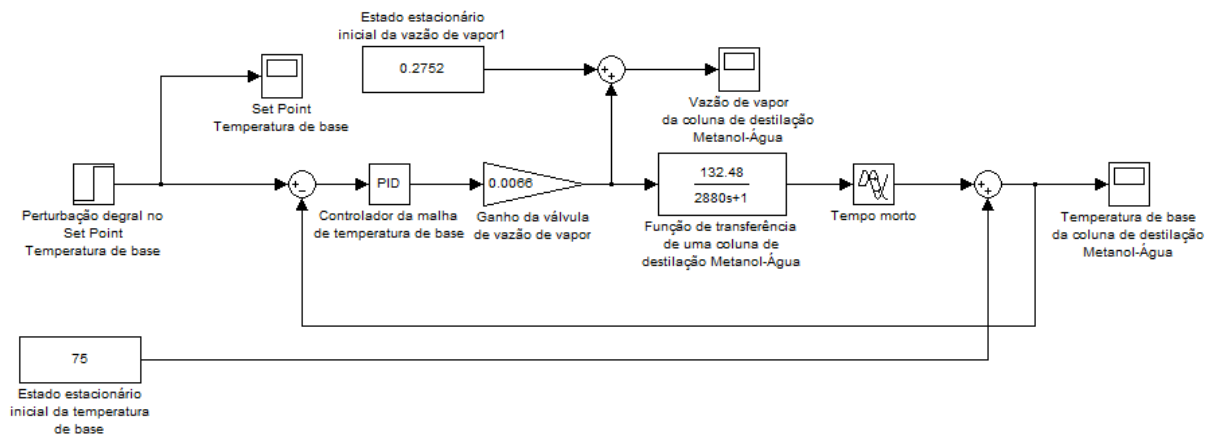
Controlador	K_c	τ_i	τ_d
P	0,362307		
PI	0,326076	3,33	
PID	0,434768	2	0,5

Fonte: Autor, 2011.

Os controladores projetados são testados para permitir a decisão de qual projeto oferece maior desempenho. Durante os testes optou-se em alterar os parâmetros projetados através da técnica de tentativas e erros visando obter uma melhor eficiência dos controladores. A malha foi testada através da simulação conforme o diagrama de blocos mostrado na Figura 6.17.

O ganho do elemento final de controle foi determinado através da curva de resposta da válvula de controle da malha 1.

Figura 6.17 - Diagrama de bloco da malha 1 fechada.



Fonte: Autor, 2011.

Os objetivos de controle determinados para testar os controladores da malha 1 são: valor desejado de 80 °C, tolerância de 0,5 °C, sobre sinal máximo de 3 °C e tempo de acomodação de 2000 segundos.

A Figura 6.18 demonstra o desempenho do controlador escolhido para controlar a malha 1. A curva amarela do gráfico da temperatura de base representa o valor desejado e a curva de cor violeta representa a variável de processo.

Figura 6.18 - Resposta ao degrau do sistema mostrado pela figura 6.17.



Fonte: Autor, 2011.

Percebe-se através destas respostas que o controlador consegue manter a variável de processo próximo do valor desejado sem provocar sobre sinais comprometedores, e que, considerando uma tolerância de $0,5^{\circ}\text{C}$, o tempo de acomodação da variável controlada é aproximadamente 1200 segundos. Portanto, os objetivos de controle são atendidos por este controlador.

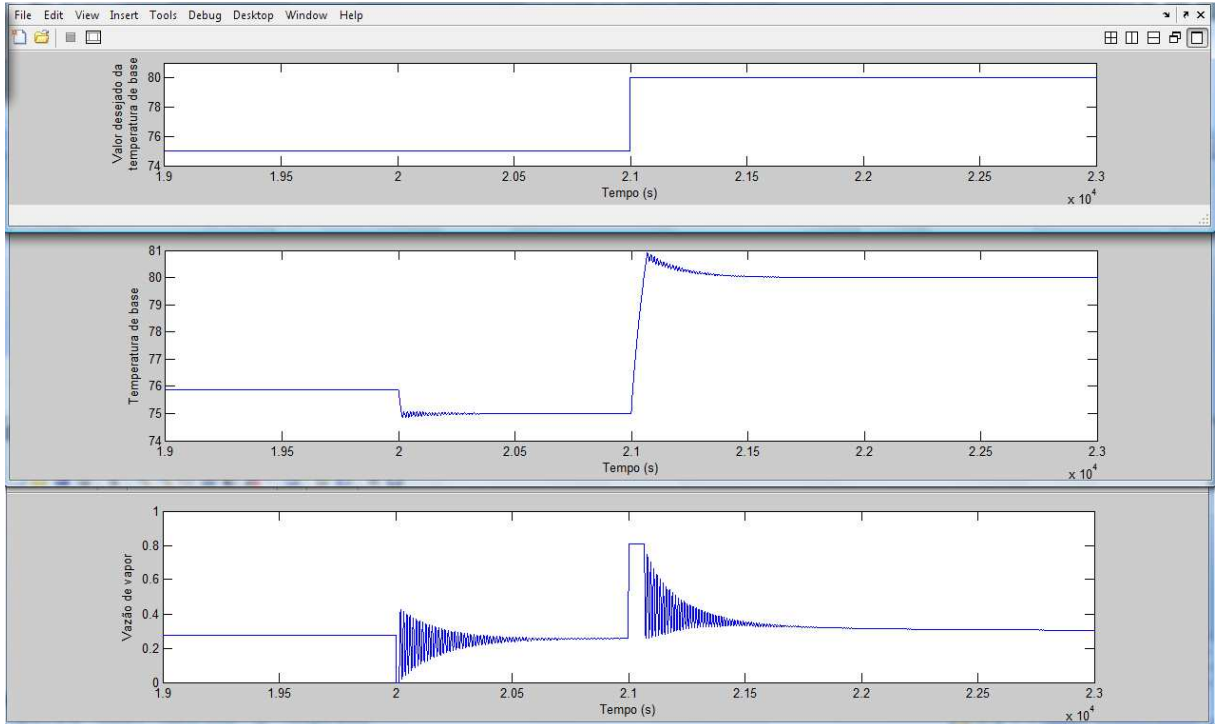
6.2 Projeto do PRBS

Para elaborar o projeto do PRBS é necessário conhecer a dinâmica do sistema nas duas configurações de operação, em malha aberta e fechada. Entretanto, as dinâmicas do sistema em malha aberta são obtidas através das funções de transferências encontradas anteriormente.

Com o controlador projetado por Sodré (2001) as malhas 1 e 2 são excitadas através de perturbação degrau. A resposta destas duas perturbações é mostrada nas figuras 6.19 e 6.20.

A Figura 6.19 mostra a resposta da temperatura de base a uma perturbação degrau de 5°C aplicado em seu valor desejado (*Set Point*). Neste ensaio a temperatura de base é controlada por um controlador PI (Proporcional e Integral) que manipula a vazão de vapor.


Figura 6.19 - Resposta da temperatura de base a perturbação degrau no valor desejado



Fonte: Autor, 2011.

A Figura 6.20 exibe a resposta da temperatura de topo a uma perturbação degrau de $0,5 \text{ }^\circ\text{C}$ aplicado em seu valor desejado (*Set Point*). Neste ensaio a temperatura de topo é controlada por um controlador PI (Proporcional e Integral) que manipula a vazão de refluxo.

Figura 6.20 - Resposta da temperatura de topo a perturbação degrau no valor desejado



Fonte: Autor, 2011.

Conforme é visto no capítulo 3 sessão 3.5.3.1, o conjunto de critérios utilizado para definir os sinais PRBS são os seguintes:

Malha 1:

$$T \geq 2 \cdot N_u \cdot T_s$$

$$T \geq 2.1.5000$$

$$T \geq 10000 \text{ s}$$

Como a malha 1 levou 5000 s para estabilizar e é um sistema de apenas uma entrada, o tempo mínimo para o ensaio de identificação foi calculado para maior ou igual a 10000 segundos.

$$T_{sw} = \left(\frac{1}{10} \dots 1 \right) \cdot \tau_{dom}$$

$$T_{sw} = \left(\frac{1}{10} \dots 1 \right) \cdot 800$$

$$T_{sw1} = \frac{1}{10} \cdot 800$$

$$T_{sw1} = 80 \text{ s}$$

$$T_{sw2} = 1.800$$

$$T_{sw2} = 800 \text{ s}$$

Esta metodologia assume que o PRBS deve oscilar com tempo de largura de pulso variando entre 10% e 100% da constante de tempo do sistema em malha fechada.

$$\alpha_s = \frac{\tau_{dom}^{ABERTA}}{\tau_{dom}^{FECHADA}}$$

$$\alpha_s = \frac{2880}{800}$$

$$\alpha_s = 3,6$$

Este valor de α_s significa que a resposta do sistema em malha fechada está 3,6 vezes mais rápida que o mesmo sistema em malha aberta.

$$T_{sw} \leq \frac{2,78 \cdot \tau_{dom}^L}{\alpha_s}$$

$$T_{sw} \leq \frac{2,78 \cdot 800}{3,6}$$

$$T_{sw} \leq 617,78 \text{ s}$$

Este valor de T_{sw} significa que T_{sw2} terá que ser reduzido para um valor menor ou igual 617,78 segundos.

$$N_s \cdot T_{sw} \geq 2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H$$

$$T = N_s \cdot T_{sw} \geq 2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H$$

$$T \geq 2 \cdot \pi \cdot 3.800$$

$$T \geq 15080 \text{ s}$$

Ao multiplicar o número de oscilações necessárias pelo tempo máximo de comutação, observa-se que a resposta representa o tempo necessário para o ensaio de identificação que neste caso terá que ser maior ou igual a 15080 segundos.

Malha 2:

$$T \geq 2 \cdot N_u \cdot T_s$$

$$T \geq 2 \cdot 1.300$$

$$T \geq 600 \text{ s}$$

Como a malha 2 levou 300 segundos para estabilizar e é um sistema de apenas uma entrada, o tempo mínimo para o ensaio de identificação foi calculado para maior ou igual a 600 segundos.

$$T_{sw} = \left(\frac{1}{10} \dots 1 \right) \cdot \tau_{dom}$$

$$T_{sw} = \left(\frac{1}{10} \dots 1 \right) \cdot 80$$

$$T_{sw1} = \frac{1}{10} \cdot 80$$

$$T_{sw1} = 8 \text{ s}$$

$$T_{sw2} = 1.80$$

$$T_{sw2} = 80 \text{ s}$$

Esta metodologia assume que o PRBS deve oscilar com tempo de largura de pulso variando entre 10% e 100% da constante de tempo do sistema em malha fechada.

$$\alpha_s = \frac{\tau_{dom}^{ABERTA}}{\tau_{dom}^{FECHADA}}$$

$$\alpha_s = \frac{720}{80}$$

$$\alpha_s = 9$$

Este valor de α_s significa que a resposta do sistema em malha fechada está 9 vezes mais rápida que o mesmo sistema em malha aberta.

$$T_{sw} \leq \frac{2,78 \cdot \tau_{dom}^L}{\alpha_s}$$

$$T_{sw} \leq \frac{2,78 \cdot 80}{9}$$

$$T_{sw} \leq 24,71 \text{ s}$$

Este valor de T_{sw} significa que T_{sw2} terá que ser reduzido para um valor menor ou igual 24,71 segundos.

$$N_s \cdot T_{sw} \geq 2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H$$

$$T = N_s \cdot T_{sw} \geq 2 \cdot \pi \cdot \beta_s \cdot \tau_{dom}^H$$

$$T \geq 2 \cdot \pi \cdot 5,80$$

$$T \geq 2514 \text{ s}$$

Ao multiplicar o número de oscilações necessárias pelo tempo máximo de comutação, observa-se que a resposta representa o tempo necessário para o ensaio de identificação que neste caso terá que ser maior ou igual a 2514 segundos.

Com os conjuntos de dados obtidos nos ensaios em malha aberta e fechada determinou-se o intervalo de frequência do PRBS para malha 1, de 1/80 hertz a 1/617 hertz. O tempo estimado para realização do ensaio de identificação através do PRBS de forma a gerar uma quantidade mínima suficiente de dados é de 15080 segundos para malha 1. Com o objetivo de validar e testar os modelos obtidos através da identificação optou-se por triplicar o tempo de ensaio para 45240 segundos, podendo assim dividir os dados entre treinamento, validação e teste dos modelos.

O intervalo de frequência para o PRBS para malha 2 é de 1/8 hertz a 1/24 hertz. O tempo estimado para realização do ensaio de identificação através do PRBS de forma a gerar

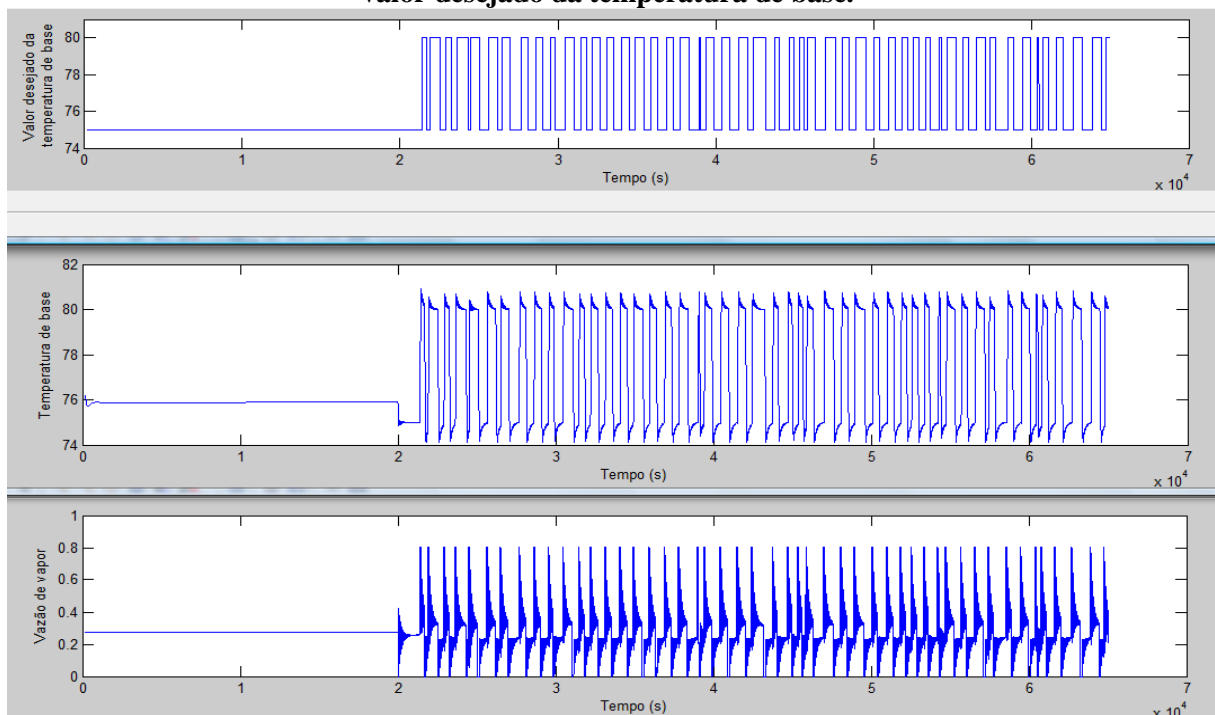
uma quantidade mínima suficiente de dados é de 2514 segundos para malha 2. Com o objetivo de validar e testar os modelos obtidos através da identificação optou-se novamente por triplicar o tempo de ensaio para 7542 segundos, podendo assim dividir os dados entre treinamento, validação e teste dos modelos.

Foi elaborada neste trabalho uma sub-rotina na linguagem FORTRAN para geração do PRBS, devido à necessidade de implantar este sinal ao mesmo ambiente do modelo fenomenológico de Sodré (2001). A sub-rotina é mostrada no Capítulo 3, seção 3.5.3.2.

6.3 Identificação em Malha Fechada com PRBS

Agora serão realizados os ensaios com PRBS devidamente projetado nas malhas 1 e 2, os resultados destes são mostrados nas Figuras 6.21 e 6.30, respectivamente.

Figura 6.21 - Resposta do ensaio de identificação em malha fechada com perturbação PRBS no valor desejado da temperatura de base.




Fonte: Autor, 2011.

A Figura 6.22 apresenta como foi desenvolvido o ensaio de identificação em malha fechada para malha 1. Ao excitar o valor desejado da temperatura de base, o controlador manipula a vazão de vapor de forma que a temperatura de base apresente comportamento semelhante ao desejado. Neste ensaio é necessário separar os sinais a partir do momento que

inicia a excitação através do PRBS, que corresponde ao instante de tempo 21000 segundos após a inicialização da operação desta coluna de destilação.

Figura 6.22 - Conjunto de dados selecionados para identificação da malha 1 fechada.



Fonte: Autor, 2011.

Este conjunto de dados é exportado para o aplicativo IDENT, que é um ambiente de identificação do *software* MATLAB em que são escolhidos os modelos candidatos à identificação bem como sua ordem. Feitas estas escolhas são realizadas as estimações dos parâmetros dos modelos através de algum algoritmo de otimização, ou seja, são realizadas as identificações, cujos resultados são mostrados nas Figuras 6.23, 6.24, 6.25 e 6.26.


Um dos resultados das identificações em malha fechada realizadas neste trabalho é o modelo ARX apresentado pela equação 6.6 cujos parâmetros $A(q)$ e $B(q)$ são polinômios de décima ordem representados respectivamente pelas equações 6.7 e 6.8.

$$A(q)y(t) = B(q)u(t) + e(t) \quad (6.6)$$

$$A(q) = 1 - 1.672 q^{-1} + 0.8734 q^{-2} - 0.1226 q^{-3} - 0.1069 q^{-4} - 0.06873 q^{-5} - \\ 0.04511 q^{-6} - 0.03342 q^{-7} - 0.01507 q^{-8} + 0.2653 q^{-9} - 0.07459 q^{-10} \quad (6.7)$$

$$B(q) = 0.15 q^{-1} + 0.02744 q^{-2} + 0.004428 q^{-3} - 0.02742 q^{-4} - 0.04346 q^{-5} - \\ 0.04962 q^{-6} - 0.05166 q^{-7} - 0.04949 q^{-8} + 0.03155 q^{-9} + 0.006323 q^{-10} \quad (6.8)$$

Figura 6.23 - Comparação da resposta do modelo ARX em relação à resposta experimental da temperatura de base.



Fonte: Autor, 2011.

Outro resultado das identificações realizadas neste trabalho é o modelo ARMAX representado pela equação 6.9 cujos parâmetros $A(q)$, $B(q)$ e $C(q)$ são polinômios de terceira ordem representados respectivamente pelas equações 6.10, 6.11 e 6.12.


$$A(q)y(t) = B(q)u(t) + C(q)e(t) \quad (6.9)$$

$$A(q) = 1 - 2.549 q^{-1} + 2.104 q^{-2} - 0.5551 q^{-3} \quad (6.10)$$

$$B(q) = 0.3535 q^{-1} - 0.6056 q^{-2} + 0.2521 q^{-3} \quad (6.11)$$

$$C(q) = 1 - 1.512 q^{-1} + 0.6305 q^{-2} - 0.01876 q^{-3} \quad (6.12)$$

Figura 6.24 - Comparação da resposta do modelo ARMAX em relação à resposta experimental da temperatura de base.



Fonte: Autor, 2011.


Outro modelo elaborado neste trabalho é o OE representado pela equação 6.13 cujos parâmetros $B(q)$ e $F(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.14 e 6.15.

$$y(t) = [B(q)/F(q)]u(t) + e(t) \quad (6.13)$$

$$B(q) = 0.2886 q^{-1} - 0.288 q^{-2} \quad (6.14)$$

$$F(q) = 1 - 1.986 q^{-1} + 0.9856 q^{-2} \quad (6.15)$$

Figura 6.25 - Comparação da resposta do modelo OE em relação à resposta experimental da temperatura de base.



Fonte: Autor, 2011.

O modelo BJ, elaborado neste trabalho, é representado pela equação 6.16 cujos parâmetros $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.17, 6.18, 6.19 e 6.20.

$$y(t) = [B(q)/F(q)]u(t) + [C(q)/D(q)]e(t) \quad (6.16)$$


$$B(q) = 0.2886 q^{-1} - 0.288 q^{-2} \quad (6.17)$$

$$C(q) = 1 - 0.1737 q^{-1} + 0.1653 q^{-2} \quad (6.18)$$

$$D(q) = 1 - 1.635 q^{-1} + 0.6358 q^{-2} \quad (6.19)$$

$$F(q) = 1 - 1.986 q^{-1} + 0.9856 q^{-2} \quad (6.20)$$

Figura 6.26 - Comparação da resposta do modelo BJ em relação á resposta experimental da temperatura de base.



Fonte: Autor, 2011.

Visando obter um parâmetro para quantificar a eficiência dos modelos ARX, ARMAX, OE e BJ, são calculados os somatórios dos erros quadráticos e as médias dos erros quadráticos de cada modelo, tornado assim mais contundente as comparações entre estes modelos. A Tabela 6.5 mostra os somatórios dos erros e as médias dos erros entre as respostas dos modelos e dos experimentos, o que permite uma comparação de eficiência entre os modelos obtidos através das identificações da malha 1.

Tabela 6.5 - Comparação dos erros dos modelos candidatos à identificação para malha 1 fechada.

Modelo malha 1	ARX	ARMAX	OE	BJ
Somatório do erro quadrático	968218,5154	308047,5131	3441,16	3385,151935
Média do erro quadrático	22,00496626	7,001079843	0,078208	0,076935271

Fonte: Autor, 2011.

Partindo do mesmo ensaio de identificação, é utilizado também uma rede neural artificial para identificar a malha 1 na configuração malha fechada.

Para construir uma rede é necessário decidir qual tipo de rede, quantas camadas intermediárias, quantos neurônios terão em cada camada intermediária, se será utilizado o conceito de regressão, conseqüentemente, definir quantas e quem serão as variáveis de entrada, quais as funções de ativação para cada camada da rede, qual algoritmo de otimização será utilizado para treinamento para que sejam encontrados os pesos e os *bias* da rede de modo que a mesma aprenda o comportamento do sistema identificado.

Para que a rede neural artificial aprenda o comportamento dinâmico de algum sistema, é necessário utilizar o conceito de regressão. Portanto, como o interesse deste trabalho é obter modelos dinâmicos, a rede utilizada para identificar a malha 1 na configuração malha fechada utiliza o conceito de regressão e tem a vazão de vapor a um passo atrás, a dois passos atrás, e a três passos atrás e a temperatura de base a um passo atrás, a dois passos atrás e a três passos atrás como variáveis de entrada da RNA. Isto implica dizer que esta RNA possui seis variáveis de entrada, logo, tem seis neurônios na camada de entrada.


Esta RNA possui apenas uma camada intermediária com dez neurônios. Como a malha 1 possui apenas uma variável de saída, a RNA tem apenas a temperatura de base instantânea como variável de saída.

Todas as funções de ativações utilizadas nesta RNA são do tipo tangente sigmoide e o algoritmo de otimização utilizado para treinar a RNA é o *Levenberg Marquardt backpropagation*.

Feitas estas escolhas, parte dos dados gerados através do ensaio de identificação é utilizada para realizar o treinamento da RNA no software MATLAB[®]. No treinamento, a RNA aprende a replicar o comportamento dinâmico da malha 1, em seguida, outra parte dos dados gerados é usada para validar o modelo da RNA. Por fim, a terceira parte dos dados gerados no ensaio de identificação é utilizada para testar a RNA.

A Figura 6.27 mostra a comparação da resposta da RNA com o experimento.


Figura 6.27 - Comparação da resposta da RNA em relação à resposta experimental da temperatura de base no ensaio da malha 1 fechada.



Fonte: Autor, 2011.

A Figura 6.28 mostra a curva de regressão entre os dados experimentais e os gerados pela RNA. Através deste gráfico fica evidente a capacidade de aprendizagem de uma RNA, pois quanto mais próximo de 1 for o fator R, melhor é o modelo identificado.

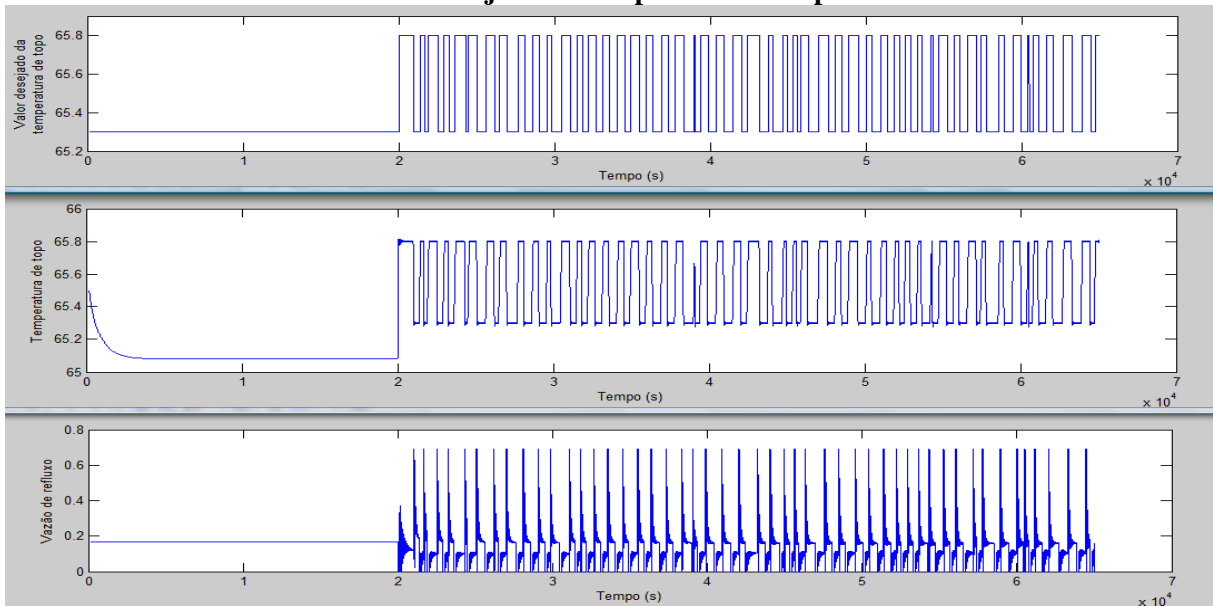
Figura 6.28 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 1 na configuração malha fechada.



Fonte: Autor, 2011.

A Figura 6.29 mostra como é desenvolvido o ensaio de identificação em malha fechada para malha 2. Ao excitar o valor desejado da temperatura de topo, o controlador manipula a vazão de refluxo de forma que a temperatura de topo apresente comportamento semelhante ao desejado.


Figura 6.29 - Resposta do ensaio de identificação em malha fechada com perturbação PRBS no valor desejado da temperatura de topo.



Fonte: Autor, 2011.

A Figura 6.30 mostra como foi desenvolvido o ensaio de identificação em malha fechada para malha 2. Ao excitar o valor desejado da temperatura de topo, o controlador manipula a vazão de refluxo de forma que a temperatura de topo apresente comportamento semelhante ao desejado. Neste ensaio é necessário também separar os sinais a partir do momento que inicia a excitação através do PRBS, que corresponde ao instante de tempo 21000 segundos após a inicialização da operação desta coluna de destilação.

Figura 6.30 - Conjunto de dados selecionados para identificação da malha 2 fechada.



Fonte: Autor, 2011.

Este conjunto de dados é exportado para o aplicativo IDENT. Feitas as escolhas devidas, são realizadas as estimações dos parâmetros dos modelos, cujos resultados são mostrados nas Figuras 6.32, 6.33, 6.34 e 6.35.


O modelo ARX é representado pela equação 6.21 cujos parâmetros $A(q)$ e $B(q)$ são polinômios de quarta ordem representados respectivamente pelas equações 6.22 e 6.23.

$$A(q)y(t) = B(q)u(t) + e(t) \quad (6.21)$$

$$A(q) = 1 - 2.243 q^{-1} + 2.128 q^{-2} - 1.434 q^{-3} + 0.549 q^{-4} \quad (6.22)$$

$$B(q) = 0.006154 q^{-1} - 0.03461 q^{-2} + 0.03021 q^{-3} - 0.002258 q^{-4} \quad (6.23)$$

Figura 6.31 - Comparação da resposta do modelo ARX em relação a resposta experimental da temperatura de topo.



Fonte: Autor, 2011.

O modelo ARMAX é representado equação 6.24 cujos parâmetros $A(q)$, $B(q)$ e $C(q)$ são polinômios de quarta ordem representados respectivamente pelas equações 6.25, 6.26 e 6.27.


$$A(q)y(t) = B(q)u(t) + C(q)e(t) \quad (6.24)$$

$$A(q) = 1 - 0.6861 q^{-1} - 1.082 q^{-2} + 0.2345 q^{-3} + 0.5334 q^{-4} \quad (6.25)$$

$$B(q) = -0.07954 q^{-1} + 0.101 q^{-2} - 0.01036 q^{-3} - 0.01105 q^{-4} \quad (6.26)$$

$$C(q) = 1 + 0.02858 q^{-1} + 0.7021 q^{-2} + 0.2923 q^{-3} + 0.04371 q^{-4} \quad (6.27)$$

Figura 6.32 - Comparação da resposta do modelo ARMAX em relação a resposta experimental da temperatura de topo.



Fonte: Autor, 2011.


O modelo OE é representado pela equação 6.28 cujos parâmetros $B(q)$ e $F(q)$ são polinômios de quarta ordem representados respectivamente pelas equações 6.29 e 6.30.

$$y(t) = [B(q)/F(q)]u(t) + e(t) \quad (6.28)$$

$$B(q) = -0.07954 q^{-1} + 0.101 q^{-2} - 0.01036 q^{-3} - 0.01105 q^{-4} \quad (6.29)$$

$$F(q) = 1 - 0.6861 q^{-1} - 1.082 q^{-2} + 0.2345 q^{-3} + 0.5334 q^{-4} \quad (6.30)$$

Figura 6.33 - Comparação da resposta do modelo OE em relação à resposta experimental da temperatura de topo.



Fonte: Autor, 2011.

O modelo BJ é representado pela equação 6.31 cujos parâmetros $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são polinômios de quarta ordem representados pelas equações 6.32, 6.33, 6.34 e 6.35.

$$y(t) = [B(q)/F(q)]u(t) + [C(q)/D(q)]e(t) \quad (6.31)$$


$$B(q) = -0.07954 q^{-1} + 0.101 q^{-2} - 0.01036 q^{-3} - 0.01105 q^{-4} \quad (6.32)$$

$$C(q) = 1 + 0.01702 q^{-1} + 0.9039 q^{-2} + 0.2285 q^{-3} + 0.2533 q^{-4} \quad (6.33)$$

$$D(q) = 1 - 0.6044 q^{-1} - 0.8196 q^{-2} + 0.05843 q^{-3} + 0.3666 q^{-4} \quad (6.34)$$

$$F(q) = 1 - 0.6861 q^{-1} - 1.082 q^{-2} + 0.2345 q^{-3} + 0.5334 q^{-4} \quad (6.35)$$

Figura 6.34 - Comparação da resposta do modelo BJ em relação à resposta experimental da temperatura de topo.



Fonte: Autor, 2011.

Assim como é feito para malha 1, são calculados os somatórios e as médias dos erros quadráticos de cada modelo. A Tabela 6.6 demonstra os somatórios dos erros e as médias dos erros entre as respostas dos modelos e dos experimentos, o que permite uma comparação de eficiência entre os modelos obtidos através das identificações da malha 2.


Tabela 6.6 - Comparação dos erros dos modelos candidatos a identificação para malha 2 fechada.

Modelo malha 2	ARX	ARMAX	OE	BJ
Somatório do erro quadrático	1678,025	488,3274243	381,1984	376,9654584
Média do erro quadrático	0,038138	0,011098603	0,008664	0,008567591

Fonte: Autor, 2011.

Assim como é feito para malha 1, é utilizado uma RNA para identificar a malha 2 nesta configuração de malha fechada.


Figura 6.35 - Comparação da resposta da RNA em relação à resposta experimental da temperatura de topo.



Fonte: Autor, 2011.

A Figura 6.36 mostra a curva de regressão entre os dados experimentais e os gerados pela RNA. Apesar de haver alguns pontos dispersos da curva de regressão, eles podem ser desprezados frente a quantidade de dados pertencentes a esta amostra.

Figura 6.36 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 2 na configuração malha fechada.



Fonte: Autor, 2011.


6.4 Identificação em Malha Aberta com PRBS

Nesta etapa é testado o PRBS projetado nas etapas anteriores para excitar as malhas 1 e 2 nas respectivas variáveis manipuladas, e não no valor desejado. Desta forma as identificações são realizadas em malha aberta, o que permitirá uma comparação entre as configurações malha aberta e fechada.

Então são realizados os ensaios com PRBS devidamente projetado nas malhas 1 e 2, os resultados destes são mostrados nas Figuras 6.37 e 6.44, respectivamente.

Para identificar a malha 1 a vazão de vapor é perturbada através do PRBS cujo dois níveis lógicos variam em 0,2752 mol/min ou 0,2889 mol/min.

Figura 6.37 - Ensaio de identificação através do PRBS na malha 1 aberta.



Fonte: Autor, 2011.

Com os conjuntos de dados gerados no ensaio de identificação conforme Figuras 6.37 e 6.45, são realizadas as estimativas dos parâmetros dos modelos candidatos à identificação. Os modelos escolhidos como candidatos a identificação em malha aberta são os mesmos modelos usados na identificação em malha fechada, ou seja, RNA, ARX, ARMAX, OE e BJ.

A seguir são mostrados os resultados referentes às identificações da malha 1 na configuração malha aberta.


Um dos resultados das identificações em malha aberta realizadas neste trabalho é o modelo ARX representado pela equação 6.36 cujos parâmetros $A(q)$ e $B(q)$ são polinômios de quarta ordem representados respectivamente pelas equações 6.37 e 6.38.

$$A(q)y(t) = B(q)u(t) + e(t) \quad (6.36)$$

$$A(q) = 1 - 0.9933 q^{-1} - 0.48 q^{-2} - 0.01159 q^{-3} + 0.4849 q^{-4} \quad (6.37)$$

$$B(q) = 0.3034 q^{-1} - 0.003382 q^{-2} - 0.1492 q^{-3} - 0.1483 q^{-4} \quad (6.38)$$

Figura 6.38 - Comparação entre dados experimentais e simulados pelo modelo ARX para malha 1.



Fonte: Autor, 2011.

Outro resultado das identificações em malha aberta realizadas neste trabalho é o modelo ARMAX representado pela equação 6.39 cujos parâmetros $A(q)$, $B(q)$ e $C(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.40, 6.41 e 6.42.


$$A(q)y(t) = B(q)u(t) + C(q)e(t) \quad (6.39)$$

$$A(q) = 1 - 1.981 q^{-1} + 0.9807 q^{-2} \quad (6.40)$$

$$B(q) = 0.3022 q^{-1} - 0.3012 q^{-2} \quad (6.41)$$

$$C(q) = 1 - 1.48 q^{-1} + 0.631 q^{-2} \quad (6.42)$$

Figura 6.39 - Comparação entre dados experimentais e simulados pelo modelo ARMAX para malha 1.



Fonte: Autor, 2011.


O modelo OE elaborado neste trabalho é representado pela equação 6.43 cujos parâmetros $B(q)$ e $F(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.44 e 6.45.

$$y(t) = [B(q)/F(q)]u(t) + e(t) \quad (6.43)$$

$$B(q) = 0.2293 q^{-1} - 0.2289 q^{-2} \quad (6.44)$$

$$F(q) = 1 - 1.989 q^{-1} + 0.9889 q^{-2} \quad (6.45)$$

Figura 6.40 - Comparação entre dados experimentais e simulados pelo modelo OE para malha 1.



Fonte: Autor, 2011.

O modelo BJ é representado pela equação 6.46 cujos parâmetros $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.47, 6.48, 6.49 e 6.50.

$$y(t) = [B(q)/F(q)]u(t) + [C(q)/D(q)]e(t) \quad (6.46)$$


$$B(q) = 0.2293 q^{-1} - 0.2289 q^{-2} \quad (6.47)$$

$$C(q) = 1 - 0.5005 q^{-1} + 0.1407 q^{-2} \quad (6.48)$$

$$D(q) = 1 - 1.958 q^{-1} + 0.9582 q^{-2} \quad (6.49)$$

$$F(q) = 1 - 1.989 q^{-1} + 0.9889 q^{-2} \quad (6.50)$$

Figura 6.41 - Comparação entre dados experimentais e simulados pelo modelo Box Jenkins para malha 1.



Fonte: Autor, 2011.

Assim como é feito nas identificações em malha fechada, nas identificações em malha aberta também é necessário obter parâmetros para quantificar a eficiência dos modelos ARX, ARMAX, OE e BJ. Portanto, são calculados os somatórios e as médias dos erros quadráticos destes modelos em relação ao experimento. A Tabela 6.7 mostra os somatórios dos erros e as médias dos erros entre as respostas dos modelos e dos experimentos, o que permite uma comparação de eficiência entre os modelos obtidos através das identificações da malha 1.

]

Tabela 6.7 - Comparação dos erros dos modelos candidatos à identificação para malha 1 aberta.

Modelo malha 1	ARX	ARMAX	OE	BJ
Somatório do erro quadrático	74,20043	69,20234	26,78586	25,13786
Média do erro quadrático	0,001686	0,001573	0,000609	0,000571

Fonte: Autor, 2011.

Partindo do mesmo ensaio de identificação, é utilizada também uma rede neural artificial para identificar a malha 1 na configuração malha aberta.


A rede utilizada para identificar a malha 1 na configuração malha aberta utiliza o conceito de regressão e tem a vazão de vapor a um passo atrás, a dois passos atrás, e a três passos atrás e a temperatura de base a um passo atrás, a dois passos atrás e a três passos atrás como variáveis de entrada da RNA. Isto implica dizer que esta RNA possui seis variáveis de entrada, logo, tem seis neurônios na camada de entrada.

Esta RNA possui apenas uma camada intermediária com dez neurônios. Como a malha 1 possui apenas uma variável de saída, a RNA tem apenas a temperatura de base instantânea como variável de saída.

Todas as funções de ativações utilizadas nesta RNA são do tipo tangente sigmoide e o algoritmo de otimização utilizado para treinar a RNA é o *Levenberg Marguardt backpropagation*.

A Figura 6.42 mostra a comparação da resposta da RNA com o experimento.

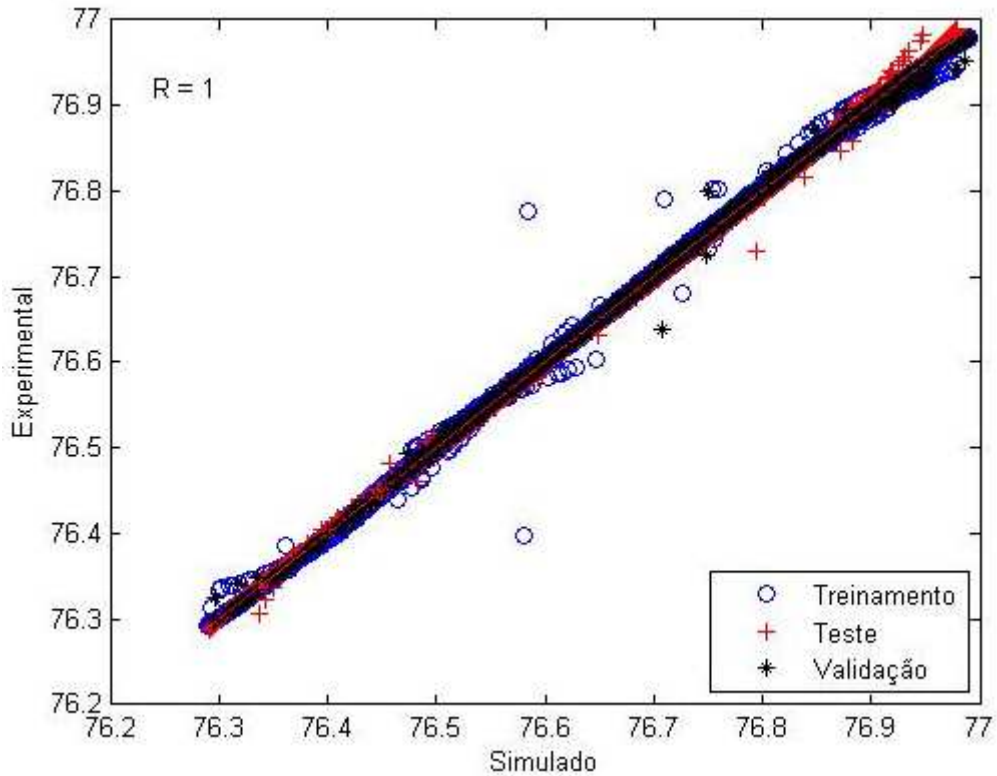
Figura 6.42 - Comparação da resposta da RNA em relação à resposta experimental da temperatura de base no ensaio de malha aberta.



Fonte: Autor, 2011.

A Figura 6.43 mostra a curva de regressão entre os dados experimentais e os gerados pela RNA.


Figura 6.43 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 1 na configuração malha aberta.



Fonte: Autor, 2011.

A Figura 6.44 exibe como é desenvolvido o ensaio de identificação em malha aberta para malha 2. Neste ensaio a vazão de refluxo é perturbada através do PRBS cujos dois níveis lógicos variam em 0,1654 mol/min ou 0,1737 mol/min.

Figura 6.44 - Ensaio de identificação através do PRBS na malha 2 aberta.



Fonte: Autor, 2011.


Assim como é feito na identificação da malha 1 aberta, são realizadas as estimativas dos parâmetros dos modelos candidatos à identificação para malha 2. Nesta etapa é obtido o modelo ARX representado pela equação 6.51 cujos parâmetros $A(q)$ e $B(q)$ são polinômios de quarta ordem representados respectivamente pelas equações 6.52 e 6.53.

$$A(q)y(t) = B(q)u(t) + e(t) \quad (6.51)$$

$$A(q) = 1 - 0.4823 q^{-1} - 0.6209 q^{-2} - 0.1849 q^{-3} + 0.288 q^{-4} \quad (6.52)$$

$$B(q) = -0.01729 q^{-1} - 0.008304 q^{-2} + 0.002277 q^{-3} + 0.0112 q^{-4} \quad (6.53)$$

Figura 6.45 - Comparação entre dados experimentais e simulados pelo modelo ARX para malha 2.



Fonte: Autor, 2011.

Outro resultado das identificações é o modelo ARMAX, que é representado pela equação 6.54 cujos parâmetros $A(q)$, $B(q)$ e $C(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.55, 6.56 e 6.57.


$$A(q)y(t) = B(q)u(t) + C(q)e(t) \quad (6.54)$$

$$A(q) = 1 - 1.986 q^{-1} + 0.9856 q^{-2} \quad (6.55)$$

$$B(q) = -0.01533 q^{-1} + 0.01521 q^{-2} \quad (6.56)$$

$$C(q) = 1 - 1.866 q^{-1} + 0.8936 q^{-2} \quad (6.57)$$

Figura 6.47 - Comparação entre dados experimentais e simulados pelo modelo ARMAX para malha 2.



Fonte: Autor, 2011.


O modelo OE é representado pela equação 6.58 cujos parâmetros $B(q)$ e $F(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.59 e 6.60.

$$y(t) = [B(q)/F(q)]u(t) + e(t) \quad (6.58)$$

$$B(q) = -0.008808 q^{-1} + 0.008808 q^{-2} \quad (6.59)$$

$$F(q) = 1 - 1.996 q^{-1} + 0.9963 q^{-2} \quad (6.60)$$

Figura 6.47 - Comparação entre dados experimentais e simulados pelo modelo OE para malha 2.



Fonte: Autor, 2011.

O modelo BJ é representado pela equação 6.61 cujos parâmetros $B(q)$, $C(q)$, $D(q)$ e $F(q)$ são polinômios de segunda ordem representados respectivamente pelas equações 6.62, 6.63, 6.64 e 6.65.

$$y(t) = [B(q)/F(q)]u(t) + [C(q)/D(q)]e(t) \quad (6.61)$$


$$B(q) = -0.008808 q^{-1} + 0.008808 q^{-2} \quad (6.62)$$

$$C(q) = 1 - 1.658 q^{-1} + 0.7554 q^{-2} \quad (6.63)$$

$$D(q) = 1 - 1.98 q^{-1} + 0.9804 q^{-2} \quad (6.64)$$

$$F(q) = 1 - 1.996 q^{-1} + 0.9963 q^{-2} \quad (6.65)$$

Figura 6.48 - Comparação entre dados experimentais e simulados pelo modelo Box Jenkins para malha 2.



Fonte: Autor, 2011.

Assim como é feito nas identificações anteriores, os cálculos dos somatórios e das médias dos erros quadráticos, estimados a partir da comparação entre os modelos obtidos através das identificações e dos experimentos, são essenciais para comparações e consequentemente escolhas dos modelos candidatos à identificação. A Tabela 6.8 mostra os somatórios e as médias dos erros quadráticos entre as respostas dos modelos e dos experimentos.

Tabela 6.8 - Comparação dos erros dos modelos candidatos a identificação para malha 2 aberta.

Modelo malha 2	ARX	ARMAX	OE	BJ
Somatório do erro quadrático	315,7166	136,0911	0,620735	1,530031
Média do erro quadrático	0,007175	0,003093	1,41E-05	3,48E-05

Fonte: Autor, 2011.

Após observar as Tabelas 6.7 e 6.8, fica evidente que dentre os modelos testados, os que apresentaram melhores resultados foram os modelos BJ para malha 1 e OE para malha 2.

Partindo do mesmo ensaio de identificação mostrado na figura 6.49, é utilizado também uma rede neural artificial para identificar a malha 2 na configuração malha aberta.


A rede utilizada para identificar a malha 2 na configuração malha aberta utiliza o conceito de regressão e tem a vazão de refluxo a um passo atrás, a dois passos atrás, e a três passos atrás e a temperatura de topo a um passo atrás, a dois passos atrás e a três passos atrás como variáveis de entrada da RNA. Isto implica dizer que esta RNA possui seis variáveis de entrada, logo, tem seis neurônios na camada de entrada.

Esta RNA possui apenas uma camada intermediária com dez neurônios. Como a malha 2 possui apenas uma variável de saída, a RNA tem apenas a temperatura de topo instantânea como variável de saída.

Todas as funções de ativações utilizadas nesta RNA são do tipo tangente sigmoide e o algoritmo de otimização utilizado para treinar a RNA é o *Levenberg Marguardt backpropagation*.

A Figura 6.49 mostra a comparação da resposta da RNA com o experimento.


Figura 6.49 - Comparação da resposta da RNA em relação a resposta experimental da temperatura de topo no ensaio de malha aberta.



Fonte: Autor, 2011.

A Figura 6.50 mostra a curva de regressão entre os dados experimentais e os gerados pela RNA.

Figura 6.50 - Curva de regressão entre os dados experimentais e os gerados pela RNA para malha 2 na configuração malha aberta.



Fonte: Autor, 2011.

Após todos estes resultados e discussões todas as ideias serão concluídas no Capítulo 7.

7 CONCLUSÕES

O trabalho aqui apresentado estudou o desempenho dos modelos ARMAX, ARX, BJ, OE e RNA utilizados na identificação da coluna de destilação metanol-água. O sinal de excitação utilizado para perturbar o processo foi o PRBS. Foram avaliados os desempenhos dos modelos em malha aberta e malha fechada para ambas as malhas, ou seja, a malha 1 (temperatura da base da coluna manipulada pela vazão de vapor) e malha 2 (temperatura do topo da coluna manipulada pela vazão de refluxo).

Para o projeto do PRBS é necessário a determinação do tempo de ensaio e o tempo de amostragem. Estes parâmetros determinam a quantidade mínima suficientemente representativa de dados para caracterizar o fenômeno. No entanto o PRBS como o próprio nome estabelece, é um sinal binário pseudoaleatório, ou seja, o conjunto de dados gerados é aleatório obedecendo apenas à faixa de frequência e os níveis lógicos altos e baixos. Atendendo a esta particularidade, uma mesma classe de modelos gerados a partir destes dados apresenta diferentes parâmetros, mas, concordam no desempenho para representar o sistema. Outra conclusão em relação ao PRBS é que apesar deste sinal ser apropriado para identificação em malha fechada, neste trabalho constatou-se que é possível utilizá-lo para identificação em malha aberta.

Na identificação da malha 1 fechada, o modelo linear que apresentou melhor desempenho foi o BJ, em seguida o OE. Os modelos ARMAX e ARX, não apresentaram desempenho satisfatório para representar a malha 1. É importante salientar que durante o ensaio de identificação a variável de processo apresentou oscilações entre 74 °C a 81 °C, ou seja, uma variação de 7 °C. Isto impõe uma limitação no modelo, pois o desempenho quantificado só é garantido para esta faixa operacional.

Na identificação da malha 1 aberta, a sequência de desempenho dos modelos lineares foi BJ, OE, ARMAX e ARX. Neste caso todos estes modelos apresentaram desempenho satisfatório, logo, todos podem ser utilizados para representar a malha 1. A temperatura de base, para malha aberta, apresentou oscilações entre 76,3°C a 77°C, ou seja, uma variação de 0,7 °C.

Ao comparar os resultados das identificações da malha 1 nas duas configurações, aberta e fechada, nota-se que as médias dos erros quadráticos foram bem menores nas

identificações em malha aberta. A questão é que o desempenho do modelo depende das variações da variável de processo durante o ensaio, pois quanto maior as variações desta variável, maiores serão as não linearidades manifestadas.

O desempenho dos modelos escolhidos foram avaliados em percentagem % da média do erro quadrático em relação à variação da variável de processo durante ensaio, verificou-se que, em malha aberta o melhor resultado foi 0,08% referente à identificação utilizando o modelo BJ enquanto que na fechada foi 1,09% referente à identificação utilizando o modelo também BJ.

Mesmo após todos estes resultados favorecendo a identificação em malha aberta, conclui-se que, é mais prudente, seguro e eficaz, para este caso, a realização da identificação em malha fechada. Esta orientação deve-se ao fato que a perturbação na variável de processo foi limitada em malha aberta, pela própria particularidade desta configuração de não haver controle, ou seja, a malha estava sendo operada em manual, e não existia domínio das oscilações na variável de processo, portanto não era possível arriscar oscilações que compromettesse a segurança da planta ou que produzisse produtos fora de especificação, limitando assim os limites no ensaio de identificação. Isto não é verificado nas perturbações em malha fechada, pois quando a perturbação é realizada o controlador tende a controlar esta variável.

Outro aspecto que não pode ser esquecido, é que se espera que o maior intervalo de tempo, estas malhas operem em modo automático, ou seja, em malha fechada. As dinâmicas dos sistemas industriais são bastante influenciadas pelos pontos operacionais e também pela região de frequência que as variáveis oscilam. Portanto, realizar identificação em malha fechada significa excitar o sistema em condições mais próximas do que de fato este passará mais tempo operando, logo o desempenho dos modelos estarão mais relacionados com o comportamento real deste processo.

As RNA's foram os modelos que apresentaram melhor desempenho em relação a todos os casos estudados neste trabalho. Isto se deve a alta capacidade de aprendizado da RNA.

Nos casos estudados neste trabalho foi possível aproximar um sistema não linear através de modelos lineares, porém, pelo fato da RNA ser uma representação não linear, esta

teve maior capacidade de representar estes fenômenos que apresentam comportamento não linear.

A malha 2, cuja variável de processo é a temperatura de topo manipulada pela vazão de refluxo, foi um sistema bastante complicado de controlar e também de realizar o ensaio. Durante o ensaio da malha 2 fechada a variável de processo oscilou de 65,3 °C a 65,8 °C enquanto que a mesma malha aberta oscilou de 65,04 °C a 65,08 °C. Por causa desta pequena variação na variável de processo foi tentado aumentar a amplitude da excitação, porém sinais maiores que estes retiravam esta malha de faixas operacionais permitidas.

Esta limitação nas oscilações permitidas para variável de processo é um fator decisivo, podendo inviabilizar a identificação no caso da malha 2, pois a variação da temperatura de topo pode facilmente ser confundida por ruídos de medição. Mesmo ciente desta dificuldade, foram realizadas as identificações da malha 2 fechada, e a sequência de desempenho dos modelos lineares foram BJ, OE, ARMAX e ARX. Na identificação da malha 2 aberta a sequência de melhores desempenho dos modelos lineares foram OE, BJ, ARMAX e ARX.

Os modelos obtidos neste trabalho que apresentam respostas semelhantes a do processo real podem ser utilizados para simular as duas malhas em estudo a partir de outros dados de entrada, desde que sejam respeitadas as faixas operacionais no qual foram realizados os ensaios de identificação.

A identificação de sistemas dinâmicos mostrou ser uma alternativa bastante interessante e atrativa para obtenção de modelos de processos industriais, pois pouco conhecimento é necessário, o que implica na diminuição do tempo de execução da modelagem. Outra vantagem desta metodologia é o tamanho das equações obtidas, que normalmente será bastante reduzido em relação aos modelos fenomenológicos, o que implica na velocidade de processamento de dados durante simulação do processo em estudo. E principalmente se o objetivo do modelo for implementação em algum Sistema Digital de Controle Distribuído (SDCD) ou Controlador Lógico Programável (CLP), no qual o tempo de processamento e memória podem ser fatores determinantes para aplicações de controles avançados que necessitem do modelo dinâmico do processo.

Para novos pesquisadores que tiverem o interesse de estudar temas semelhantes aos abordados neste trabalho, sugiro que pesquisem outras possibilidades de sinais para excitação

de processos, formas de gerar e implementar o PRBS em sistemas reais e métodos práticos para utilizar os modelos discretos ARX, ARMAX, BJ e OE em controladores adaptativos e ou em controle preditivo baseado em modelo.

REFERÊNCIAS

- AGARWAK, M. Combining neural and conventional paradigms for modeling prediction and control. **International Journal of System Science**, v. 28, n. 1, p. 66-81, 1997. ISSN 0020-7721.
- AGUIRRE, L. A. **Introdução à identificação de sistemas: técnicas lineares e não lineares aplicadas a sistemas reais**. 3. ed. Belo Horizonte: Editora da UFMG, 2007.
- ALARADI, A. A.; ROHANI, S. Identification and Control of a riser-type FCC unit using neural networks. **Computer and Chemical Engineering**, v. 26, p. 401-421, 2002. ISSN 0098-1354.
- ALDRICH, C.; SLATER, M. J. Simulation of liquid-liquid extraction data with artificial neural networks. In: MUJTABA, I. M.; HUSSAIN, M. A. (Ed.). **Application of neural networks and other learning**. London: Imperial College Press, 2001. p. 3-22.
- ANDRADE, C, M, G. **Identificação de processos químicos em malha fechada**. 2000. Tese (Doutorado em Engenharia Química) - Universidade Estadual de Campinas, Campinas, 2000.
- ASSAF, E. M.; GIORDANO, R. C.; NASCIMENTO, C. A. O. Thermal runaway of ethylene oxidation reactors: prevision through neuronal networks. **Computer and Chemical Engineering**, v. 51, n. 11, p. 3107-3112, 1996. ISSN 0098-1354.
- ASSIS, A. J. **Identificação e controle de processos não lineares utilizando redes neurais artificiais**. 2001. Tese (Doutorado em Engenharia Química) - Universidade Estadual de Campinas, Campinas, 2001.
- ASTRÖM, K; NILSON, J. Analysis of a scheme for iterated identification and control. In: IFAC: SYMOSIUM ON SYSTEM IDENTIFICATION, 10th, 1994. Copenhagen. **Proceedings...** Copenhagen, 1994. p. 171-176.
- BARRERAS, M.; SANZ, M. G. Model identification of a multivariable industrial furnace. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 13th, 2003, Rotterdam. **Preprints...** Rotterdam, 2003. p. 449-454.
- BEHESHTI, S.; DAHLEH, M. A. A new information theoretic approach to order estimation problem. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 13th, 2003, Rotterdam. **Preprints...** Rotterdam, 2003. p. 791-796.
- BOLLAS, G. M.; PAPADOKONSTADAKIS, S.; MICHALOPOULOS, J. Using hybrid neural networks in scaling Up na FCC model from pilot to an industrial unit. **Chemical Engineering and Process**, v. 42, p. 697-713, 2003. ISSN: 0255-2701.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis, forecasting and control**. Oakland: Holden-Day, 1970.
- BROSILOW, C.; JOSEPH, B. **Techniques of model based control**. Upper Saddle River: Prentice Hall, 2002.

BULSARI, A. Multivariable control of a linear system using feed-forward neural networks. In: IEEE: CONFERENCE ON CONTROL APPLICATIONS, 2nd, 1983, Vancouver. **Proceedings...** Vancouver, 1993.

CHEN, J. K.; YU, C. C. Optimal input design using generalized binary sequence. **Automatica**, v. 33, p. 2081-2084, 1997. ISSN 0103-1759.

CHEUNG, O. K.; ELSEY, J. I. Building empirical models of process plant data by regression or neural network. In: AMERICAN CONFERENCE, 1992.

COELHO, A. A. R.; COELHO, L. S. **Identificação de sistemas dinâmicos lineares**. Florianópolis: Editora da UFCS, 2004.

CÓNSUL, C. M. D. **Técnicas estatísticas multivariadas para o monitoramento de processos industriais contínuos**. 2002. Tese (Doutorado em Engenharia Química) - Universidade Estadual de Campinas, Campinas, 2002.

CUBILOS, F. A.; LIMA, E. L. Model predictive control based on a hybrid neural model. **Brazilian Journal of Chemical Engineering**, v. 12, n. 4, p. 208-217, 1995. ISSN 0104-6632.

DAYAL, B. S.; MACGREGOR, J. F. Multi-output process identification. **Journal of Process Control**, v. 7, p. 269-282, 1997. ISSN 0959-1524.

DONAT, J. S.; BHAT, N.; MCAVOY, J. Neural net based model predictive control. **The International Journal of Control**, v. 54, n. 6, p. 1453-1468, 1991. ISSN 2005-4092.

DONKELAAR, E. T. V. **Improvement of efficiency in identification and model predictive control of industrial processes**. 2000. Tese (Doutorado em Engenharia Mecânica) - Technische Universiteit Delft, Donkelaar, 2000.

ELMAN, J. L. Finding structure in time. **Cognitive Science**, v. 14, p. 179-211, 1990. ISSN 1939-5086.

FILETI, A. F.; PEREIRA, J. A. F. R. Adaptive and predictive control strategies for batch distillation: development and experimental testing. **Computer and Chemical Engineering**, v. 21, Suppl., p. S1227-S1231, 1997. ISSN 0098-1354.

FORSELL, U.; LJUNG, L. Closed-loop identification revisited. **Automática**, v. 35, p. 1215-1241, 1999. ISSN 0103-1759.

_____; _____. Some results on optimal experiment design. **Automática**, v. 36, p. 749-756, 2000. ISSN 0103-1759.

GEVERS, M. Towards a joint design of identification and control? In: TRENTELMAN, H. L.; WILLEMS, J. C. (Ed.). **Essays on control: perspectives in the theory and its applications**. Cambridge: Birkhäuser, 1993. p. 111-151. (Progress in systems and control theory, 14).

GODFREY, K. R.; TAN, A. H.; BARKER, H. A. A survey of readily accessible perturbation signals. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 13th, 2003, Rotterdam. **Preprints...** Rotterdam, 2003. p. 653-658.

- GOMM, J. B.; EVANS, J. T.; WILLIAMS, D. Development and performance of neural-networks predictive controller. **Control Eng. Practice**, v. 5, n. 1, p. 49-59, 1997. ISSN 0967-0661.
- GROSSBERG, S. Adaptive pattern classification and universal recoding. I: parallel development and coding of neural feature detectors, **Biological Cybernetics**, v.23, p. 121-134, 1976. 1432-0770.
- HENRIQUE, H. M.; LIMA, E. L.; SEBORG, D. E. Model structure determination in neural networks models. **Chemical Engineering Science**, v. 55, p. 5457-5469, 2000. ISSN 0255-2701.
- HJALMARSSON, H. From experiments to closed loop control. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 13th, 2003, Rotterdam. **Preprints...** Rotterdam, 2003. p. 1-14.
- _____; GEVERS, M.; BRUYNE, F. de. For model-based control design, closed-loop identification gives better performance. **Automática**, v. 32, p. 1659-1673, 1996. ISSN 0005-1098.
- HUAMANÍ, I. R. L. **Redes neurais fuzzy aplicadas em aplicadas em identificação e controle de sistemas**. Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Campinas, 2003.
- HUANG, B.; KADALI, R.; ZHAO, X. An investigation into the poor performance of a model predictive control system on an industrial CGO coker. **Control Engineering Practice**, v. 8, p. 619-631, 2000. ISSN 0967-0661.
- JIA, C.; ROHANI, S.; JUTAN, A. FCC unit modeling, identification and model predictive control, a simulation study. **Chemical Engineering and Processing**, 2002. ISSN 0255-2701.
- LAKSHMINARAYANAN, S.; EMOTO, G.; EBARA, S. Closed loop identification and control loop reconfiguration: an industrial case study. **Journal of Process Control**, v. 11, p. 587-599, 2001. ISSN 0959-1524.
- LANDAU, I. D. Identification in closed loop: a powerful design tool (better design models, simpler controllers). **Control Engineering Practice**, v. 9, p. 52-65, 2001. ISSN 0967-0661.
- _____; KARIMI, A. Recursive algorithms for identification in closed loop: a unified approach and evaluation. **Automática**, v. 33, n. 8, p.1499-1523, 1997. ISSN 0005-1098.
- _____; _____. An output error recursive algorithm for unbiased identification in closed loop. **Automática**, v. 33, n. 5, p.933-938, 1997. ISSN 0005-1098.
- LARA, J. M. V. **Identificação de modelos para controle preditivo: aplicação a uma planta de lodos ativos**. 2005. Tese (Doutorado em Engenharia Elétrica) - Universidade Estadual de Campinas, Campinas, 2005.
- LEE, W. S.; ANDERSON, B. D. O.; KOSUT, R. L. A new approach to adaptive robust control. **International Journal of Adaptive Control and Signal Processing**, v. 7, p. 183-211, 1993. ISSN 0890-6327.

LJUNG, L.; GLAD, T. Modelling of dynamical systems. Englewood Cliffs: Prentice-Hall, 1994.

_____. **System identification: theory for the user.** 2nd. Englewood Cliffs: Prentice-Hall, 1999.

KLERK, E.; CRAIG, I. K. Multivariable closed-loop system identification of plants under model predictive control. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 13th, 2003, Rotterdam. **Preprints...** Rotterdam, 2003. p. 431-436.

MACHADO, V. C. **Planejamento de perturbações para a identificação de modelos dinâmicos.** 2004. Dissertação (Mestrado em Engenharia Química) – Universidade Federal do Rio Grande do Sul, Porto Alegre. 2004.

MARGAGLIO, E.; URIA, M.; RODRIGUEZ, J. J. Neural networks for the identification of a three component distillation column. In: CONFERENCE ON DEVICES, CIRCUITS AND SYSTEMS, 1995, Caracas. **Proceeding...** Caracas, 1995.

MCCULLOCH, W.; PITTS, W. A logical calculus of ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115-133, 1943. ISSN 0007-4985.

McFARLANE, R. C.; RIVERA, D. E. Identification of distillation systems: practical. In: LUYBEN, W. L. (Ed.). **Distillation Control.** Van Nostrand Reinhold, 1992. p. 96-139.

MEDEIROS, F. T. P. **Desenvolvimento de um modelo de predição de condições operacionais de altos-fornos siderúrgicos com base em redes neurais artificiais.** 2006. Tese (Doutorado em Engenharia Química) - Universidade Estadual de Campinas) - Campinas, 2006.

MIRANDA, F. C. P. R. **Identificação de sistemas em malha fechada usando controlador preditivo multivariável: um caso industrial.** 2005. Dissertação (Mestrado em Engenharia) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2005.

MONTEIRO, L. H. A. **Sistema dinâmicos.** São Paulo: Livraria da Física, 2002.

MORARI, M.; LEE, J. H. Model predictive control: past, present and future. **Computer and Chemical Engineering**, v. 23, p.667-682, 1999. ISSN 0098-1354.

NAGY, Z.; AGACHI, S.; BODIZS, L. Adaptive neural network model based nonlinear predictive control of a fluid catalytic cracking unit. In: EUROPEAN SYMPOSIUM ON COMPUTER AIDED PROCESS ENGINEERING, 10th Florence. **Proceeding...** Florence: Computer-Aided Chemical Engineering, 2000. p. 235-240.

NARASHIMHAN, S.; SRINIVASAN, R.; RENGASWAMY, R. Multi-objective input signal design for plant-friendly identification. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 13th, 2003, Rotterdam. **Preprints...** Rotterdam, 2003. p. 923-928.

NASCIMENTO, C. A. O.; GUIDICI, R. Neural network based approach for optimization applied to industrial nylon-6,6 polymerization process. **Computer and Chemical Engineering**, v. 22, Suppl., p. S595-S600, 1998. ISSN 0098-1354.

NEVES, C. F. C. Desenvolvimento de uma instalação de separação de gases por adsorção e modelagem do processo. 2000. Tese (Doutorado em Engenharia Química) - Universidade Estadual de Campinas), Campinas, 2000.

OGATA, K. **Engenharia de controle moderno**. 3. ed. Rio de Janeiro: LTC, 2000.

PASADYN, A. J.; QIN, S. J.; VALLE-CERVANTES, S. Closed-loop and open-loop identification of an industrial wastewater reactor. In: AMERICAN CONTROL CONFERENCE, 1999. San Diego. **Proceedings...** San Diego, 1999.

RIVERA, D. E.; FLORES, M. E. Beyond step testing and process reaction curves: Introducing meaningful identification concepts in the undergraduate chemical engineering curriculum. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 12th, 2000, Rotterdam. **Preprints...** Santa Barbara, 2000.

_____. et al. "Plant-friendly" system identification: a challenge for the process industries. In: IFAC: SYMPOSIUM ON SYSTEM IDENTIFICATION, 13th, 2003, Rotterdam. **Preprints...** Rotterdam, 2003. p.917-922.

SANTOS, V. M. L.; CARVALHO, F. R.; SOUZA JUNIOR, M. B. de. Predictive control based on neural networks: an application to a fluid catalytic cracking industrial unit. **Brazilian journal of Chemical Engineering**, v. 17, p. 401-421, 2000. ISSN 0104-6632.

SCHRAMA, R. J. P.; BOSGRA, O. Adaptive performance enhancement by iterative identification and control design. **International Journal of Adaptive Control and Signal Processing**, v. 7, p. 475-487, 1993. ISSN 0890-6327.

SCHVARTZMAN, M. M. A. M. **Metodologia para seleção de adsorventes de zeólita para a separação de gases pelo processo PSA**. 1999. Tese (Doutorado Engenharia Química) - Universidade Estadual de Campinas), Campinas, 1999.

SEBORG, D. E.; EDGAR, T. F.; MELLICHAMP, D. A. **Process dynamics and control**. New York: J. Wiley & Sons, 1989.

SILVA, R.; SBÁRBARO, D.; BARRA, B. A. L. Closed-loop process identification under PI control: a time domain approach. **Industrial & Engineering Chemistry Research**, v. 45, p. 4671-4678, 2006. ISSN 0888-5885.

SMITH, C. A.; CORRIPIO, A. B. **Princípios e prática do controle automático de processo**. 3. ed. Rio de Janeiro: LTC, 2008.

SODERSTROM, T.; LJUNG, L.; GUSTAVSSON, I. Identifiability conditions for linear multivariable systems operating under feedback. **IEEE Transactions on Automatic Control**, p. 837-840, Dec. 1976. ISSN 0018-9286.

SRIDHAR, D. V.; SEAGRAVE, R. C. Process Modeling using stacked neural networks. **Aiche Journal**, v. 42, n. 9, set. 1996. ISSN 1547-5905.

TATIBANA, C.; Kaetsu, D. **Uma introdução às redes neurais**. 2002. Disponível em: <<http://www.din.uem.br/ia/neurais>>. Acesso em: 2 jun. 2011.

TAVARES NETO, Julio I. H. Identificação de sistemas usando uma sequência PRBS com a inclusão da dinâmica da variável de entrada. 2010. Tese (Doutorado em Engenharia Química) - Universidade Federal de Campinas Grande. Campina Grande, 2010.

TSAKALIS, K. S. Performace limitations of adaptive parameter estimation and system identification algorithms in the absence of excitation. **Automática**, v. 32, p. 549-560, 1996. ISSN 0005-1098.

TUGNAIT, J. K.; ZHOU, Y. On closed-loop system identification usind polyspectral analysis given noisy input-output time-domain data. **Automática**, v. 36, p. 1795-1808, 2000. ISSN 0005-1098.

TURNER, P.; MONTAGUE, G.; MORRIS, J. Non Linear and direction-dependent dynamic process modeling using neural networks. **IEE Proceedings - Control Theory and Applications**, v. 143, n. 1, jan. 1996. ISSN 1751-8644.

_____. et al. Neural network model-based predictive controlo of a distillation column – a neural network modeling methodology. **Trans. Inst. MC**. v. 18, n. 1, 1996. ISSN 1439-9776.

VAN DEN HOF, P. M. J. **System identification**: lecture notes. Delft: Delft University of Technology, 2004.

_____; SCHRAMA, R. J. P. Identification for control: closed loop issues. **Automática**, v. 31, p. 1751-1770, 1995. ISSN 0005-1098.

VIEIRA, W. G. et al. Identification and predictive control of a FCC unit using a MIMO neural model. **Chemical Engineering and Processing**, v. 44, p. 855-868, 2005. ISSN 0255-2701.

WERBOS, P. **Beyond regression**: New tools for prediction and analysis n the behavioral sciences. 1974. Tese (Doutorado em Engenharia Química) - Harvard University, Cambridge. Cambridge, 1974.

ZANG, Z., R. R., B.; GEVERS, M. Iterative wieghted least-squares identification and weighted lqg control design. **Automática**, v. 31, n. 11, p.1577-1594, 1995. ISSN 0005-1098.

ZHU, Y. Multivariable process identification for MPC: the asymptotic method and its applications. **Journal of Process Control**, v. 8, p. 101-115, 1998. ISSN 0959-1524.

_____; BUTOYI, F. Case studies on closed-loop identification for MPC. **Control Engineering Practice**, v. 10, p. 403-417, 2002. ISSN 0967-0661.

_____. et al. **Parametric versus nonparametric models in identification for MPC**. Hydrocarbon Processing, 2000.

ZUBEN, F. Von. **Redes neurais aplicadas ao controle de máquina de indução**. 1993. Tese (Mestrado em Engenharia Elétrica) - Universidade Estadual de Campinas), Campinas, 1993.

ANEXO A

```

#####
!
!           SUB-ROTINA PARA GERAÇÃO DO PRBS
#####
!Sincronismo do time com o contador
#####
if (abs(time-bbbbb).lt.0.001) then
bbbb=bbbb+1
contador=contador+1

#####
!Determinação dos valores dos tempos mínimos e máximos de oscilação
!projetados para o PRBS. Onde o tempo mínimo projetado é igual a rbsmin e o
!tempo máximo projetado é igual a rbsmin+rbsmax.
#####

rbsmin=80
rbsmax=720

#####
!Inicialização dos valores de alto e baixo, que são os tempos de duração do
!nível lógico alto e baixo respectivamente. Estes tempos são gerados
!randomicamente limitados pelo tempo mínimo e máximo de projeto. O ua(3)
!representa a vazão de vapor, que, neste exemplo, foi inicializada com nível
!lógico alto. O nível lógico baixo tem amplitude de 0,275175 mol/min e o nível
!lógico alto é 5% acima do nível lógico baixo.
#####

if (contador.lt.1000) then
ua(3)=0.275175+0.275175*5/100
alto=ceiling(rbsmin+rbsmax*random())

```

```
baixo=ceiling(rbsmin+rbsmax*random())
```

```
habilita=0
```

```
acontador=1
```

```
bcontador=1
```

```
endif
```

```
!#####
```

```
! O bcontador é incrementado em sincronismo com contador, e aumenta até  
!igualar a baixo, que é o tempo de duração do nível lógico baixo.
```

```
!#####
```

```
if((contador.ge.999).and.(bcontador.lt.baixo).and.(habilita.lt.1)) then
```

```
ua(3)=0.275175
```

```
bcontador=bcontador+1
```

```
else
```

```
habilita=2
```

```
endif
```

```
!#####
```

```
! O acontador é incrementado em sincronismo com contador, e aumenta até  
!igualar a alto, que é o tempo de duração do nível lógico alto.
```

```
!#####
```

```
if((contador.ge.999).and.(acontador.lt.alto).and.(habilita.ge.1)) then
```

```
ua(3)=0.275175+0.275175*5/100
```

```
acontador=acontador+1
```

```
endif
```

```
!#####
```

```
! Novos valores de alto e baixo são gerados, e zera as variáveis acontador e  
!bcontador, para quando o programa executar um novo loop, não repetir os  
!tempos de duração de níveis lógicos altos e baixos do loop anterior, e sim,  
!determine uma nova condição de forma randômica.
```

```
!#####
```

```
if((contador.ge.999).and.(acontador.ge.alto).and.(bcontador.ge.baixo).and.(acontador.ge.2))
then
alto=ceiling(rbsmin+rbsmax*random())
baixo=ceiling(rbsmin+rbsmax*random())
acontador=0
bcontador=0
habilita=0
endif
!#####
```