



**UNICAMP**

UNIVERSIDADE ESTADUAL DE CAMPINAS  
FACULDADE DE ENGENHARIA QUÍMICA  
ÁREA DE CONCENTRAÇÃO:  
DESENVOLVIMENTO DE PROCESSOS QUÍMICOS

**PROJETO DE CONTROLADORES ADAPTATIVOS  
AUTO-AJUSTÁVEIS**

por

**Adilson José de Assis**  
(Eng<sup>o</sup> Químico - UFU - 1993)

Orientador: Prof. Dr. **Rubens Maciel Filho**

Dissertação de mestrado apresentada à  
Faculdade de Engenharia Química como  
parte dos requisitos exigidos para  
obtenção do título de Mestre em  
Engenharia Química.

CAMPINAS - SÃO PAULO - BRASIL  
MAIO DE 1996



UNICAMP  
BIBLIOTECA CENTRAL

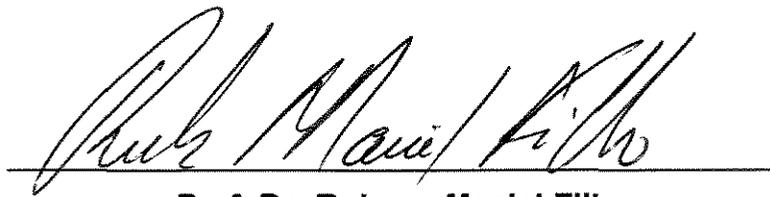
FICHA CATALOGRÁFICA ELABORADA PELA  
BIBLIOTECA DA ÁREA DE ENGENHARIA - BAE - UNICAMP

As76p Assis, Adilson José de  
Projeto de controladores adaptativos auto-ajustáveis /  
Adilson José de Assis.--Campinas, SP: [s.n.], 1996.

Orientador: Rubens Maciel Filho.  
Dissertação (mestrado) - Universidade Estadual de  
Campinas, Faculdade de Engenharia Química.

1. Controle de processos químicos. 2. Estimativa de  
parâmetro. 3. Kalman, Filtragem de. 4. Fermentação  
alcoólica. 5. Destilação. I. Maciel Filho, Rubens. II.  
Universidade Estadual de Campinas. Faculdade de  
Engenharia Química. III. Título.

**Esta versão corresponde à redação final da dissertação de mestrado defendida pelo Engenheiro Químico Adilson José de Assis e aprovada pela comissão julgadora em 27 de maio de 1996.**

A handwritten signature in black ink, reading "Rubens Maciel Filho", is written over a horizontal line. The signature is cursive and stylized.

**Prof. Dr. Rubens Maciel Filho**

Tese defendida e aprovada em 27 de maio de 1996 pela banca examinadora  
constituída pelos professores:



Prof. Dr. Rubens Maciel Filho

Orientador



Prof. Dr. Wagner Caradori do Amaral

FEE - UNICAMP



Prof. Dr. Sílvio Roberto Andrietta

CPQBA - UNICAMP

## AGRADECIMENTOS

Ao professor Rubens Maciel Filho, pela orientação, incentivo e amizade ao longo deste trabalho e à professora Maria Regina Wolf Maciel pelo incentivo e solicitude sempre dispensados no LOPCA/PPDS.

Aos meus pais (Alfredo & Emerenciana), irmãs (Silva, Selma & Marlúcia) e familiares mais próximos, por terem caminhado junto a mim em mais esta etapa de realização pessoal.

Ao CNPq pelo suporte financeiro na forma de bolsa de estudos.

A todos que direta ou indiretamente contribuíram para a minha formação acadêmica em todos os seus níveis e em especial àqueles que têm me ensinado a buscar o propósito da vida.

"Já se disse que as grande idéias vêm ao mundo mansamente, como pombas. Talvez, então, se ouvirmos com atenção, escutaremos, em meio ao estrépito de impérios e nações, no discreto bater de asas, o suave acordar da vida e da esperança. Alguns dirão que tal esperança jaz numa nação; outros, num homem.

Eu creio, ao contrário, que ela é despertada, revivificada, alimentada por milhões de indivíduos solitários, cujos atos e trabalho, diariamente, negam as fronteiras e as implicações mais cruas da história.

Como resultado, brilha por um breve momento a verdade, sempre ameaçada, de que cada e todo homem, sobre a base de seus próprios sofrimentos e alegrias, constrói para todos."

Albert Camus

# SUMÁRIO

**AGRADECIMENTOS**

**SUMÁRIO**

**RESUMO**

## **CAPÍTULO I - INTRODUÇÃO**

1.1 - Motivação e objetivos do trabalho, I.1

1.2 - Organização da Tese, I.2

## **CAPÍTULO 2 - CONCEITOS FUNDAMENTAIS**

2.1 - Introdução, II.1

2.2- Tipos de Controladores

2.2.1 - Revisão Histórica, II.1

2.2.2 - Teoria de Controle Moderno, II.3

2.2.3 - Sistema de Controle Adaptativo, II.4

2.2.4 - Sistema de Controle Preditivo, II.4

2.2.5 - Sistema de Controle Robusto, II.4

2.2.6 - Sistema de Controle Otimizante, II.5

2.2.7 - Sistema de Controle com Aprendizado, II.6

2.3 - Sistema de Controle Adaptativo

2.3.1 - Introdução, II.7

2.3.2 - Definição de Sistema de Controle Adaptativo, II.8

2.3.3 - Revisão Histórica do Controle Adaptativo, II.8

2.3.4 - Estrutura Básica do Controlador Adaptativo, II.11

2.3.5 - Tipos de Controladores Adaptativos

- 2.3.5.1 - Controlador Adaptativo com Ganho Programado, II.15
- 2.3.5.2 - Controlador Adaptativo com Modelo de Referência, II.16
- 2.3.5.3 - Controlador Adaptativo Auto-Ajustável STR, II.17
- 2.4 - O Controlador Adaptativo STR
  - 2.4.1 - Introdução, II.17
  - 2.4.2 - Modelos para o Controlador STR, II.18
    - 2.4.2.1 - Modelo na Forma de Equações à diferenças lineares, II.19
    - 2.4.2.2 - Modelos na forma de variáveis de estado, II.22
  - 2.4.3 - Identificação do Modelo, II.27
  - 2.4.4 - Princípios de Projeto, II.28
  - 2.4.5 - Implementação do STR, II.28
- 2.5 - Controle Adaptativo de Sistemas Não-Lineares, II.29
- 2.6 - Supervisionamento e Coordenação de Controladores Adaptativos
  - 2.6.1 - Supervisionamento dos Controladores Adaptativos, II.31
  - 2.6.2 - Coordenação de Controle Adaptativo, II.33
- 2.7 - Conclusões, II.33

## **CAPÍTULO 3 - ESTIMATIVA DE ESTADOS E PARÂMETROS EM TEMPO REAL**

- 3.1 - Introdução, III.1
- 3.2 - Estimativa de Estados
  - 3.2.1 - Introdução, III.2
  - 3.2.2 - Estimativa de Estados Utilizando o Filtro de Kalman e Filtro de Kalman Estendido, III.3
    - 3.2.3 - Estimativa de Estado Utilizando Observadores de Estado, III.9
- 3.3 - Estimativa de Parâmetros
  - 3.3.1 - Introdução, III.10
  - 3.3.2 - Estimativa de Parâmetros de Modelos Estocásticos Espaço-de-Estados Utilizando Filtro de Kalman Estendido, III.11
  - 3.3.3 - Estimativa de Parâmetros de Modelos Estocásticos na forma de Equações à

Diferenças Lineares, III.15

3.3.3.1 - Algoritmo dos Quadrados Mínimos Recursivos, III.16

3.3.3.2 - Quadrados Mínimos Recursivos com Fator de Esquecimento, III.17

3.3.3.3 - Algoritmo Recursivo Baseado no Filtro de Kalman, III.19

3.4 - **Caso Estudo:** Estimativa Recursiva de Estados e Parâmetros, utilizando Filtro de Kalman Estendido, de um Sistema Fermentativo em Batelada para Produção de Cerveja

3.4.1 - Introdução, III.21

3.4.2 - Modelo Matemático e Parâmetros Utilizados, III.21

3.4.3 - Estimativa de Estados e Parâmetros, III.27

3.4.4 - Resultados e Discussão, III.29

3.5 - Conclusões, III.41

## **CAPÍTULO 4 - PROJETO DE CONTROLADORES ADAPTATIVOS AUTO-AJUSTÁVEIS**

4.1 - Introdução, IV.1

4.2 - Projeto de Sistemas de Controle Moderno, IV.1

4.3 - Controle Adaptativo de Variância Mínima

4.3.1 - O *Self-Tuning Regulator*, IV.3

4.3.2 - O *Self-Tuning Controller*, IV.6

4.4 - Controle Adaptativo Ótimo LQG, IV.9

4.4.1 - Problema Regulador, IV.10

4.4.2 - Problema Servo, IV.13

4.5 - Controle Adaptativo com Imposição de Pólos, IV.15

4.6 - Conclusões, IV.18

## **CAPÍTULO 5 - CONTROLE DE UM PROCESSO CONTÍNUO DE FERMENTAÇÃO ALCÓOLICA EM ESCALA INDUSTRIAL**

5.1 - Introdução, V.1

5.2 - Descrição do Processo Simulado, V.2

5.3 - Modelagem Matemática, Parâmetros e Condições Iniciais do Processo Simulado, V.4

5.4 - Projeto do Sistema de Controle

5.4.1 - Objetivos do Controle, V.11

5.4.2 - Configuração do Sistema de Controle, V.11

5.4.3 - Controle Adaptativo Utilizando Modelo Linear com projeto LQG, V.13

5.4.4 - Controle Adaptativo Utilizando Modelo Não-Linear, V.17

5.4.4 - Controle por Retroalimentação de Estados utilizando Técnicas de Otimização no Projeto do Controlador, V.19

5.5 - Resultados e Discussão

5.5.1 - Controlador Adaptativo LQG, Controlador Adaptativo baseado em Modelo Não-Linear e Controlador PID digital, V.21

5.5.2 - Controlador Projetado utilizando Técnicas de Otimização, V.31

5.6 - Conclusões, V.35

## **CAPÍTULO 6 - CONTROLE DE UMA COLUNA DE DESTILAÇÃO EM BATELADA**

6.1 - Introdução, VI.1

6.2 - Descrição do Processo Simulado, VI.2

6.3 - Modelagem, Parâmetros e Condições Iniciais do Processo Simulado, VI.4

6.4 - Projeto do Sistema de Controle

6.4.1 - Introdução, VI.8

6.4.2 - Objetivos do Controle, VI.9

6.4.3 - Configuração do Sistema de Controle, VI.10

6.4.4 - Controle Adaptativo utilizando Modelo na forma Equações Diferenças, VI.12

6.5 - Resultados e Discussão, VI.14

6.6 - Conclusões, VI.21

## **CAPÍTULO 7 - CONCLUSÕES GERAIS E SUGESTÕES PARA TRABALHOS FUTUROS**

7.1 - Conclusões, VII.1

7.2 - Trabalhos futuros, VII.3

**ANEXO I - LINEARIZAÇÃO DE SISTEMAS NÃO-LINEARES UTILIZANDO SÉRIE DE  
TAYLOR**

**ANEXO II - CONTROLADOR PID DIGITAL**

**ANEXO III - TRABALHOS CIENTÍFICOS PUBLICADOS DURANTE O PERÍODO DE TESE**

**REFERÊNCIAS BIBLIOGRÁFICAS**

***ABSTRACT***

## LISTA DE TABELAS

Tabela 3.1 - Parâmetros reacionais e cinéticos, III.24

Tabela 3.2 - Condições iniciais e Parâmetros do Equipamento, III.25

Tabela 5.1 - Valores dos parâmetros cinéticos do modelo, V.5

Tabela 5.2 - Estado Estacionário de Referência, V.7

Tabela 5.3 - Parâmetros de projeto, V.7

Tabela 5.4 - Valores das variáveis de processo, V.9

Tabela 5.5 - Vazões dos fluidos de reagente e de refrigeração para cada reator, V.9

Tabela 5.6 - Parâmetros do modelo matemático, V.10

Tabela 5.7 - Parâmetros de projeto que devem ser ajustados nas estratégias de controle implementadas,  
V.22

Tabela 5.8 - Vantagens e desvantagens dos controladores implementados, V.34

Tabela 6.1 - Parâmetros da coluna de destilação em batelada simulada, VI.14

Tabela 6.2 - Quantidade de componente 1 recuperada como destilado a uma composição média de 90%,  
VI.19

## LISTA DE FIGURAS

- Figura 2.1 - Estrutura básica de um controlador adaptativo, II.12
- Figura 2.2 - Controlador Adaptativo com ganho programado, II.15
- Figura 2.3 - Diagrama de blocos do sistema de controle adaptativo com modelo de referência, II.16
- Figura 2.4 - Esquema geral do controlador adaptativo STR, II.18
- Figura 2.5 - Sistema dinâmico, II.24
- Figura 2.6 - Malha de controle adaptativo com nível de supervisionamento e controle, II.34
- Figura 3.1 - Concentração de açúcar ( $\text{mol/m}^3$ ), III.26
- Figura 3.2 - Temperatura do meio reacional ( $^{\circ}\text{C}$ ), III.26
- Figura 3.3 - Concentração de etanol e biomassa produzidos ( $\text{mol/m}^3$ ), III.26
- Figura 3.4- Concentração de glicose, maltose e maltotriose, III.30
- Figura 3.5- Concentração de biomassa e etanol, III.30
- Figura 3.6- Temperatura do meio reacional, III.31
- Figura 3.7- Parâmetro estimado, III.31
- Figura 3.8- Covariança do parâmetro estimado, III.31
- Figura 3.9- Tempo de CPU gasto para realizar os cálculos em cada intervalo de amostragem, III.31
- Figura 3.10 - Concentração de glicose, maltose e maltotriose, III.33
- Figura 3.11- Concentração de biomassa e etanol, III.33
- Figura 3.12- Temperatura do meio reacional. Valor incorreto de Q, III.33
- Figura 3.13- Parâmetro estimado quando se utiliza Q superestimado, III.33
- Figura 3.14- Parâmetro estimado para diferentes valores de  $P_0$ , III.34
- Figura 3.15 - Parâmetro estimado quando se utiliza R subestimado, III.35
- Figura 3.16- Concentração de glicose, maltose e maltotriose. Valor incorreto de R, III.36
- Figura 3.17- Concentração de biomassa e etanol. Valor incorreto de R, III.36
- Figura 3.18- Temperatura do meio reacional. Valor incorreto de R, III.36
- Figura 3.19- Parâmetro estimado quando se utiliza R superestimado, III.36
- Figura 3.20- Concentração de glicose, maltose e maltotriose. Tempo de amostragem de 5 min, III.37
- Figura 3.21- Concentração de biomassa e etanol. Tempo de amostragem de 5 min, III.37

- Figura 3.22- Temperatura do meio reacional. Tempo de amostragem de 5 min, III.38
- Figura 3.23 - Parâmetro estimado quando se utiliza tempo de amostragem de 5 min, III.38
- Figura 3.24- Concentração de glicose, maltose e maltotriose. Tempo de amostragem de 1h, III.38
- Figura 3.25- Concentração de biomassa e etanol, III.38
- Figura 3.26- Temperatura do meio reacional. Tempo de amostragem: 1 h. III.39
- Figura 3.27- Parâmetro estimado para tempo de amostragem de 1h, III.39
- Figura 3.28 - Estimativa simultânea de dois parâmetros do modelo (tempo de amostragem de 0.5 h), III.40
- Figura 3.29 - Estimativa simultânea de dois parâmetros do modelo (tempo de amostragem de 0.2 h), III.40
- Figura 3.30 - Estimativa de parâmetro tempo-variante, III.40
- Figura 4.1 - Solução para o problema do controle ótimo LQG (princípio da separação), IV.13
- Figura 5.1 - Esquema geral do processo de fermentação alcoólica contínua, com reciclo de células, V.3
- Figura 5.2 - Esquema do sistema de controle proposto utilizando o *Simulink/Matlab 4.0*, V.19
- Figura 5.3 - Controle PID supervisor da concentração de ART no 1º reator;  $K_c = 4$ ,  $\tau_I = 0,3$  e  $\tau_D = 0,1$ ; tempo de amostragem: 12 min., V.25
- Figura 5.4 - Controle Adaptativo supervisor baseado em modelo não-linear da concentração de ART no 1º reator; vermelho:  $q = 10$ ; azul:  $q = 4$ ; verde:  $q = 2$ ; rosa:  $q = 0,5$ ; tempo de amostragem: 12 min., V.25
- Figura 5.5 - Controle Adaptativo supervisor baseado em modelo não-linear da concentração de ART no 1º reator; azul:  $q = 0,3$ ; vermelho:  $q = 0$ ; tempo de amostragem: 12 min., V.25
- Figura 5.6 - Controle Adaptativo supervisor baseado em modelo não-linear da concentração de ART no 1º reator; influência do tempo de amostragem para um valor fixo de  $q = 2$ : vermelho: 5 min; azul: 12 min; preto: 20 min, V.25
- Figura 5.7 - Controle Adaptativo regulatório baseado em modelo não-linear da concentração de ART no 1º reator; Perturbação em  $S_0 = 198$  g/l e  $K_s = 2$  g/l; tempo de amostragem de 12 min; vermelho:  $q = 4$ ; azul:  $q = 2$ ; verde:  $q = 0,5$ ; preto: PID, V.26
- Figura 5.8 - Controle Adaptativo regulatório baseado em modelo não-linear da concentração de ART no 1º reator; Perturbação em  $S_0 = 198$  g/l e  $K_s = 2$  g/l; influência do tempo de amostragem: vermelho: 5 min; azul: 12 min; preto: 20 min;  $q = 0,5$ , V.26

- Figura 5.9 - Controle Adaptativo regulatório baseado em modelo não-linear da concentração de ART no 1º reator; Perturbação em  $S_0 = 162$  g/l e  $K_s = 2$  g/l; verde:  $q = 4$ ; preto:  $q = 2$ ; vermelho:  $q = 0,5$ ; azul: PID; tempo de amostragem de 12 min, V.26
- Figura 5.10 - Controle Adaptativo supervisorio baseado em modelo não-linear da concentração de ART no 1º reator; tempo de amostragem de 5 min, V.26
- Figura 5.11 - Controle Adaptativo LQG supervisorio da concentração de ART no 1º reator; tempo de amostragem de 12 min; azul: PID; preto:  $Q_{11} = 0,8$ ; verde:  $Q_{11} = 0,1$ ; vermelho:  $Q_{11} = 0,01$ ; V.27
- Figura 5.12 - Controle Adaptativo LQG supervisorio da concentração de ART no 1º reator; tempo de amostragem de 12 min; azul: PID; vermelho:  $Q_{11} = 1,5$ ; V.27
- Figura 5.13 - Controle Adaptativo LQG supervisorio da concentração de ART no 1º reator;  $Q_{11} = 0,1$ ;  $K_I = 50$ ; influência do tempo de amostragem - azul: 20 min; preto: 12 min; vermelho: 5 min, V.27
- Figura 5.14 - Controle Adaptativo LQG regulatório da concentração de ART no 1º reator; Perturbação em  $S_0 = 198$  g/l e  $K_s = 2$  g/l; tempo de amostragem de 12 min; vermelho:  $Q_{11} = 0,05$ ; azul:  $Q_{11} = 0,1$ ; verde:  $Q_{11} = 1$ ; preto: PID, V.27
- Figura 5.15 - Controle Adaptativo LQG regulatório da concentração de ART no 1º reator; Perturbação em  $S_0 = 162$  g/l e  $K_s = 2$  g/l; tempo de amostragem de 12 min; vermelho:  $Q_{11} = 0,05$ ; azul:  $Q_{11} = 0,1$ ; verde:  $Q_{11} = 1$ ; preto:  $Q_{11} = 3$ ; vermelho pontilhado: PID, V.28
- Figura 5.16 - Controle Adaptativo LQG regulatório da concentração de ART no 1º reator; Perturbação em  $S_0 = 198$  g/l e  $K_s = 2$  g/l; influência do tempo de amostragem: verde: 20 min; azul: 12 min; vermelho: 5 min;  $Q_{11} = 0,1$ , V.28
- Figura 5.17 - Controle Adaptativo supervisorio da concentração de ART no 1º reator. Comportamento da variável manipulada; preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$  e  $K_I = 5$ ; 12 min, V.28
- Figura 5.18 - Controle Adaptativo regulatório da concentração de ART no 1º reator. Comportamento da variável manipulada; preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$  e  $K_I = 5$ ; 12 min; perturbação:  $S_0 = 198$  g/l;  $K_s = 2$  g/l, V.28

- Figura 5.19 - Concentração de ART no 4º reator. Controle supervisorio no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min, V.29
- Figura 5.20 - Concentração de ART no 4º reator. Controle regulatório no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_o = 198$  g/l;  $K_s = 2$  g/l, V.29
- Figura 5.21 - Concentração de ART no 4º reator. Controle regulatório no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_o = 162$  g/l;  $K_s = 2$  g/l, V.29
- Figura 5.22 - Concentração de etanol no 4º reator. Controle regulatório no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_o = 162$  g/l;  $K_s = 2$  g/l, V.29
- Figura 5.23 - Concentração de etanol no 4º reator. Controle regulatório no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_o = 198$  g/l;  $K_s = 2$  g/l, V.30
- Figura 5.24 - Concentração de etanol no 4º reator. Controle supervisorio no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; V.30
- Figura 5.25 - Controle Adaptativo supervisorio da concentração de ART no 1º reator. Controlador PID mal sintonizado.  $K_c = 4$ ;  $\tau_i = 0,3$ ;  $\tau_D = 1$ , V.30
- Figura 5.26 - Controle Adaptativo regulatório da concentração de ART no 1º reator. Controlador PID mal sintonizado.  $K_c = 4$ ;  $\tau_i = 0,3$ ;  $\tau_D = 1$ ; perturbação:  $S_o = 198$  g/l;  $K_s = 2$  g/l, V.30
- Figura 5.27 - Concentração de ART (g/l - Eixo Y) no 4º reator versus tempo (h - Eixo X). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada). V.32
- Figura 5.28 - Vazão de mosto ( $m^3/h$  - variável manipulada) versus tempo (h). Resposta do sistema a uma trajetória requerida, V.32
- Figura 5.29 - Concentração de ART (g/l) no 4º reator versus tempo (h). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada) sob perturbação em  $S_o = 198$  g/l,  $T_o = T_{je} = 31$  °C, V.32

- Figura 5.30 - Vazão de mosto ( $\text{m}^3/\text{h}$  - variável manipulada) versus tempo (h). Resposta do sistema a uma trajetória requerida sob perturbação em  $S_o = 198 \text{ g/l}$ ,  $T_o = T_{je} = 31 \text{ }^\circ\text{C}$ , V.32
- Figura 5.31 - Concentração de ART (g/l) no 4º reator versus tempo (h). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada) sob perturbação em  $K_s = \text{g/l}$ , V.33
- Figura 5.32 - Concentração de ART (g/l) no 4º reator versus tempo (h). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada), V.33
- Figura 6.1 - Esquema geral de uma coluna de destilação batelada, VI.2
- Figura 6.2 - Configuração mínima de controle de uma coluna de destilação em batelada. (1 - malha de controle da vazão de vapor; 2 - malha de controle da composição instantânea de destilado; 3 - malha de controle da temperatura da água de resfriamento; 4 - malha de controle do nível do condensador, VI.11
- Figura 6.3 - Fração molar instantânea do componente 1 no destilado  $x$  tempo de batelada (h). Controle PID, VI.15
- Figura 6.4 - Vazão de destilado ( $\text{mol/h}$ )  $x$  tempo de batelada (h). Controle PID, VI.15
- Figura 6.5 - Composição acumulada do componente 1 no destilado  $x$  tempo de batelada (h). Controle PID, VI.16
- Figura 6.6 - Quantidade total de destilado e componente 1 recuperado ( $\text{mol}$ )  $x$  tempo de batelada (h). Controle PID, VI.16
- Figura 6.7 - Fração molar do componente 1 no retervedor  $x$  tempo de batelada (h). Controle PID, VI.16
- Figura 6.8 - Tempo de CPU gasto em cada intervalo de amostragem (s)  $x$  tempo de batelada (h). PC 486, 66 Mz. Volatilidade relativa constante. Controle PID, VI.16
- Figura 6.9 - Fração molar instantânea do componente 1 no destilado  $x$  tempo de batelada (h). Controle STR, VI.17
- Figura 6.10 - Vazão de destilado ( $\text{mol/h}$ )  $x$  tempo de batelada (h). Controle STR, VI.17
- Figura 6.11 - Composição acumulada do componente 1 no destilado  $x$  tempo de batelada (h). Controle STR, VI.17
- Figura 6.12 - Quantidade total de destilado e de benzeno destilado ( $\text{mol}$ )  $x$  tempo de batelada (h). Controle STR, VI.17
- Figura 6.13 - Tempo de CPU gasto em cada intervalo de amostragem (s)  $x$  tempo de batelada (h). PC 486, 66 Mz. Volatilidade relativa constante. Controle STR, VI.18

Figura 6.14 - Composição instantânea do componente 1 no destilado  $x$  tempo de batelada (h). Controle STR, VI.18

Figura 6.15 - Vazão de destilado (mol/h)  $x$  tempo de batelada (h). Controle STR, VI.18

Figura 6.16 - Composição acumulada do componente 1 no destilado  $x$  tempo de batelada (h). Controle STR, VI.18

Figura 6.17 - Quantidade de componente 1 recuperada (mol)  $x$  tempo de batelada (h). Controle STR, VI.19.

## RESUMO

ASSIS, A. J., *Projeto de Controladores Adaptativos Auto-Ajustáveis*, dissertação de mestrado, DPQ - FEQ - UNICAMP Campinas, SP, 1996

Com a necessidade crescente de controladores de processos químicos com desempenho cada vez mais precisos tem sido propostas várias estratégias de controle avançado, como por exemplo o *Controle Adaptativo*, na solução deste problema. No presente trabalho é apresentada uma revisão geral do Controle Adaptativo, das técnicas mais comuns de estimativa de estado e identificação do processo, bem como aplicações dessas técnicas a relevantes processos químicos e biotecnológicos.

Apresenta-se um tratamento sistemático tanto para o Filtro de Kalman como para o Filtro de Kalman Estendido (FKE) quando aplicados na estimativa recursiva de estados e identificação de parâmetros de sistemas estocásticos, utilizando a metodologia espaço-de-estados. Como caso estudo, considerou-se o processo de fermentação de cerveja em batelada. Este processo requer a identificação simultânea dos estados do sistema e dos parâmetros do modelo com finalidades de monitoramento automático do meio reacional. Estudou-se a influência do tempo de amostragem, presença de medidas imprecisas, e condições de convergência do FKE. Resultados obtidos por simulação são apresentados e discutidos.

Neste trabalho também é apresentada uma metodologia geral para o projeto de controladores adaptativos aplicados a reatores biotecnológicos. Tomou-se como caso estudo o processo contínuo de fabricação de etanol em escala industrial. Os controladores adaptativos foram projetados utilizando as estratégias LQG e variância mínima, ambos na formulação espaço-de-estados. Adotou-se um modelo simplificado do processo para finalidades de controle sendo que esse modelo é identificado em tempo real empregando um algoritmo derivado do Filtro de Kalman. Resultados obtidos por simulação mostram que os controladores adaptativos apresentam um melhor desempenho do sistema em malha fechada quando comparado com o desempenho do sistema sob a ação de um controlador clássico PID.

Finalmente, apresenta-se um breve tratamento dos problemas a serem considerados no desenvolvimento de algoritmos de controle avançado do tipo adaptativo para colunas de destilação em batelada.

# CAPÍTULO I

## INTRODUÇÃO

### ***1.1 - Motivação e Objetivos do Trabalho***

O emprego de sistemas de controle automático de processos inclui inevitavelmente o ajuste do conjunto de constantes do controlador (sintonia do controlador) que facilitam a operação do sistema sobre uma larga faixa de condições. Usualmente, as constantes são ajustadas depois que o sistema de controle já foi instalado, utilizando o método da tentativa e erro e consumindo tempo e materiais em quantidade apreciáveis. Se as condições operacionais do processo mudarem significativamente o controlador necessita, então, ser sintonizado novamente de modo a se obter um desempenho satisfatório.

Tem crescido nos últimos anos o interesse pelo controle adaptativo pois este tipo de controlador é capaz de ajustar automaticamente as suas constantes de modo a compensar mudanças no processo ou na sua vizinhança. O controle adaptativo apresenta uma metodologia sistemática e flexível que é adequada ao tratamento de incertezas, não-linearidades e parâmetros que variam com o tempo. Consequentemente, sistemas de controle adaptativo oferecem um imenso potencial no controle de processos complexos onde este seja pouco compreendido e/ou mude de maneira não previsível. Os benefícios práticos da implementação de controle adaptativo têm sido documentados para uma larga gama de aplicações industriais bem sucedidas.

Apesar do fato do controle adaptativo ter sido uma significativa área de pesquisa por aproximadamente trinta anos, somente na década de 70 é que atingiu certa proeminência como uma das mais ativas áreas no campo da engenharia de controle. Atualmente, devido principalmente aos expressivos progressos realizados na teoria e desenvolvimento de algoritmos práticos de controle adaptativo e ao grande avanço da microeletrônica que possibilita uma implementação deste controle de uma maneira simples e barata, esta estratégia de controle tem recebido considerável atenção principalmente pelo seu potencial de aplicação.

A maioria das aplicações referentes ao controle adaptativo têm se restringido a processos lineares e com dinâmica bem comportada. No entanto, a maior parte dos processos químicos apresentam uma dinâmica complexa, altas não-linearidades, parâmetros que variam com o tempo, etc, além do fato da dificuldade de medida de certas variáveis.

Um problema estreitamente relacionado com o controle adaptativo é a estimativa de estados e parâmetros. Quando o modelo do processo não for bem conhecido pode-se utilizar um estimador em linha na determinação de parâmetros de valor desconhecido ou que possam estar variando com o tempo. Do mesmo modo, se alguma variável de interesse não puder ser medida em tempo real ou for conhecida de maneira muito imprecisa, pode-se utilizar uma técnica de estimativa de estado para estimar ou reconciliar o valor de uma medida a partir de um modelo disponível para o processo.

Os objetivos principais deste trabalho podem ser resumidos como sendo:

1. Apresentar as principais técnicas de estimativa de estado e parâmetros para processos modelados tanto na forma espaço-de-estados quanto para modelos na forma de equações diferenças e que apresentam um certo grau de incerteza tanto no processo quanto no instrumento de medida;

Apresentar os principais métodos de projeto de controladores adaptativos disponíveis na literatura que apresentam potencial para uso industrial;

3. Aplicar as técnicas de estimativa de estados e parâmetros e o controle adaptativo projetado utilizando vários critérios a processos representativos da Engenharia Química e comparar seu desempenho com o controlador clássico PID;

## **1.2 - Organização da Tese**

No presente capítulo procurou-se mostrar a importância do controle adaptativo no universo da engenharia de controle e sua grande potencialidade no controle de processos complexos como os que

estão presentes na Engenharia Química.

No Capítulo II apresenta-se uma rápida revisão do controle de processos, destacando-se o surgimento do controle adaptativo como uma necessidade para atuar em sistemas de controle onde há a presença de incertezas. Apresenta-se os diversos tipos de controladores adaptativos enfatizando-se o controlador adaptativo auto-ajustável, que é a estratégia implementada neste trabalho. Cita-se também aplicações do controle adaptativo a diversos processos químicos e, finalmente, apresenta-se duas áreas de recentes pesquisas em controle adaptativo: o controle adaptativo não-linear e o supervisionamento e coordenação de sistemas de controle.

No Capítulo III aborda-se o problema da estimativa recursiva de estados e parâmetros. Apresenta-se o algoritmo do filtro de Kalman (aplicável a sistemas lineares) e sua extensão para sistemas não lineares: o Filtro de Kalman Estendido (FKE), discutindo-se com relativo detalhe a implementação deste estimador, discussão essa raramente abordada na literatura. Ainda na estimativa de parâmetros de modelos equações-diferenças apresenta-se o estimador baseado no método dos quadrados mínimos recursivos. Como caso estudo foi implementado o FKE na identificação de um processo fermentativo em batelada.

O Capítulo IV é relacionado com o projeto de controladores adaptativos. Apresenta-se o procedimento da minimização da variância como critério de projeto e o método baseado no segundo critério de estabilidade de Lyapunov: o controle ótimo LQG. Embora de maneira bem sucinta, apresenta-se o critério de projeto baseado na imposição dos pólos em malha fechada. Para todas as técnicas de projeto é citada uma ampla literatura onde se pode encontrar mais detalhes acerca destas.

No Capítulo V investiga-se o comportamento de um sistema contínuo de fermentação alcoólica em larga escala sob a ação do controle adaptativo. O sistema é constituído de um típico processo industrial de grande porte, composto por quatro fermentadores de mistura, ligados em série e operando com reciclo de células. O controle adaptativo é implementado utilizando a metodologia de modelos na forma espaço-de-estados, sendo o controlador projetado usando os algoritmos LQG e variância mínima. Apresenta-se também um controlador com estados realimentados e projetado utilizando técnicas de

otimização. Os desempenhos de todas as estratégias de controle foram comparados graficamente com o controlador PID digital.

O Capítulo VI é relacionado com o controle adaptativo de uma coluna de destilação em batelada. O controlador foi implementado utilizando um modelo do processo na forma de equações diferenças e projetado utilizando o critério da variância mínima. Os resultados foram comparados com o controlador PID digital.

No Capítulo VII são apresentadas as conclusões gerais desta tese bem como as sugestões para trabalhos futuros.

## CAPÍTULO II

### CONCEITOS FUNDAMENTAIS

#### **2.1 - Introdução**

Este capítulo é relacionado com os controladores com parâmetros adaptativos os quais são baseados em métodos adequados de estimativa de parâmetros, projeto do controlador e algoritmos de controle. Uma rápida revisão histórica do controle de processos é feita, destacando o surgimento do controle adaptativo como uma necessidade para atuar em sistemas de controle onde há a presença de incertezas.

Apresenta-se os tipos de controladores adaptativos, sendo enfatizado o regulador auto-ajustável STR (*Self Tuning Regulator*), que é objeto de estudo mais detalhado neste trabalho. Cita-se também diversas aplicações industriais destes controladores a processos químicos e bioquímicos.

Em seguida apresenta-se duas classes de modelos para controle: os modelos na forma de funções de transferência (equações à diferenças) e os modelos na forma espaço-de-estados, ambos na configuração discreta e aplicáveis a processos SISO e MIMO. Os métodos mais relevantes de estimativa de parâmetros do modelo para controle serão discutidos no Capítulo III e as técnicas de projeto do controlador STR no Capítulo IV.

Os dois últimos itens são relacionados com o controle adaptativo não linear e o supervisionamento e coordenação em sistemas de controle. Embora estes assuntos não sejam objeto de estudo neste trabalho, são apresentados de forma introdutória, pois constituem áreas de recentes e futuras pesquisas na teoria e prática do controle adaptativo.

#### **2.2- Tipos de Controladores**

##### **2.2.1 - Revisão histórica**

“O primeiro trabalho significativo em controle automático foi o de James Watt, que construiu

um controlador centrífugo para controle da velocidade de uma máquina a vapor no século XVIII. Outros trabalhos significativos nos primeiros estágios de desenvolvimento da teoria de controle foram devidos a Minorsky, Hazen e Nyquist, entre muitos outros. Em 1922, Minorsky trabalhou em controladores automáticos para pilotagem de navios e mostrou como poderia ser determinada a estabilidade a partir das equações diferenciais que descrevem o sistema. Em 1932, Nyquist desenvolveu um procedimento relativamente simples para a determinação da estabilidade de sistemas de malha fechada com base na resposta da malha aberta a entradas senoidais em regime permanente. Em 1934 Hazen, que introduziu o termo *servomecanismos* para sistemas de controle de posição, discutiu o projeto de servomecanismos a relé capazes de seguir muito de perto uma entrada variável.” (Ogata, 1993).

“Durante a década de 40, os métodos de resposta em frequência tornaram possível aos engenheiros projetar sistemas de controle em malha fechada lineares que satisfaziam determinados requisitos de desempenho. No período entre o final da década de 40 até o início dos anos 50, o método do lugar das raízes, devido a Evans, foi completamente desenvolvido.” (*idem*)

Os métodos de resposta em frequência e lugar das raízes, que constituem o coração da *teoria de controle clássica*, levam a sistemas que são estáveis e satisfazem a um conjunto de requisitos de desempenho mais ou menos arbitrários. Tais sistemas são, em geral, aceitáveis mas não são ótimos em qualquer sentido expressivo. Desde a década de 50, a ênfase nos problemas de projeto de controle tem sido transferida do projeto de um dos muitos sistemas que funcionam, para o projeto de um sistema ótimo em relação a alguma função objetivo.

Em virtude dos processos (*plantas*) com muitas entradas e saídas tornarem-se cada vez mais complexos, a descrição de um sistema de controle moderno requer um grande número de equações. A teoria de controle clássica, que trata apenas de sistemas de uma entrada e uma saída (**SISO** - *Single-Input, Single-Output*), não é adequada para os sistemas de múltiplas entradas e múltiplas saídas (**MIMO** - *Multiple-Input, Multiple-Output*). Desde 1960, aproximadamente, devido à disponibilidade dos computadores digitais ter tornado possível a análise de sistemas complexos no domínio do tempo, a teoria de controle moderna, baseada na análise e na síntese no domínio do tempo usando variáveis de

estado, tem sido desenvolvida para competir com a complexidade crescente dos processos industriais.

### 2.2.2 - Teoria de controle moderno

“A teoria de controle moderno contrasta com a teoria de controle convencional no sentido de que a primeira é aplicável a sistemas de múltiplas entradas e saídas, que podem ser lineares ou não lineares, invariantes ou variantes no tempo, enquanto que a última é aplicável apenas a sistemas lineares invariantes no tempo e com uma entrada e uma saída. Além disso, a teoria de controle moderno é essencialmente uma abordagem no domínio do tempo, enquanto que a teoria de controle convencional é uma abordagem no domínio da frequência complexa.” (Ogata, 1993).

As principais justificativas para a utilização do Controle Avançado em Controle de Processos Químicos são:

- muitos processos químicos possuem **parâmetros que variam ao longo do tempo** de maneira difícil de ser prevista, como por exemplo a atividade de catalisadores em sistemas catalíticos, o fator de incrustamento em trocadores de calor, o fator de frequência da equação da taxa da reação em processos biotecnológicos, a vazão de alimentação, etc, para citar apenas alguns exemplos;
- **Limitações de ordem instrumental:** a ausência de instrumentos fidedignos e confiáveis para medida de concentração de determinados reagentes, principalmente em meios reacionais biológicos, ou então, em ambientes industriais e com preços acessíveis;
- **Processos não lineares:** as não linearidades são inerentes aos processos químicos e dificultam o desempenho satisfatório de controladores convencionais;
- **Dinâmicas complexas:** alguns sistemas respondem por um curto período de tempo, de modo inverso, a uma perturbação. Isso faz com que o controle clássico tome ações de controle incorretas, prejudicando o desempenho do sistema em malha fechada.

Objetivando ter um melhor desempenho do sistema de controle para estes processos complexos

onde a teoria de controle clássica não é aplicável ou, quando o é, produz resultados insatisfatórios, é que surgiram diversas configurações de controle moderno ou avançado. A seguir discute-se de maneira introdutória algumas destas estratégias de controle.

### 2.2.3 - Sistema de Controle Adaptativo

Para se obter um desempenho satisfatório em um sistema em malha fechada é comum a necessidade de alteração em tempo real das constantes do controlador. Se as condições operacionais ou a vizinhança do processo estão sujeitos a alterações significativas, o controlador necessita ser reajustado para adequá-lo às novas condições de operação e, se estas mudanças ocorrem com certa frequência, necessita-se então de utilizar uma técnica de *Controle Adaptativo* que seja capaz de reconhecer as mudanças no sistema e alterar o controlador de modo a compensar essas mudanças e manter assim um desempenho aceitável.

No item 2.3 será examinado com mais detalhes as características do controle adaptativo.

### 2.2.4 - Sistema de Controle Preditivo

A idéia básica desta estratégia de controle é usar um modelo do processo identificado através de uma perturbação (em geral degrau) aplicada na entrada do processo e utilizar esse modelo para calcular as mudanças futuras da variável manipulada que minimizará um dado índice de desempenho. Uma estratégia bem conhecida de sistema de Controle Preditivo desenvolvida na Shell Oil Company é o DMC (*Dynamic Matrix Control*) que utiliza um modelo interno no domínio do tempo (Luyben, 1989). A idéia básica do controlador preditivo DMC é utilizar um modelo do processo na forma de modelo de convolução, com coeficientes identificados através de uma perturbação degrau ou impulso, em paralelo com a planta, de modo que as saídas futuras são previstas com base nos valores passados das entradas e nas medidas atuais. Uma função objetivo é minimizada em linha no cálculo da variável manipulada.

### 2.2.5 - Sistema de Controle Robusto

As incertezas presentes no modelo interno do controlador é um dos maiores obstáculos ao bom desempenho dos sistemas de controle que utilizam tais modelos internos. Procurando contornar esta dificuldade surgiram várias propostas de *Controle Robusto* sendo uma das mais conhecidas o IMC (*Internal Model Control*) (Morari, 1987). A estrutura de controle IMC é na realidade uma representação alternativa da estrutura de controle *feedback* clássica que revela alguns resultados

teóricos que permitem descrever matematicamente de forma simples o conceito de controle ótimo e suas limitações. A maior contribuição da teoria IMC é a simplicidade com que ela incorpora as restrições associadas à implementação de um controlador ótimo, tais como a estabilidade do sistema, a realização física do controlador, limites físicos de operação das variáveis manipuladas, a robustez na presença de erros na modelagem, dentre outras ( *Wieniewicz, 1994*).

### 2.2.6 - Sistema de controle otimizando

Os sistemas de controle otimizando se apóiam fortemente em técnicas de otimização ( *Voronov e Pospelov, 1984*). De forma geral, a otimização consiste na busca do espaço de parâmetros variáveis para encontrar em função de algum índice de desempenho para determinar onde este é maximizado ou minimizado. Está implícito na afirmação anterior o fato de que um índice de desempenho escalar, que é uma função das saídas do sistema, pode ser definido de tal forma que seu extremo representa o melhor desempenho possível do sistema. Isto é realmente possível e necessário para qualquer sistema de controle adaptativo, por exemplo.

“Os métodos de achar o ponto de operação ótimo são basicamente procedimentos de tentativa e erro. No método de “descida mais abrupta” (*steepest descent*), o gradiente da superfície do índice de desempenho é medido observando-se os efeitos de pequenas mudanças nos parâmetros variáveis. (Isto pode ser chamado método de “sentir a derivada”). O vetor de parâmetro é então movido em direção à máxima inclinação, ou de uma quantidade fixa, ou de uma quantidade determinada pelo gradiente da superfície. Nos locais onde os parâmetros variam lentamente, o gradiente pode ser calculado relativamente com pouca frequência. Em condições de variações mais rápidas dos parâmetros, entretanto, um procedimento conhecido como polarização alternada é superior ao método de sentir a derivada. Com polarização alternada, o sistema nunca é operado na condição ótima, mas operado alternadamente a uma distância fixa em ambos os lados do ótimo calculado, e um novo ótimo é calculado a partir da diferença nos valores do índice de desempenho.

Provavelmente a maior vantagem do método do controle otimizando é que não se colocam restrições na planta. A planta pode ser não linear, de múltipla entrada e múltipla saída, variante no tempo, etc. Uma grande dificuldade deste método de otimização é que ainda não se determinou nenhum método satisfatório para discriminar extremos locais. Portanto, esta abordagem é útil para qualquer

processo físico cuja superfície de desempenho tem um único ótimo e cujas variações são lentas o suficiente para que o sistema de controle se acomode a elas.” (Ogata, 1993)

### 2.2.7 - Sistemas de Controle com Aprendizado

Uma diferença significativa entre um operador humano treinado e um controlador clássico ou avançado é que o operador humano reconhece entradas familiares e pode usar suas experiências passadas aprendidas para compensar alterações no processo. Sistemas de controle adaptativo, por exemplo, são projetados para modificar o sinal de controle à medida que o meio externo ao sistema muda de tal forma a manter um desempenho ótimo.

Um sistema que é capaz de reconhecer características e padrões familiares de uma situação e que usa suas experiências passadas aprendidas para se comportar de uma forma ótima é chamado de um *sistema com aprendizado*.

Um sistema com aprendizado é um sistema de nível superior ao do sistema de controle (moderno ou avançado). O espaço de todos os sistemas de controle pode ser dividido em quatro níveis básicos de hierarquia:

1. Malha aberta
2. Malha fechada
3. Malha de controle moderno ou avançado
- Malha de aprendizado

onde cada nível é sensível a um índice de desempenho ou erro de controle medido no próximo nível mais baixo e onde existirão níveis mais altos do que o quarto, para ambientes mais complexos.

Um sistema com aprendizado respondendo a uma situação familiar não vai requerer novamente a identificação do sistema. A abordagem para o projeto de tal sistema é a de “ensinar” ao sistema qual a melhor escolha para cada situação. Uma vez que o sistema aprendeu a lei de controle ótimo para cada situação possível ele pode operar perto da condição ótima, independentemente das alterações nas condições operacionais ou internas do processo.

Um sistema com aprendizado, quando sujeito a uma nova situação, aprende como se comportar através de um método adaptativo. Se o sistema é sujeito a uma mesma situação que aprendeu antes ele reconhecerá isto e se comportará de forma ótima sem ter que passar pelo mesmo método adaptativo. Modelos de comportamento humano que estão sendo desenvolvidos por muitos pesquisadores proverão, sem dúvida, resultados úteis para aplicações em sistemas com aprendizado.

### **2.3 - Sistema de Controle Adaptativo**

Após uma breve apresentação das principais estratégias de controle moderno será discutido mais detalhadamente neste item o controle adaptativo, incluindo seus tipos e modelos do processo requeridos.

#### **2.3.1 - Introdução**

Nos últimos anos o interesse em sistemas de controle adaptativos aumentou rapidamente junto com o interesse e o progresso em robótica e outros campos de controle. O termo *sistema adaptativo* tem uma variedade de significados específicos, mas normalmente implica que o sistema é capaz de se ajustar à mudanças, venham estas mudanças de dentro do sistema ou de fora dele. Este conceito é de muito interesse para o projetista de sistema pois um sistema altamente adaptativo, além de se acomodar a mudanças ambientais, também se acomodaria a erros de projeto de engenharia e compensaria possíveis falhas ou incertezas moderadas de componentes secundários do sistema, aumentando portanto a confiabilidade deste.

Na maioria dos sistemas de controle com realimentação pequenos desvios nos valores dos parâmetros em relação aos seus valores de projeto não causarão grandes problemas na operação normal do sistema. Entretanto, se os parâmetros da planta variam com mudanças ambientais ou mesmo com mudanças internas o sistema de controle pode deixar de apresentar uma resposta satisfatória nessas novas condições. Em certos casos, grandes variações de parâmetros da planta podem até causar instabilidade no sistema de controle.

Se a função de transferência ou a equação de estado da planta puderem ser identificadas continuamente pode-se compensar variações da função de transferência ou da equação de estado da planta simplesmente variando os parâmetros ajustáveis do controlador e, desta forma, obter um

desempenho satisfatório do sistema sob várias condições ambientais. Tal abordagem adaptativa é bastante útil para lidar com problemas onde a planta é normalmente exposta a ambientes variáveis de tal forma que parâmetros da planta mudam de tempos em tempos. Como essas mudanças não são previsíveis na maioria dos casos práticos um controlador de parâmetros fixos ou um controlador variante no tempo, previamente programado, não pode resolver o problema.

### 2.3.2 - Definição de sistemas de controle adaptativo

A adaptação é uma característica fundamental dos organismos vivos, pois eles tentam manter o equilíbrio fisiológico diante de condições ambientais variantes. Uma abordagem para o projeto de sistemas adaptativos é então considerar os aspectos adaptativos do comportamento humano ou animal e desenvolver sistemas que se comportem aproximadamente de forma análoga.

Há diferentes definições de sistemas de controle adaptativo atualmente em uso na literatura. O caráter um tanto vago da maioria das definições e classificações de sistemas adaptativos é devido à grande variedade de mecanismos através dos quais a adaptação pode ser conseguida.

O “**Controle Adaptativo** é uma estratégia que aplica uma técnica de identificação de sistemas para obter um modelo do processo e sua vizinhança a partir de dados experimentais de entrada e saída e usa esse modelo para projetar o controlador. Os parâmetros do controlador são ajustados durante a operação da planta na medida em que os dados disponíveis para identificação aumentam” (Sastry, 1989).

Alternativamente, tal sistema pode continuamente medir seu próprio desempenho de acordo com um dado índice de desempenho e modificar, se necessário, seus próprios parâmetros de tal forma a manter o desempenho ótimo independentemente das mudanças ambientais.

### 2.3.3 - Revisão Histórica do Controle Adaptativo

A teoria de controle adaptativo teve seu início na década de 50, “motivada pelo problema do projeto de pilotos automáticos em aeronaves operando em uma larga faixa de velocidades e altitudes. O objetivo de tal sistema de controle era projetar um controlador com ganho fixo, ou seja, um piloto

automático, que fosse insensível às grandes variações dos parâmetros. No entanto, observou-se que um simples ganho constante não era suficiente para tal tarefa. Em consequência deste fato adotou-se uma estratégia em que o ganho do controlador variava de acordo com algumas medidas auxiliares como, por exemplo, a medida da velocidade do ar. Com este sistema funcionando tentou-se utilizar uma estratégia mais avançada em que se usava um modelo de referência, embora ainda de maneira rudimentar. O objetivo deste procedimento era construir um controlador auto-ajustável o qual produzia uma função de transferência em malha fechada que seguia um modelo prévio. Vários esquemas de auto-ajuste dos parâmetros do controlador foram propostos, tais como as regras de sensibilidade e a regra conhecida como MIT, que funcionavam bem sob certas condições. Finalmente, *Kalman (1958)* apresentou um tratamento conceitual dos controladores auto-ajustáveis gerais com identificação explícita dos parâmetros de um modelo linear com uma entrada e uma saída e o uso desta estimativa de parâmetros para atualizar um controlador linear quadrático ótimo.

A década de 60 foi marcada por um importante desenvolvimento na teoria de controle, particularmente, no controle adaptativo. A teoria da estabilidade de Lyapunov foi firmemente estabelecida como uma ferramenta importante no estudo da estabilidade de sistemas de controle adaptativo. O controle estocástico teve avanços gigantescos com a compreensão da programação dinâmica com os trabalhos de Bellman e outros. Os esquemas de aprendizado propostos por Tsytkin, Feldbaum e outros, foram reconhecidos por terem todos raízes em uma única classe de equações: as equações recursivas. A identificação de sistemas (*off-line*) foi extensivamente pesquisada e compreendida. Ademais, *Parks (1966)* achou um caminho para reescrever as leis de atualização (*update laws*), propostas na década de 1950, para esquemas de modelo de referência, de modo a permitir a prova da convergência de seu controlador.

Na década de 1970, devido ao trabalho de vários grupos de pesquisadores, apresentou-se provas completas de estabilidade para vários esquemas adaptativos. Provas para estabilidade de sistemas modelados na forma espaço-de-estados, baseadas no critério de Lyapunov e aplicadas a controladores com modelo de referência foram publicadas por *Narendra et al. (1980)* e por *Morse (1980)*. No final da década de 1970, apareceram as provas para modelos na forma entrada/saída nos trabalhos de *Egardt (1979)* e *Landau (1979)*. Provas de estabilidade em tempo discreto para o caso determinístico e

estocástico (devido aos trabalhos de *Goodwin et al., 1980*) também apareceram nesta época e foram continuados no livro-texto de *Goodwin & Sin (1984)*. Este período foi, então, marcado pela culminância no desenvolvimento analítico do controle adaptativo nos últimos vinte anos.

Com os desenvolvimentos teóricos efetuados nas décadas precedentes, a década de 80 foi a década do exame crítico e avaliação. *Rohrs et al. (1982)*, mostraram que as condições sob as quais foi provada a estabilidade dos esquemas adaptativos eram muito sensíveis à presença de dinâmicas não modeladas. Isto provocou a pesquisa na área da robustez dos controladores adaptativos: um reexame das condições sob as quais os controladores adaptativos eram, pelo menos, iguais aos controladores de ganho fixo; o desenvolvimento de ferramentas para a análise do comportamento transiente dos algoritmos adaptativos e a atenção na implementação dos algoritmos na prática (reatores, manipuladores robóticos e sistemas de direcionamento de navios, para citar apenas alguns). A implementação das leis não lineares inerentes ao controle adaptativo foi imensamente facilitada pelo grande desenvolvimento que a microeletrônica sofreu e hoje pode-se até falar em *chips* particulares para controle adaptativo. Com todo este desenvolvimento e pesquisa efetuados, o interesse industrial na utilização do controle adaptativo tem aumentado continuamente.

Alguns livros recentes sobre estimativa recursiva, a qual é uma importante parte do controle adaptativo, são por exemplo, *Eykhoff (1974)*, *Goodwin & Payne (1977)*, *Ljung & Soderstrom (1983)* e *Ung (1987)*. Alguns livros recentes relacionados com a teoria do controle adaptativo: *Landau (1979)*, *Art (1979)*, *Ioannou & Kokotovic (1984)*, *Goodwin & Sin (1984)*, *Anderson et al. (1986)*, *Kumar & Varaiya (1986)*, *Polderman (1988)* e *Caines (1988)*. Revisões de aplicações do controle adaptativo são dadas por *Harris & Billings (1981)*, *Narendra & Monopoli (1980)* e *Unbehauen (1980)*" (*Sastry, 1989*). *Åström (1983)* e *Åström et al. (1977)* fazem referências à aplicações no controle da indústria de cimento, reatores químicos, trocadores de calor, controle de pH. *Seborg et al. (1986)* cita exemplos de aplicações experimentais de controladores adaptativos projetados utilizando vários critérios a diversos processos químicos. Além destas, outras aplicações incluem o controle adaptativo de reatores de leito fixo (*Sørensen et al., 1980a e 1980b; McDermott et al., 1986; Maciel Filho, 1989; Chen & Sun, 1991*), secagem de fosfato (*Najim et al., 1982*), reatores de polimerização (*Tzouanas & Shah, 1989; Defaye et al., 1993*), processo fermentativo com substrato sólido (*Sargantanis & Karim, 1994*) e cristalizadores

(Rohani & Bourne, 1990). As aplicações a biorreatores serão citadas no Capítulo V e à colunas de destilação no Capítulo VI.

Apesar do grande número de publicações sobre controle adaptativo, não há ainda, até o momento, um tratamento unificado completo, objetivo e claro, acerca dos tipos de modelos usuais, métodos de estimativa de parâmetros, metodologia de projeto do controlador, etc.

### 2.3.4 - Estrutura Básica do Controlador Adaptativo

A estrutura básica de um controlador adaptativo está relacionada com as funções básicas que o

1. Identificação das características dinâmicas do processo;
2. Decisão ou projeto do controlador, baseado no modelo identificado e
3. Modificação ou atuação baseada na decisão tomada.

Cada função gera um bloco que juntos formam a estrutura básica do controlador adaptativo.

Se a planta é conhecida apenas imperfeitamente, talvez por causa de parâmetros variando no tempo de forma não previsível ou em virtude dos efeitos de mudanças externas nas características dinâmicas da planta, então a identificação inicial, a decisão e os procedimentos de modificação não serão suficientes para minimizar (ou maximizar) o índice de desempenho. Torna-se necessário realizar estes procedimentos continuamente ou a intervalos de tempo definidos, dependendo de quão rapidamente os parâmetros da planta estão mudando. Este constante “reprojeto”, ou auto-organização do sistema para compensar as mudanças imprevisíveis na planta, é o aspecto do desempenho normalmente considerado ao se definir um sistema de controle adaptativo.

Estes procedimentos podem ser resumidos em:

- i) projetar o controlador como se os parâmetros conhecidos fossem verdadeiros;
- ii) estimar em tempo real os parâmetros e/ou os estados;
- iii) ajustar continuamente o controlador com as estimativas correntes.

A estrutura básica de um controlador adaptativo é mostrada na Figura 2.1.

A seguir, discute-se com algum detalhe as três funções: identificação, decisão e modificação.

**Identificação das características dinâmicas do processo.** As características dinâmicas da planta devem ser medidas e identificadas continuamente ou, pelo menos, muito frequentemente. Isto deve ser conseguido sem afetar a operação normal do sistema. Para identificar as características de um sistema, deve-se fazer um teste e analisar os resultados. Para um sistema de controle isto implica a imposição de um sinal de controle na planta e a análise da resposta. A identificação pode ser feita a partir de dados de operação normal da planta ou pelo uso de sinais de teste tais como os sinais senoidais de baixa amplitude ou de vários sinais estocásticos de pequena amplitude. Na prática, a aplicação direta

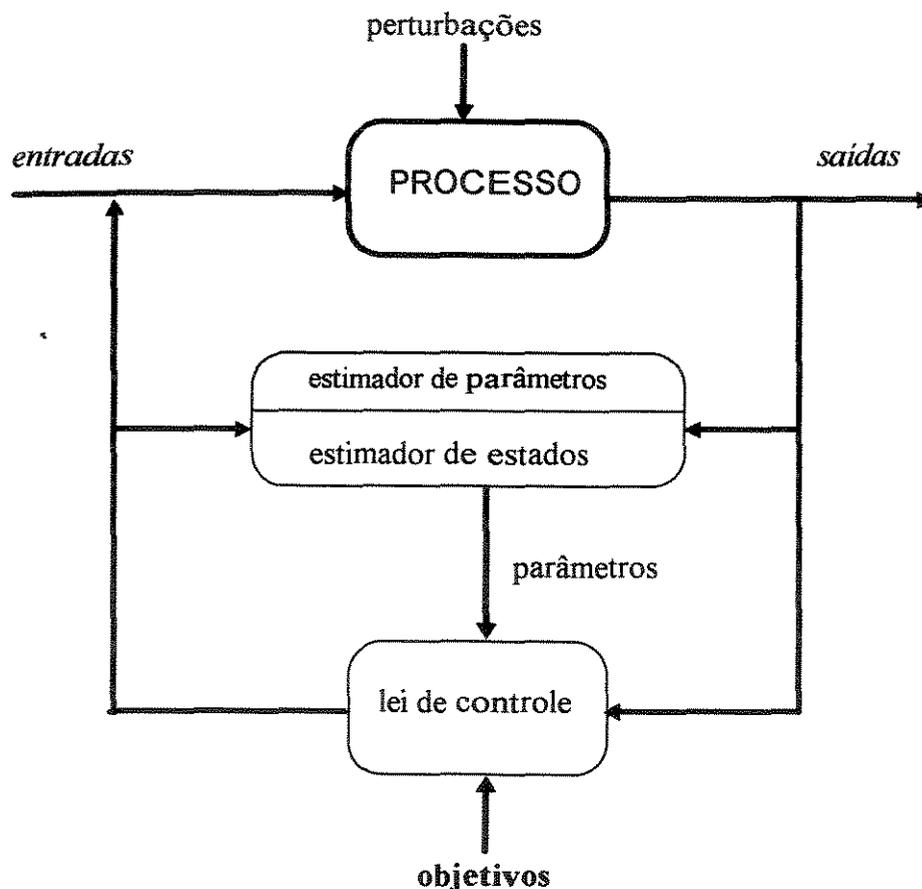


Figura 2.1 - Estrutura básica de um controlador adaptativo (Goodwin & Sin, 1984).

de entradas em degrau ou impulsivas não são realizadas com facilidade. Exceto em certos casos especiais, a planta estará em operação normal durante o teste, de tal forma que os sinais de teste

impostos não devem perturbar as saídas normais; além do mais, entradas normais e ruído no sistema não devem perturbar e confundir o teste. As entradas normais são ideais como sinais de teste, uma vez que não se encontra as dificuldades de saídas não desejadas ou entradas perturbadas. Entretanto, a identificação com entradas normais só é possível quando elas têm características de sinal convenientes (banda, amplitude, etc) para a identificação adequada.

Os sinais de teste estocásticos são bastante convenientes em certas aplicações. Usando técnicas de correlação cruzada pode-se analisar a saída como uma função da entrada estocástica para determinar as características da resposta. Com uma entrada estocástica, a energia de excitação se espalha sobre uma banda de frequências fazendo com que o efeito seja tolerável. Além disso, já que o dispositivo de cálculo da correlação cruzada pode ser projetado para correlacionar rigorosamente entradas e saídas, o nível do sinal de teste pode ser mantido baixo.

A identificação não pode demorar muito, pois, caso contrário, podem ocorrer novas variações dos parâmetros da planta. O tempo de identificação deve ser suficientemente curto comparado com a taxa de mudança no sistema. Com o tempo de identificação limitado, geralmente é difícil identificar a planta completamente; o melhor que se pode esperar é apenas uma identificação parcial.

É importante notar que nem todos os sistemas adaptativos requerem uma identificação de forma explícita. Alguns sistemas já foram identificados a ponto de a medida do valor do índice de desempenho poder indicar que parâmetros do controlador devem ser modificados. Isto é, o sistema é muito bem conhecido de tal forma que uma medida do índice de desempenho completa a identificação.

Por outro lado, se a identificação da planta é muito difícil, deve-se medir diretamente o índice de desempenho e construir um controlador adaptativo baseado nele. Se não for solicitada a identificação e a adaptabilidade é baseada apenas em medidas do índice de desempenho do controlador, o sistema de controle é chamado sistema de controle otimizante. Como é obtida uma auto-organização usando-se este método, considera-se tais sistemas ainda como adaptativos.

A dificuldade de fazer uma identificação realística dependerá de quanta informação requer-se

sobre a planta e da quantidade de conhecimento prévio desta. Em geral, estes serão também os fatores que determinarão o tipo da abordagem de identificação ou uma busca direta no espaço de parâmetros do controlador em função do índice de desempenho, que é discutido mais adiante sob o título de sistemas de controle otimizantes.

**Decisão baseada na identificação da planta.** Decisão se refere aqui a uma decisão baseada nas características da planta que foram identificadas e no valor calculado do índice de desempenho.

Uma vez que a planta foi identificada ela é comparada com as características ótimas (ou desempenho ótimo) e, então, uma decisão deve ser tomada de como os parâmetros ajustáveis (características do controlador) devem ser variados para manter um desempenho ótimo. A decisão é tomada por um computador.

**Modificação baseada na decisão tomada.** Esta etapa consiste na modificação dos sinais de controle de acordo com os resultados das etapas anteriores de identificação e de decisão. Na maioria dos casos a decisão e a modificação são conceitualmente uma única operação, com a modificação consistindo em um meio de mecanizar a transformação de um sinal de saída de decisão em um sinal de controle (a entrada da planta).

Este sinal de controle, o sinal de entrada para a planta, pode ser modificado de duas formas. O primeiro método é o de ajustar os parâmetros do controlador para compensar as mudanças na dinâmica da planta. Isto é chamado modificação do parâmetro do controlador. O segundo método é o de sintetizar o sinal de controle ótimo baseado na função de transferência da planta ou na equação de estado da planta, no índice de desempenho e na resposta transitória desejada. Isto é chamado síntese do sinal de controle.

A escolha entre a modificação de parâmetros do controlador e a síntese de sinal de controle é primordialmente de *hardware*, uma vez que os dois métodos são conceitualmente equivalentes. Quando a confiabilidade é muito importante, como em aplicações aeroespaciais, o uso da adaptação por mudança de parâmetros é frequentemente favorecido ao invés da síntese de sinal de controle. Isto

acontece porque o sistema pode operar mesmo após a falha da malha adaptativa se o sinal de controle não é inteiramente dependente da porção adaptativa do sistema (Ogata, 1993).

### 2.3.5 - Tipos de Controladores Adaptativos

Existem, basicamente, três classes de controladores adaptativos: ganho programado (*gain scheduler*), modelo de referência e regulador auto-ajustável, que são descritos a seguir.

#### 2.3.5.1 - Controlador Adaptativo com Ganho Programado

Uma das primeiras e mais intuitivas abordagens para controle adaptativo é o ganho programado. Embora esta classe de controladores não obedeça integralmente a definição apresentada no item 2.3.2, ela foi aqui incluída por ser importante do ponto de vista conceitual e, principalmente, histórico. A idéia desta técnica é achar uma variável auxiliar do processo (outra que não seja a saída da planta usada na realimentação) que se correlacione bem com as suas mudanças dinâmicas. É possível então compensar as variações dos parâmetros da planta pelas mudanças nos parâmetros do regulador como funções das variáveis auxiliares. Isto é ilustrado na Figura 2.2.

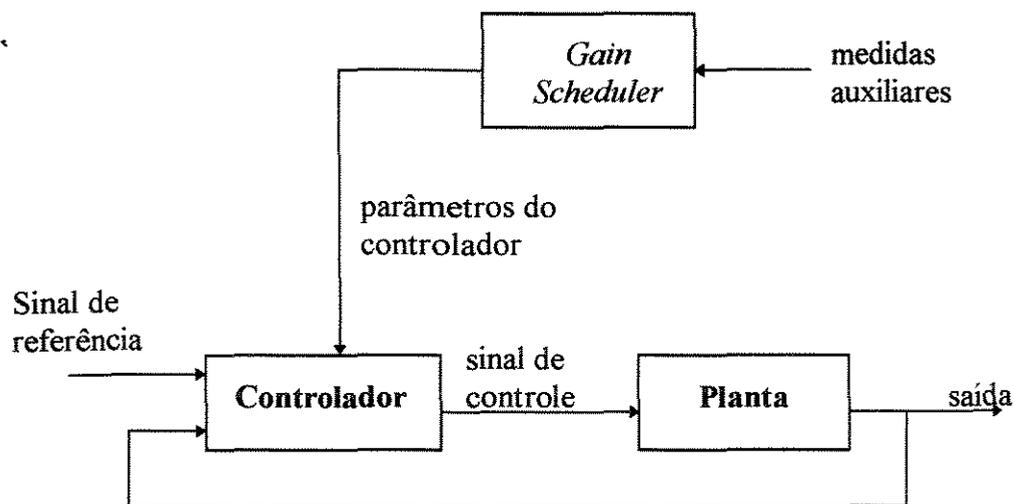


Figura 2.2 - Controlador Adaptativo com ganho programado (Åström & Wittenmark, 1989).

A vantagem do controlador de ganho programado é que os parâmetros podem ser alterados rapidamente (tão rápido quanto a velocidade da medida auxiliar) em resposta à mudanças na dinâmica



que é constituído por um controlador e pelo processo. Os parâmetros do controlador são ajustados por um ramo externo, de tal modo que o erro entre a saída do modelo  $y_m$  e a saída do processo  $y$ , seja pequeno. Necessita-se de um mecanismo de ajuste tal que o erro seja reduzido a zero simultaneamente com a garantia de estabilidade do sistema sendo esta a grande dificuldade de implementação desta estratégia de controle.

Maiores detalhes acerca dos tipos de controle adaptativo descritos anteriormente podem ser encontrados em *Åström (1983)* e *Åström & Wittenmark (1989)*.

### **2.3.5.3 - Controlador Adaptativo Auto-Ajustável STR**

Além do controlador adaptativo com ganho programado e do controlador adaptativo com modelo de referência, existe uma terceira maneira de implementar o controle adaptativo: é o Regulador Auto-Ajustável (*Self Tuning Regulator - STR*), que será discutido, com detalhes, no próximo item.

## **2.4 - O Controlador Adaptativo STR**

### **2.4.1 - Introdução**

Este método de projeto pode ser sumarizado por uma estrutura de controle e uma relação entre os parâmetros da planta e os parâmetros do controlador. Desde que os parâmetros da planta não são conhecidos eles são obtidos usando um algoritmo recursivo de identificação de parâmetros. Os parâmetros do controlador são então obtidos a partir dos parâmetros estimados do processo, considerando que estes parâmetros são os verdadeiros parâmetros. Este é o chamado princípio da equivalência. A Figura 2.4 mostra um esquema geral do STR.

Assume-se uma separação explícita entre a etapa de identificação e controle em contraste com a metodologia anterior. A metodologia auto-ajustável foi proposta originalmente por *Kalman (1958)* e popularizada por *Åström & Wittenmark (1973)* que inicialmente propuseram um controlador para um processo de uma entrada e uma saída, com um modelo com parâmetros constantes, um estimador utilizando mínimos quadrados recursivos e projeto que minimizava a variância da saída.

O controlador é chamado de auto-ajustável (*self tuning*), devido à sua habilidade em ajustar seus

próprios parâmetros e é constituído por dois ramos: um interno constituído de um controlador convencional, mas com parâmetros variáveis, e outro ramo externo composto por um identificador e uma etapa de projeto (representando o projeto em tempo real do controlador utilizando os parâmetros identificados também em linha) a qual é responsável pelo ajuste dos parâmetros do controlador.

O STR é muito flexível em relação à metodologia de projeto utilizada (critérios quadráticos, localização dos pólos, etc) e à escolha do esquema de identificação (mínimos quadrados recursivos, máxima verossemelhança, filtro de Kalman estendido, etc). A análise de sistemas auto-ajustáveis é no entanto mais complexa que a análise dos sistemas com modelo de referência, devido principalmente à

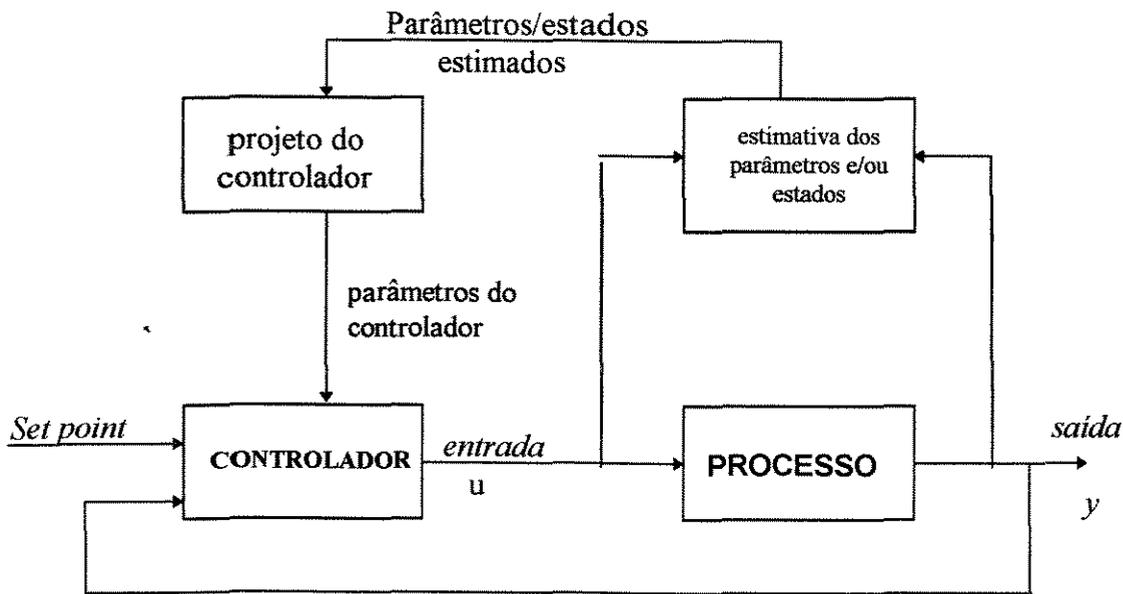


Figura 2.4 - Esquema geral do controlador adaptativo STR  
(Åström & Wittenmark, 1989).

(usualmente não linear) transformação dos parâmetros identificados para os parâmetros do controlador.

#### 2.4.2 - Modelos para o Controlador STR

O *modelo para controle* difere do *modelo para simulação* pois enquanto o segundo necessita ser o mais rigoroso possível, a fim de representar todos os aspectos fenomenológicos do processo, o primeiro pode ser uma forma mais simplificada do modelo rigoroso. Uma das justificativas para que se adote uma forma mais simplificada no modelo para controle é a necessidade de realização dos cálculos

em tempo real. Afinal, entre dois intervalos de amostragem, o controlador necessita identificar o modelo, prever a saída do processo utilizando este modelo e tomar uma ação de controle baseada na saída prevista. Se o modelo para controle tiver uma forma muito rigorosa, o tempo computacional para a sua resolução pode ser grande o suficiente para inviabilizar sua utilização em tempo real.

A grande vantagem do controle adaptativo é que mesmo utilizando um modelo simplificado do processo a representação exata do comportamento do sistema não é muito prejudicada pois esse modelo é atualizado em todos os intervalos de amostragem, através do estimador de parâmetros. Como essa atualização é em geral realizada de maneira recursiva, o esforço computacional para a identificação e resolução do modelo é sensivelmente menor quando comparado com uma estimativa “off line” acompanhada da resolução de um modelo rigoroso. Mesmo com o advento dos computadores com alto desempenho de cálculo a idéia de um modelo identificado em linha continua sendo atrativa pois, se o fato de ter que se resolver um modelo complexo em tempo real pode não representar um grande obstáculo, ainda mesmo assim há as dificuldades de determinação precisa de certos parâmetros que podem ser estimados com relativa facilidade utilizando algoritmos sequenciais. Além disso, nos processos com parâmetros que variam ao longo do tempo a identificação em linha é uma necessidade para a obtenção de desempenhos aceitáveis do sistema de controle.

Existem duas classes de modelos dinâmicos para controle. A primeira delas é um modelo do processo descrito por funções polinomiais, chamadas funções de transferência, que relacionam a entrada e a saída ou as entradas e as saídas, conforme o tipo de problema. Nessa metodologia, utiliza-se um modelo externo e não há a preocupação em representar matematicamente os fenômenos intrínsecos do processo. Para processos discretos ou amostrados, as funções de transferência podem ser escritas na forma de equações à diferenças. Essa classe de modelos é discutida no item seguinte.

A segunda classe de modelos para controle são os chamados modelos internos na forma espaço-de-estados e que descrevem todas as interações internas entre as variáveis de estado. O item 2.4.2.2 tratará com mais detalhes esses modelos.

#### *2.4.2.1 - Modelo da forma de equações à diferenças lineares*

Um típico modelo na forma de equações diferenças lineares de uma entrada e uma saída

empregado em controle adaptativo é uma equação à diferenças conhecida como modelo ARMAX (AutoRegressive, Moving Average model with auxiliary or eXogeneous input), descrito matematicamente por:

$$y(t) + a_1 y(t-1) + \dots + a_n y(t-n) = b_0 u(t-k) + b_1 u(t-k-1) + \dots + b_m u(t-k-m) + c_0 \xi(t) + c_1 \xi(t-1) + \dots + c_n \xi(t-n) + d(t) \quad (2.2.1)$$

onde

$y$  é a saída (*output*);

$u$  é a entrada (*input*);

$\xi$  é um ruído estocástico (variável aleatória com média zero e distribuição normal);

$d$  é a perturbação da carga (geralmente não mensurável);

$t$  é um inteiro positivo que representa o instante de amostragem,  $t = 0, 1, 2, \dots$

Na equação acima,  $n$  e  $m$  são inteiros positivos e supostos conhecidos (ordem do modelo) e  $k$  é o atraso do sistema expresso como um inteiro múltiplo do tempo de amostragem ( $k \geq 1$ ). Os parâmetros  $a_i$ ,  $b_i$  e  $c_i$  do modelo são geralmente desconhecidos e portanto devem ser estimados em tempo real. Aplicando o operador *backward-shift operator*, (definido como:  $q^{-1}y(k) = y(k-1)$ ) a equação acima pode ser escrita de forma mais compacta como:

$$A(q^{-1})y(t) = B(q^{-1})u(t-k) + C(q^{-1})\xi(t) + d(t) \quad (2.2.2)$$

onde os polinômios A, B e C são definidos como:

$$\begin{aligned} A(q^{-1}) &= 1 + \sum_{i=1}^n a_i q^{-i} \\ B(q^{-1}) &= \sum_{i=0}^m b_i q^{-i} \\ C(q^{-1}) &= \sum_{i=0}^n c_i q^{-i} \end{aligned} \quad (2.2.3)$$

Quatro parâmetros necessitam ser especificados *a priori* na equação acima: ordens do modelo  $m$  e  $n$ ; o atraso no tempo  $k$  e o tempo de amostragem  $\Delta t$ . A escolha da ordem da equação à diferenças é geralmente arbitrária. Altos valores de  $n$  são indesejáveis pois requer maior esforço computacional na estimativa dos parâmetros *on-line*. Valores muito baixos de  $n$  pode levar a uma pobre descrição da dinâmica do processo. A escolha de um tempo de amostragem  $\Delta t$  muito pequeno pode levar a duas desvantagens:

1. Pequenos valores de  $\Delta t$  podem levar o modelo do processo a ter zeros fora do círculo unitário em referência à localização dos pólos, tornando assim o modelo instável.
2. Se  $\Delta t$  é muito pequeno, então a ação de controle tende a se tornar excessiva.

Por outro lado, se  $\Delta t$  é escolhido muito grande, o controlador passa a responder vagarosamente à perturbações.

No caso de sistemas com mais de uma entrada e/ou saída (MIMO),  $y(t)$  e  $u(t)$  são vetores e  $A(q^{-1})$  e  $B(q^{-1})$  matrizes de dimensões  $ny \times ny$  e  $ny \times nu$ , respectivamente, onde  $ny$  é o número de saídas e  $nu$  é o número de entradas ao sistema. Neste caso a matriz  $A$  pode ser representada por:

$$A(q^{-1}) = I_{ny} + A_1 q^{-1} + \dots + A_{na} q^{-na} \quad (2.2.4)$$

ou

$$A(q^{-1}) = \begin{bmatrix} a_{11}(q^{-1}) & a_{12}(q^{-1}) & \dots & a_{1ny}(q^{-1}) \\ a_{21}(q^{-1}) & a_{22}(q^{-1}) & \dots & a_{2ny}(q^{-1}) \\ \vdots & \vdots & \ddots & \vdots \\ a_{ny1}(q^{-1}) & a_{ny2}(q^{-1}) & \dots & a_{nyny}(q^{-1}) \end{bmatrix} \quad (2.2.5)$$

onde  $a_{kj}$  são polinômios da forma:

$$a_{kj}(q^{-1}) = \delta_{kj} + a_{kj}^1 q^{-1} + \dots + a_{kj}^{na_{kj}} q^{-na_{kj}} \quad (2.2.6)$$

Este polinômio descreve como os dados antigos da saída  $j$  afetam a saída  $k$ . Aqui, a variável  $\delta_{kj}$  é o operador Kronecker-delta, definido da seguinte forma:

$$\delta_{kj} = \begin{cases} 1 & \text{se } k = j \\ 0 & \text{se } k \neq j \end{cases}$$

Similarmente,  $\mathbf{B}(q^{-1})$  é uma matriz de dimensões  $ny \times mu$ :

$$\mathbf{B}(q^{-1}) = B_0 + B_1 q^{-1} + \dots + B_{nb} q^{-nb} \quad (2.2.7)$$

ou

$$\mathbf{B}(q^{-1}) = \begin{bmatrix} b_{11}(q^{-1}) & b_{12}(q^{-1}) & \dots & b_{1mu}(q^{-1}) \\ b_{21}(q^{-1}) & b_{22}(q^{-1}) & \dots & b_{2mu}(q^{-1}) \\ \vdots & \vdots & \ddots & \vdots \\ b_{ny1}(q^{-1}) & b_{ny2}(q^{-1}) & \dots & b_{nymu}(q^{-1}) \end{bmatrix} \quad (2.2.8)$$

com:

$$b_{kj}(q^{-1}) = b_{kj}^1 q^{-1} + \dots + b_{kj}^{-nb_{kj}} q^{-nb_{kj}} \quad (2.2.9)$$

O atraso entre a entrada  $j$  e a saída  $k$  é  $nb_{kj}$ .

#### 2.4.2.2 - Modelos na forma de variáveis de estado

O **estado** de um sistema dinâmico é o menor conjunto de variáveis (chamadas *variáveis de estado*) tal que o conhecimento destas variáveis em  $t = t_0$ , junto com o conhecimento da entrada para  $t \geq t_0$ , determina completamente o comportamento do sistema para qualquer instante  $t \geq t_0$ .

Assim, o estado de um sistema dinâmico no instante  $t$  é univocamente determinado pelo estado no instante  $t_0$  e pela entrada para  $t \geq t_0$ , e é independente do estado e da entrada antes de  $t_0$ . Nota-se que, ao tratar de sistemas lineares invariantes no tempo, usualmente escolhe-se o tempo  $t_0$  de referência como sendo zero.

Observa-se que o conceito de estado de modo algum está limitado a sistemas físicos. Ele é aplicável a sistemas biológicos, sistemas econômicos, sistemas sociais e outros.

As **variáveis de estado** de um sistema dinâmico são as variáveis que constituem o menor conjunto de variáveis que determinam o estado do sistema dinâmico. Se pelo menos  $n$  variáveis  $x_1, x_2, \dots, x_n$  são necessárias para descrever completamente o comportamento de um sistema dinâmico (de modo que uma vez que a entrada é dada para  $t \geq t_0$  e o estado inicial em  $t = t_0$  está especificado, o estado futuro do sistema está completamente determinado), então tais  $n$  variáveis formam um conjunto de variáveis de estado.

O espaço  $n$ -dimensional cujos eixos coordenados consistem no eixo  $x_1$ , eixo  $x_2$ , ..., eixo  $x_n$  é chamado **espaço-de-estados**. Qualquer estado pode ser representado por um ponto no espaço de estados.

Na análise por **espaço-de-estados** há o interesse em três tipos de variáveis que estão envolvidas na modelagem de sistemas dinâmicos: variáveis de entrada, variáveis de saída e variáveis de estado.

Considere o sistema dinâmico mostrado na Figura 2.5. No diagrama as setas indicam que os sinais são grandezas vetoriais. Nesse sistema a saída  $y(t)$  para  $t \geq t_1$  depende do valor  $y(t_1)$  e da entrada  $u(t)$  para  $t \geq t_1$ . O sistema dinâmico deve envolver elementos que memorizam os valores da entrada para  $t \geq t_1$ . Já que os integradores em um sistema de controle contínuo no tempo servem como dispositivos de memória, as saídas de tais integradores podem ser consideradas como variáveis que definem o estado interno do sistema dinâmico. Assim, as saídas de integradores servem como variáveis de estado. O número de variáveis de estado necessárias para definir completamente a dinâmica do sistema é igual ao número de integradores envolvidos no sistema.

Admitindo que um sistema de múltiplas entradas e múltiplas saídas envolve  $n$  integradores e admitindo também que há  $r$  entradas  $u_1(t), u_2(t), \dots, u_r(t)$  e  $m$  saídas  $y_1(t), y_2(t), \dots, y_m(t)$ ; definindo  $n$  saídas dos integradores como variáveis de estado:  $x_1(t), x_2(t), \dots, x_n(t)$ ; então o sistema pode ser descrito por uma equação de estado e uma equação de saída na forma:

$$\begin{aligned}\dot{x}(t) &= f(x, u, t) \\ y(t) &= g(x, u, t)\end{aligned}\tag{2.2.10}$$

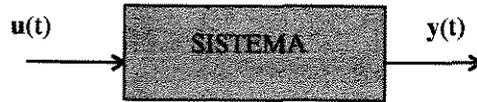


Figura 2.5 - Sistema dinâmico

Se as equações anteriores são linearizadas sobre o estado de operação (Anexo I), então tem-se a seguinte equação de estado linearizada e a equação de saída:

$$\begin{aligned}\dot{x}(t) &= F(t)x(t) + G(t)u(t) \\ y(t) &= C(t)x(t) + D(t)u(t)\end{aligned}\tag{2.2.11}$$

onde  $F(t)$  é chamada matriz de estado,  $G(t)$  a matriz de entrada,  $C(t)$  a matriz de saída e  $D(t)$  a matriz de transmissão direta.

Se as funções vetoriais  $f$  e  $g$  não envolvem o tempo  $t$  explicitamente, então o sistema é chamado sistema invariante no tempo. Neste caso, as equações acima podem ser simplificadas para:

$$\begin{aligned}\dot{x}(t) &= Fx(t) + Gu(t) \\ y(t) &= Cx(t) + Du(t)\end{aligned}\tag{2.2.12}$$

ou

$$\begin{aligned}\frac{dx}{dt} &= Fx(t) + Gu(t); & x(t_0) &= x_0 \\ y(t) &= Cx(t) + Du(t)\end{aligned}\tag{2.2.13}$$

onde:

$x(t)$  denota o vetor de estados de  $n$ -dimensões

$u(t)$  denota o vetor de *entradas* de  $r$ -dimensões

$y(t)$  denota o vetor de *saiidas* de  $m$ -dimensões

A dimensão do vetor de estados,  $n$ , é chamada de *ordem* do modelo.

A equação diferencial anterior (2.2.13) é a **equação de estado** do sistema linear invariante no tempo, e tem a seguinte solução:

$$x(t) = e^{F(t_f - t_o)} x(t_k) + \int_{t_o}^{t_f} e^{F(t_f - s)} G u(s) ds \quad (2.2.14)$$

Onde  $s$  é a variável de integração. No caso do tempo ser discreto, como por exemplo os processos controlado por computador, o sinal de entrada ser constante entre duas medidas e o sistema linear, o modelo espaço-de-estados toma a seguinte forma:

$$\begin{aligned} x(t+1) &= Ax(t) + Bu(t); & x(0) &= x_o \\ y(t) &= Cx(t) \end{aligned} \quad (2.2.15)$$

onde:

$$\begin{aligned} A &= e^{F\Delta} = \sum_{k=0}^{\infty} \frac{F^k h^k}{k!} \\ B &= \int_0^h e^{F(s)} ds G = \sum_{k=0}^{\infty} \frac{F^{k+1} h^{k+1} G}{(k+1)!} = F^{-1}(A - I)G \\ C &= H \end{aligned} \quad (2.2.16)$$

Se  $F$  é não-singular;  $t \in \{0, 1, 2, 3, \dots\}$  e  $h$  é o tempo de amostragem.

Para processos estocásticos a equação anterior é escrita como:

$$\begin{aligned}x(t+1) &= Ax(t) + Bu(t) + v_1(t); & x(0) &= x_0 \\y(t) &= Cx(t) + v_2(t)\end{aligned}\quad (2.2.17)$$

sendo  $v_1(t)$  e  $v_2(t)$  um ruído branco que procura modelar as incertezas do modelo e do instrumento de medida, respectivamente.

Se o processo for não linear, da forma:

$$\begin{aligned}\frac{dx}{dt} &= \dot{x}(t) = f[x(t), u(t)] + v_1(t) \\y(t) &= h[x(t), u(t)] + v_2(t)\end{aligned}\quad (2.2.18)$$

a discretização é feita da seguinte forma:

$$\begin{aligned}x(t+1) &= F[x(t), u(t)] + v_1(t) \\y(t) &= h[x(t), u(t)] + v_2(t)\end{aligned}\quad (2.2.19)$$

onde:

$$F[x(t), u(t)] = x(t) + \int_t^{t+1} f[x(t), u(t)] dt \quad (2.2.20)$$

A integral acima pode ser calculada por qualquer processo analítico ou numérico. O método mais usual é a aproximação por Euler, de modo que a equação anterior fica:

$$F[x(t), u(t)] = x(t) + f[x(t), u(t)]h \quad (2.2.21)$$

sendo  $h$  o tempo de amostragem ou outro tempo convenientemente escolhido para a discretização.

Pode-se mostrar que o modelo espaço-de-estados visto acima se relaciona com o modelo na forma de equações à diferenças, para o caso de uma entrada e uma saída, através da equação:

$$y(k) = H(q)u(k) \quad (2.2.22)$$

onde  $H(q)$  é chamado de operador **matriz função de transferência** e é dado por:

$$H(q) = [C(qI - A)^{-1} B] \quad (2.2.23)$$

Da mesma forma, pode-se identificar o processo utilizando um modelo na forma de equações à diferenças e em seguida transformá-lo na forma canônica espaço-de-estados, no entanto a volta da representação em espaço-de-estados não é única. Há diversos algoritmos disponíveis para efetuar essa transformação (*Åström & Wittenmark, 1984; Strmčnik & Bremsák, 1985*).

### 2.4.3 - Identificação do Modelo

A maioria das técnicas atuais para o projeto de sistemas de controle são baseadas em uma boa compreensão da planta sob estudo envolvendo o efeito que alterações externas e internas causam em sua dinâmica. No entanto, em um número significativo de processos, a planta a ser controlada é muito complexa e seus processos básicos não são totalmente conhecidos. A técnica de projeto do controlador necessita então ser acompanhada de uma técnica de identificação que se responsabiliza por uma progressiva melhora no entendimento da planta a ser controlada. É então intuitiva a junção da identificação e controle.

A *identificação de sistemas* consiste na estimativa de um modelo do processo baseada em dados observados de entrada e saída. Como visto no item anterior, existem várias maneiras de descrever um sistema, existindo também assim, diversas técnicas de estimar essa descrição que, em geral, envolve as etapas básicas, sumarizadas a seguir:

1. Projeto de um experimento e coleta de dados de entrada e saída do processo a ser identificado;
2. Exame dos dados, análise e filtragem dos dados disponíveis;
3. Seleção e definição de uma estrutura de modelo (conjunto de modelos);

4. Cálculo do melhor modelo a partir dos dados disponíveis e de um critério de ajuste;
5. Exame das propriedades do modelo obtido;
6. Se o modelo representar bem o sistema, a identificação termina aqui; se não, retorna-se à etapa 3.

Normalmente, as etapas de identificação e controle não são realizadas separadamente. Se o sistema de identificação é recursivo - o modelo da planta é periodicamente atualizado com base nas estimativas passadas e novos dados, identificação e controle podem ser realizados conjuntamente, sendo esta a principal característica do controle adaptativo.

No Capítulo III será discutido as diversas estratégias de identificação recursiva para modelos tanto na forma de espaço-de-estados quanto na forma de equações à diferenças lineares.

#### **2.4.4 - Princípios de Projeto**

Projetar um controlador significa determinar valores para as suas constantes de tal modo que o processo em malha fechada responda de um modo desejado que geralmente envolve a minimização ou maximização de determinado índice de desempenho. A teoria de controle surge justamente no suporte ao projeto do controlador pois objetiva determinar sob o ponto de vista teórico, metodologias ou estratégias de controle que possuam uma base matemática comprovada no que se refere à estabilidade, convergência e robustez do sistema de controle.

O Capítulo IV é relacionado com o projeto do controlador adaptativo STR onde será apresentado com mais detalhes o assunto.

#### **2.4.5 - Implementação do STR**

Apesar dos avanços feitos na pesquisa, os controladores STR não têm sido largamente empregados no controle de processos químicos. Há muitas explicações possíveis para este fato. Uma delas é que os controladores STR são inerentemente mais complexos do que os algoritmos convencionais com parâmetros fixos, pois há a estimativa e o projeto do controlador em tempo real. Porém, somente a complexidade não é suficiente para explicar a falta de larga implementação pois a parte de cálculos em um sistema de controle é frequentemente pequena frente ao problema global de

implementação dos controladores (*software e hardware*).

Outro fator, e talvez o mais importante, é que apesar da vigorosa e necessária pesquisa direcionada à investigação acerca da robustez, estabilidade, estimativa de parâmetros, aplicações em simulações, etc, poucas pesquisas tem sido publicadas na área de **engenharia de software** de controladores STR. A implementação desse controlador em um sistema de controle existente envolve a conversão do algoritmo matemático em um programa computacional que necessita estar interconectado com o restante do sistema e possibilitar interfaces com usuários responsáveis pelo processo (operadores e engenheiros). É interessante que tal sistema de controle seja implementado utilizando módulos independentes, o que pode ser conseguido com relativa facilidade através da utilização do conceito de projeto orientado a objeto (*Tuffs, 1988*). Um sistema na forma modular permite uma fácil manutenção e atualização somente de algumas partes sem necessidade de alterar todo o sistema. Embora possa-se utilizar uma linguagem como o FORTRAN, é interessante que se utilize uma linguagem orientada a objeto como o C++ ou Ada, pois permitem realizar interfaces com outros *softwares* e com *hardwares* com maior facilidade.

Outros aspectos práticos de implementação, tais como presença de dinâmicas e perturbações não modeladas, utilização de conhecimentos prévios do processo, etc, também são importantes e necessitam ser considerados (*Wittenmark & Åström, 1984*).

### **2.5 - Controle adaptativo de sistemas não lineares**

Como a maioria dos processos químicos são inerentemente sistemas não lineares, há duas alternativas no controle desses processos: a primeira é considerar um modelo não linear para controle e utilizar a teoria de controle não linear no projeto do controlador; a segunda alternativa consiste em utilizar um modelo linear, que pode ser obtido a partir da linearização do modelo rigoroso em um determinado ponto de operação. Esse ponto de operação pode ser, por exemplo, o estado estacionário de referência. Disposto desse modelo linear, aplica-se então uma técnica de controle linear no projeto do controlador. Ambos os métodos possuem vantagens e desvantagens.

A vantagem da utilização da teoria de controle linear é que ela se encontra bem sedimentada e com farto desenvolvimento teórico com relação à estabilidade, convergência e robustez do sistema em

malha fechada. A desvantagem desta técnica é que se projeta o controlador utilizando um modelo aproximado que dependendo do comportamento do sistema faz com que as garantias teóricas não continuem válidas. Além da linearização utilizando série de Taylor truncada na primeira derivada (o mais comum dos métodos) existem outras metodologias de aproximar um modelo não linear por um correspondente linear. Esses modelos simplificados podem variar bastante quanto ao grau de sofisticação, indo desde simples polinômios, a modelos mais complexos fundamentados em métodos geométricos (*Paolini et al., 1992*).

Apesar da teoria de controle não linear ser bem mais recente, e ainda com amplo campo de pesquisa no que se refere à sua teoria de suporte, intuitivamente é de se esperar que um processo não linear seja melhor controlado por um controlador que leva em consideração as não linearidades do processo. A desvantagem desta técnica é que ainda não dispõe de amplo suporte teórico no que se refere à estabilidade, robustez e, principalmente, convergência. Além disto, a teoria de controle não linear é bem mais complexa quando comparada com a teoria linear.

Nos últimos anos tem havido um crescente interesse na utilização da técnica de realimentação de estados a fim de linearizar de forma exata o comportamento entre as entradas e saídas de um sistema de controle não linear ou linearizar as entradas com relação aos estados.

A teoria da linearização exata por realimentação de estados foi desenvolvida com o trabalho de diversos pesquisadores nas décadas de 70 e 80, tanto para sistemas contínuos quanto para os discretos no tempo. Um número considerável de aplicações desta técnica também já foi realizado, mostrando sua potencialidade no controle de sistemas não lineares (*Henson & Seborg, 1992; Bowser, 1994*). Baseado nos trabalhos disponíveis na literatura, o maior obstáculo ao seu bom desempenho está na capacidade do cancelamento exato dos termos não lineares, responsável pela obtenção de um comportamento linear entre as entradas e as saídas. Consequentemente, se houver erros nos termos não lineares do modelo, o cancelamento não será exato e a relação entre a entrada e a saída não será mais linear. Uma alternativa para contornar este problema é o uso de um controlador com parâmetros adaptativos de modo a tornar mais robusto o cancelamento dos termos não lineares quando as incertezas nestes termos forem paramétricas (*Sastry, 1989*).

Uma revisão relativamente completa destes métodos é feita em *Henson & Seborg (1990)*, *Kravaris & Kantor (1990a; 1990b)* e em *Teixeira (1991)*.

## **2.6 - Supervisionamento e Coordenação de Controladores Adaptativos**

### **2.6.1 - supervisionamento dos controladores adaptativos**

Diversas simulações em computador de aplicações do controle adaptativo a diferentes processos têm mostrado que essa estratégia de controle tem funcionado como esperado no que se refere à estabilidade e convergência bem como obtenção do desempenho desejado. No entanto, ao se controlar um processo real, espera-se que possa haver um desvio em relação ao comportamento teórico. As razões para isto se deve na maioria dos casos à considerações errôneas acerca da estrutura do modelo do processo (modelo de controle), problemas na estimativa de parâmetros e utilização de um método incorreto para o projeto do controlador.

Cria-se deste modo a necessidade de realizar um supervisionamento contínuo da malha de controle por um nível hierárquico mais elevado capaz de tomar decisões baseadas no desempenho do processo em malha fechada e que atuará na malha de controle adaptativo. As tarefas desta malha de supervisionamento envolvem: detectar comportamentos incorretos/falhos; buscar/detectar as causas e iniciar medidas corretivas.

A seguir apresenta-se um resumo de como pode-se realizar o supervisionamento de funções básicas.

Possíveis violações às considerações necessárias para a convergência dos parâmetros podem ser causadas pela falta de uma excitação não persistente ao processo. Em *Hinde & Cooper (1994)* é apresentado uma metodologia de excitação que utiliza eventos da própria dinâmica do processo, não sendo necessário, portanto, introduzir um sinal externo com a finalidade de ativar o estimador de parâmetros. A presença de ruídos não estacionários, como mudanças degrau, também afetam negativamente a estimativa assim como mudanças bruscas do comportamento estático ou dinâmico do processo, pois em geral todos os métodos de estimativa tendem a serem robustos para sistemas nos quais os parâmetros são constantes ou mudam muito lentamente. Uma escolha errada dos parâmetros que definem o modelo, do tempo de amostragem, etc, também prejudicam o estimador.

Estes efeitos podem levar a um comportamento pobre em malha fechada ou até mesmo causar instabilidade. Para evitar tal comportamento várias medidas supervisórias necessitam ser tomadas (Isermann et al. 1985).

Para fins de supervisionamento em tempo real aconselha-se o monitoramento da grandeza do erro da equação do modelo  $[e(k)]$ , dos valores dos parâmetros estimados, da informação sobre a covariância do estimador, da variável controlada e do autovalor do estimador de parâmetros. Também informações qualitativas a respeito do comportamento dinâmico podem ser úteis na tomada de decisão. Se uma destas grandezas citadas ultrapassar certos limites, as seguintes medidas podem ser tomadas:

- 1 - parar por M passos a estimativa de parâmetros do modelo dinâmico;
- 2 - parar por M passos a estimativa do sinal de controle;
- 3 - reinicializar o estimador de parâmetros ou a matriz covariância ;
- 4 - busca automática por outra ordem do modelo e tempo-morto.

Em geral passa-se os novos valores estimados dos estados, parâmetros e entradas, por um filtro a fim de se evitar mudanças bruscas nestas variáveis, geralmente causadas por ruídos.

O emprego de uma metodologia incorreta de projeto do controlador geralmente envolve problemas ocasionados por um não cancelamento de pólos ou zeros instáveis, a utilização de um tempo de amostragem muito pequeno ou muito grande ou um erro no projeto dos parâmetros.

Se os métodos de estimativa dos parâmetros e projeto do controlador estiverem atuando de forma satisfatória, ainda assim é necessário um supervisionamento do funcionamento da malha de controle. Esse supervisionamento envolve a verificação se a diferença entre a saída de referência e a saída real cresce monotonicamente, se a posição do atuador permanece em um valor que corresponde a uma restrição ou se o sistema está apresentando um comportamento oscilatório instável.

Se apesar de todas as medidas forem tomadas e o sistema permanecer em um comportamento oscilatório instável, então a malha de controle adaptativa deve ser substituída por um outro controlador

com parâmetros fixos e que seja robusto, o qual deve ser previamente projetado e armazenado durante a etapa de pré-identificação. A literatura cita vários casos em que o comportamento em malha fechada e a robustez foram melhorados quando se utilizou estas medidas supervisórias. O esforço computacional adicional para se realizar a supervisão é estimado em 15 % (Iserman, 1989).

### 2.6.2 - Coordenação de Controle Adaptativo

Até o momento as considerações feitas acerca da inicialização e supervisionamento dos controladores adaptativos mostraram que este tipo de controlador pode ser consideravelmente melhorado pela adição de elementos supervisórios e sistemas reservas em um nível mais alto. Isto faz com que a estrutura global do controle adaptativo se torne mais complexa e algumas vezes também variável. A decisão de ativar ou não um elemento e a escolha dos parâmetros de projeto livres fazem a estrutura do controle adaptativo ser dependente das condições operacionais como por exemplo *start-up*, operação normal, mudanças rápidas nas condições operacionais, etc, que podem ser consideradas como funções de uma *coordenação* e podem ser realizadas em um terceiro nível retroalimentado, como pode ser visto na Figura 2.6.

Exemplos de tarefas para este nível de coordenação envolvem a realização do *start-up* do controle adaptativo (pré-identificação, escolha dos parâmetros de projeto e transferência para malha fechada); da procura em linha por uma estrutura de modelo adequada; do projeto do controlador fixo que irá atuar caso o controle adaptativo seja desativado; da combinação não sincronizada da estimativa de parâmetros e projeto do controlador, isto é, a cada intervalo de amostragem apenas é feita a identificação do modelo sem que se tome uma ação de controle baseada no novo modelo (esta estratégia permite que o controlador fique menos sensível ao período de convergência dos parâmetros quando estes, em geral, estão distantes de seus valores corretos); utilização de diferentes tempos de amostragem; realização do projeto do controlador sob certas condições (os novos parâmetros do controlador somente são usados se a simulação da malha de controle fechada levar a um melhor desempenho do sistema controlado); filtragem dos parâmetros estimados e a escolha de diferentes algoritmos de controle.

### 2.7 - Conclusões

Desenvolvimentos recentes de veículos aeroespaciais de grande desempenho, sistemas de

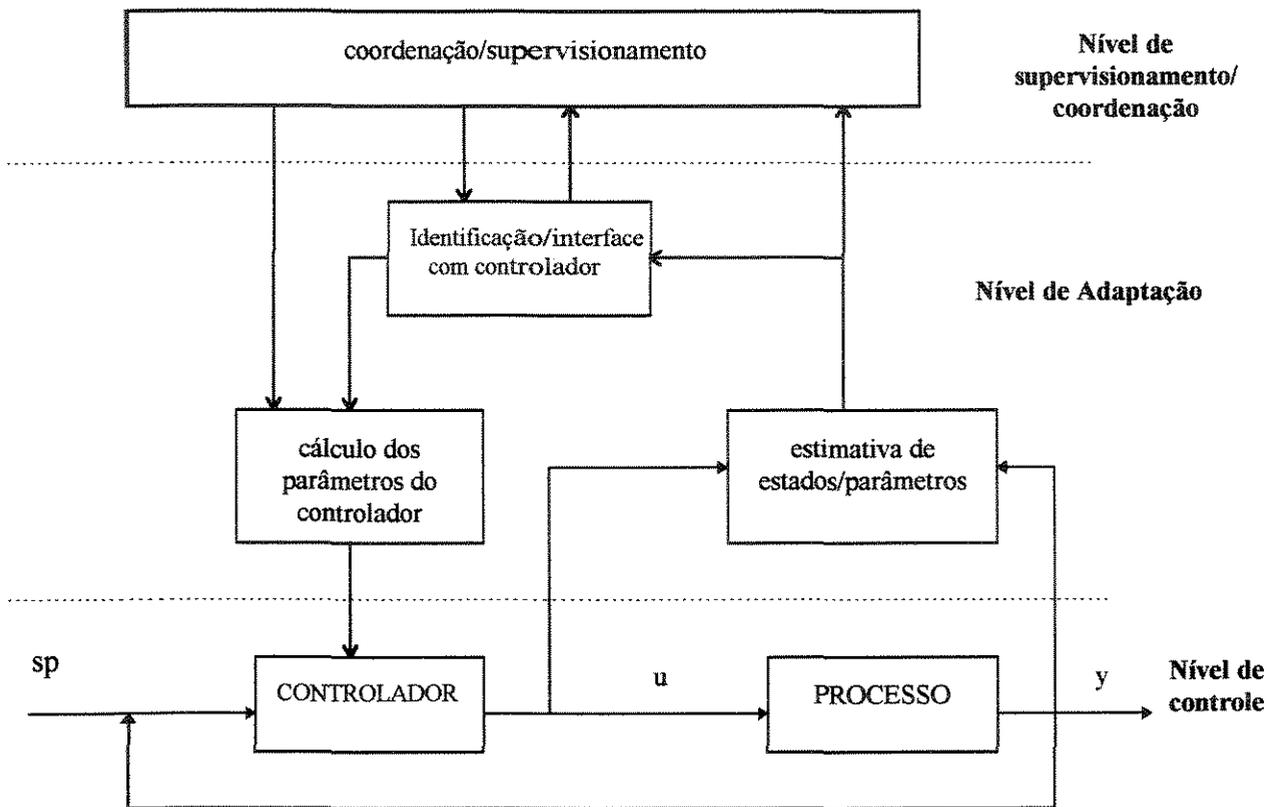


Figura 2.6 - Malha de controle adaptativo com nível de supervisão e controle (Iserman, 1989).

robótica e plantas de alta eficiência impõem restrições cada vez maiores nos seus sistemas de controle associados. Ao projetar sistemas de controle para operações de processos com alta eficiência e desempenho, há a preocupação com o projeto de sistemas que satisfaçam as especificações impostas pelos usuários sob as condições antecipadas de operação. A maioria dos sistemas de controle que exigem grande desempenho para uma grande gama de condições de operação será necessariamente adaptativa até um certo grau. Quando um alto grau de adaptabilidade é claramente requerido, a maioria das especificações atuais será obedecida por um sistema do tipo identificação-decisão-modificação com modificação sequencial ou contínua, dependendo da taxa de variação dos parâmetros envolvidos.

O controlador adaptativo auto-ajustável STR atende a estes requisitos de controle e dentre os tipos de controle adaptativo (ganho programado, modelo de referência e regulador auto-ajustável) representa a estratégia mais interessante pois intrinsecamente permite que o sistema de controle se auto-

ajuste de maneira a compensar variações das condições operacionais que podem ser impostas ou imprevisíveis.

As aplicações experimentais com sucesso do controle adaptativo a diversos processos químicos mostram que há fundamento na utilização desta estratégia no controle destes sistemas, que se caracterizam por apresentarem dinâmicas complexas e para os quais as estratégias convencionais, em geral, não apresentam bons resultados.

Os desenvolvimentos mais recentes em sistemas de controle adaptativo estão na área de reconhecimento de padrões (identificação), sistemas com aprendizado, controle adaptativo não linear e coordenação, supervisionamento de malhas de controle e desenvolvimento de *software* para controle adaptativo.

## CAPÍTULO III

### ESTIMATIVA DE ESTADOS E PARÂMETROS EM TEMPO REAL

#### 3.1 - Introdução

O conhecimento em tempo real de todos os estados de um sistema é fundamental para o seu completo monitoramento e necessário nas estratégias avançadas de controle que utilizam a técnica de realimentação de estados. Como nem todos esses estados são diretamente mensuráveis ou as medidas em tempo real são disponíveis com atrasos e/ou possuem custo muito elevado, as técnicas de **estimativa de estado** constituem em uma proposta interessante na solução deste problema.

Dentre as várias técnicas disponíveis para realizar a estimativa em linha dos estados as mais interessantes são as que utilizam um *software*, chamado de *soft sensor* (Tham et al., 1989). Esse *software* nada mais é do que a implementação computacional de um filtro ou de um observador de estado. Para processos discretos ou processos amostrados utiliza-se um algoritmo na forma sequencial.

Existem diversos filtros propostos na literatura com diferentes graus de complexidade. Para processos estocásticos, isto é, processos onde há a presença de um certo grau de incerteza, tanto no modelo do processo quanto nas medidas disponíveis, o mais conhecido é o filtro de Kalman, que é aplicável na sua forma original apenas na estimativa de estados de sistemas lineares. Baseado nesse filtro, desenvolveu-se outro algoritmo conhecido como Filtro de Kalman Estendido (FKE) que é aplicável à estimativa de estados de sistemas não lineares bem como à estimativa de parâmetros de sistemas lineares ou não.

Na estimativa sequencial de parâmetros, além do FKE, há uma variedade muito grande de algoritmos, sendo um dos mais comuns, o dos mínimos quadrados recursivos simples ou estendido e suas inúmeras variantes.

Este capítulo tem como objetivo abordar de forma clara e objetiva esses três algoritmos (filtro de Kalman, FKE e mínimos quadrados recursivos), sendo enfatizado os parâmetros que devem ser

especificados e os que devem ser ajustados, levando a uma estimativa satisfatória. Embora todos estes métodos sejam comuns na literatura referente à estimativa, filtragem e controle adaptativos, em geral, não são tratados com clareza no que se refere à implementação. Deste modo, sendo a estimativa de estados e parâmetros a etapa que confere ao controle adaptativo esta característica, pois informa a situação da dinâmica do processo à etapa de projeto do controlador, uma boa estimativa é imprescindível a um bom projeto e este para uma atuação adequada a fim de se rejeitar perturbações ou levar o processo a outro estado desejado.

Como caso estudo, foi implementado o FKE na identificação de um processo fermentativo em batelada. Esse processo é um típico sistema que requer a estimativa de estados e parâmetros em linha para finalidades de controle avançado. Resultados de simulações são apresentados objetivando mostrar a influência dos diversos parâmetros do filtro no desempenho deste.

## 3.2 - Estimativa de Estados

### 3.2.1 - Introdução

Diferentes estimadores de estado podem ser derivados dependendo das medidas disponíveis. Assumindo, por exemplo, que os seguintes dados são disponíveis:

$$Y_t = \{y(i), u(i) | i \leq t\} \quad (3.2.1)$$

ou seja, dispõe-se de um conjunto  $Y$  de dados obtidos até o tempo  $t$ , composto pelos dados de entrada  $u(i)$  e pelos dados de saída  $y(i)$  sendo  $i$  todos os tempos menores que  $t$  e deseja-se estimar  $x(t+m)$  usando  $Y_t$ . Dependendo do valor de  $m$ , tem-se três casos:

suavização ( <i>smoothing</i> ):	$m < 0$
filtragem ( <i>filtering</i> ):	$m = 0$
predição ( <i>prediction</i> ):	$m > 0$

A filtragem é relacionada com a obtenção de um sinal a partir de dados disponíveis, porém portadores de um certo grau de incerteza, ou seja, corrompidos por um ruído. Se os espectros dos sinais

e dos ruídos não são sobrepostos é possível projetar um filtro que passa os sinais desejados e atenua os ruídos indesejados. O filtro resultante poderá ser projetado para passar apenas baixa ou alta frequência (filtros passa baixa ou passa alta, respectivamente) ou selecionar apenas uma faixa de frequência desejada, dependendo da frequência relativa do sinal desejado e do ruído.

Quando o sinal e o ruído estão sobrepostos a questão se transforma na escolha de qual a melhor característica de filtro para passar os sinais desejados e suprimir os ruídos.

No caso de sistemas determinísticos, ou seja, quando os sinais de entrada não estão corrompidos por ruídos, é possível prever **exatamente** o comportamento futuro a partir das informações passadas. Já no caso de sistemas estocásticos, não é possível prever com exatidão esse comportamento futuro devido às incertezas presentes no sistema. Então, o principal objetivo da predição é minimizar a variância do erro predito. Fundamentado na teoria estatística desenvolveu-se preditores com comportamento ótimo que são filtros ótimos específicos.

Se as entradas são modeladas por modelos estocásticos lineares uma solução para o problema geral de filtragem (predição, filtragem ou suavização) pode ser obtida utilizando o filtro de Kalman. Além deste filtro existem vários outros com menor ou maior grau de complexidade, sendo exemplo do último tipo os chamados *lattice filters* que têm sido aplicados com certo sucesso na área de filtros adaptativos (*Goodwin & Sin, 1984*).

### 3.2.2 - Estimativa de Estados Utilizando o Filtro de Kalman e o Filtro de Kalman Estendido.

Considere o modelo estocástico, linear, discreto, na forma espaço-de-estados e com dimensões finitas dado pela equação matemática:

$$\begin{aligned}x(t+1) &= Ax(t) + Bu(t) + v_1(t); & x(0) &= x_0 \\ y(t) &= Cx(t) + v_2(t)\end{aligned}\tag{3.2.2}$$

onde:

$t \in \{0, 1, 2, \dots\}$  e o estado inicial  $x(t_0)$  é uma variável randômica de média  $\bar{x}_0$  e covariância  $P_0$ ;

$\{v_1(t)\}$  e  $\{v_2(t)\}$  representam sequências de ruído branco com média zero e pertencentes a um determinado espaço probabilístico e que denotam as incertezas presentes no modelo do processo e do instrumento de medida respectivamente. As covarianças desses ruídos são dadas por:

$$E\left\{\begin{bmatrix} v_1(t) \\ v_2(t) \end{bmatrix} \begin{bmatrix} v_1(\tau)^T & v_2(\tau)^T \end{bmatrix}\right\} = \begin{bmatrix} Q & S \\ S^T & R \end{bmatrix} \delta(t - \tau);$$

$$Q \geq 0, \quad R > 0$$

onde  $\delta(t - \tau)$  é o delta Kronecker (Capítulo II).

Se o modelo descrito pela Equação 3.2.2 fosse determinístico,  $x(t+1)$  estaria completamente determinado apenas com o conhecimento de  $Ax(t) + Bu(t)$ . Porém, como não se conhece  $v_1(t)$  e  $v_2(t)$ , o filtro de Kalman é uma alternativa para se calcular  $x(t+1)$ .

Considerando o estado inicial apresentado acima  $[x(t_0)]$ ,  $S = 0$  e que as sequências de ruídos são gaussianas, denota-se  $\hat{x}(t+1)$  como sendo a média de  $x(t+1)$  dados as observações de  $\{y(t)\}$  para tempos menores que  $t$ . Então  $\hat{x}(t+1)$  satisfaz a seguinte equação recursiva (Filtro de Kalman):

$$\begin{aligned} \hat{x}(t+1) &= A\hat{x}(t) + K(t)[y(t) - C\hat{x}(t)] + Bu(t) \\ \hat{x}(t_0) &= \bar{x}_0 \end{aligned} \tag{3.2.3}$$

onde  $K(t)$  é o ganho do filtro dado por:

$$K(t) = [AP(t)C^T + S][CP(t)C^T + R]^{-1} \tag{3.2.4}$$

O termo  $K(t)[y(t) - C\hat{x}(t)]$  é um termo de correção que envolve a diferença entre a saída medida  $y$  e a saída estimada  $C\hat{x}(t)$ . A matriz  $K$  serve como uma matriz peso. O termo de correção monitora o estado  $x$  estimado.

O comportamento dinâmico de vetor de erro é determinado pelos autovalores da matriz  $A-KC$ . Se essa matriz for uma matriz estável, o vetor de erro convergirá para zero para qualquer vetor de erro inicial  $e(0)$ . Isto é,  $\hat{x}(t)$  estimado convergirá para  $x(t)$  real independentemente dos valores de  $x(0)$  real e estimado.

$P(t)$  é a covariância do erro dos estados, dada por:

$$P(t) = E\{[\hat{x}(t) - x(t)][\hat{x}(t) - x(t)]^T | y(t-1), y(t-2), \dots, y(t_0)\}$$

e satisfaz a seguinte equação à diferenças de Riccati:

$$\begin{aligned} P(t+1) &= AP(t)A^T + Q - K(t)[CP(t)C^T + R]K(t)^T \\ P(t_0) &= P_0 \end{aligned} \quad (3.2.5)$$

O algoritmo completo do filtro de Kalman é então constituído pelas equações 3.2.3, 3.2.4 e 3.2.5 para o modelo dado por 3.2.2. e é completamente especificado dados:

- (i) a equação 3.2.2;
- (ii) o estado inicial  $x_0$  e sua covariância  $P_0$  e
- (iii) as covariâncias das incertezas do modelo  $Q$ , do instrumento de leitura  $R$  e  $S$  (covariância cruzada).

Partindo do pressuposto que para qualquer processo um modelo na forma espaço-de-estados pode ser derivado através das equações de balanço de massa, energia e quantidade de movimento e em geral o seu estado inicial é conhecido juntamente com sua incerteza  $P_0$ , somente os parâmetros  $Q$ ,  $R$  e  $S$  oferecem relativa dificuldade prática para serem especificados. Em simulações, utiliza-se um ruído com uma distribuição estatística, média e covariância conhecidos. Porém, em problemas práticos, geralmente não se conhece a magnitude destas variáveis que quando utilizadas com valores incorretos resultam em estimativas pobres.

O método mais comum de se determinar Q, R e S é a tentativa e erro embora seja conveniente a utilização de uma metodologia fundamentada em princípios teóricos como a proposta por *Zhou & Luecke (1995)*.

O preditor descrito pelas equações do filtro de Kalman tem a propriedade de que os estados no tempo t são reconstruídos a partir de y(t-1), y(t-2), ... É possível derivar uma forma alternativa do filtro, a qual também utiliza y(t) para estimar x(t). As equações são (*Åström & Wittenmark, 1984*):

$$\hat{x}(t+1|t+1) = A\hat{x}(t|t) + Bu(t) + K(t+1)[y(t+1) - C(A\hat{x}(t|t) + Bu(t))] \quad (3.2.6)$$

onde:

$$\begin{aligned} K(t) &= P(t|t-1)C^T [R + CP(t|t-1)C^T]^{-1} \\ P(t|t-1) &= AP(t-1|t-1)A^T + Q \\ P(t|t) &= P(t|t-1) - K(t)CP(t|t-1) \\ P(0|0) &= P_0 \end{aligned} \quad (3.2.7)$$

A notação  $P(t|t-1)$  é usada aqui no lugar de  $P(t)$  para especificar os dados avaliados;  $P(t|t)$  pode ser interpretado como a variância do erro estimado no tempo t dado y(t).

Maiores detalhes acerca das propriedades do filtro de Kalman podem ser encontrados em *Goodwin & Sin (1984)*, *Åström & Wittenmark (1984)*.

Para sistemas não lineares o filtro de Kalman não pode ser aplicado diretamente pois a linearidade do modelo é uma consideração no seu desenvolvimento. O filtro de Kalman estendido tenta contornar este problema fazendo uma aproximação que é a linearização dos estados em torno do estado estimado atual.

Considere o modelo geral não linear:

$$\begin{aligned} z(t+1) &= f(z(t), u(t), v_1(t)) \\ y(t) &= h(z(t), u(t), v_2(t)) \end{aligned} \quad (3.2.8)$$

com

$$E \left\{ \begin{bmatrix} v_1(t) \\ v_2(t) \end{bmatrix} \begin{bmatrix} v_1(\tau)^T & v_2(\tau)^T \end{bmatrix} \right\} = \begin{bmatrix} Q & S \\ S^T & R \end{bmatrix} \delta(t - \tau);$$

$$Q \geq 0, \quad R > 0$$

Denotando  $\hat{z}(t)$  como sendo uma estimativa dos estados no tempo  $t$  e linearizando (3.2.8) em torno de  $z(t) = \hat{z}(t)$ ,  $v_1(t) = 0$  e  $v_2(t) = 0$ , resulta em:

$$\begin{aligned} z(t+1) &\approx f(\hat{z}(t), u(t), 0) + F(t)[z(t) - \hat{z}(t)] + G(t)v_1(t) \\ y(t) &\approx h(\hat{z}(t), u(t), 0) + H(t)[z(t) - \hat{z}(t)] + J(t)v_2(t) \end{aligned} \quad (3.2.9)$$

onde:

$$F(t) = \left. \frac{\partial f(z(t), u(t), v_1(t))}{\partial z(t)} \right|_{z(t)=\hat{z}(t), v_1(t)=0} \quad (3.2.10)$$

é a matriz Jacobiana das equações que descrevem o processo. Os elementos  $F_{ij}$  dessa matriz são constituídos pelas derivadas parciais da equação  $f$  ( $i=1$ , número de equações) em relação às variáveis  $z(j) = 1$ , número de variáveis), calculadas em torno do estado estimado  $z$ .

$$G(t) = \left. \frac{\partial f(z(t), u(t), v_1(t))}{\partial v_1(t)} \right|_{z(t)=\hat{z}(t), v_1(t)=0} \quad (3.2.11)$$

é a matriz Jacobiana das derivadas parciais das equações do processo em relação aos ruídos do processo.

$$H(t) = \left. \frac{\partial h(z(t), u(t), v_2(t))}{\partial z(t)} \right|_{z(t)=\hat{z}(t), v_2(t)=0} \quad (3.2.12)$$

é a matriz Jacobiana das derivadas parciais da equação de observação  $h$ , em relação aos estados e

$$J(t) = \left. \frac{\partial h(z(t), u(t), v_1(t))}{\partial v_2(t)} \right|_{z(t)=\hat{z}(t), v_2(t)=0} \quad (3.2.13)$$

é matriz Jacobiana das derivadas parciais da equação de observação  $h$ , em relação aos ruídos dos instrumentos de leitura.

Aplicando o filtro de Kalman para a equação linear 3.2.9, tem-se o filtro de Kalman estendido, dado pelas seguintes equações:

$$\hat{z}(t+1) = f(\hat{z}(t), u(t), 0) + L(t)[y(t) - h(\hat{z}(t), u(t), 0)]; \quad \hat{z}(0) = \hat{z}_0 \quad (3.2.14)$$

onde  $L(t)$  é o ganho do filtro e é dado por:

$$L(t) = [F(t)P(t)H(t)^T + \bar{S}(t)][H(t)P(t)H(t)^T + \bar{R}(t)]^{-1} \quad (3.2.15)$$

A matriz covariância dos estados estimados é atualizada segundo a equação:

$$\begin{aligned} P(t+1) &= F(t)P(t)F(t)^T + \bar{Q}(t) - L(t)[H(t)P(t)H(t)^T + \bar{R}(t)]L(t)^T \\ P(t_0) &= P_0 \end{aligned} \quad (3.2.16)$$

Com

$$\begin{aligned}
 \bar{Q}(t) &= G(t)QG(t)^T \\
 \bar{S}(t) &= G(t)SJ(t)^T \\
 \bar{R}(t) &= J(t)RJ(t)^T
 \end{aligned}
 \tag{3.2.17}$$

O FKE não é ótimo em geral podendo ser considerado sub-ótimo (*Maciel Filho, 1989*). De fato, ele pode ser pensado como um *filtro mais complexo* do que o filtro de Kalman, o qual é forçado a ter um formato semelhante àquele. Devido à aproximação linear realizada, esse filtro pode divergir, e a utilização deste método deve ser acompanhada por extensas simulações. Várias melhoras para este algoritmo já foram propostas, incluindo um refinamento iterativo na linearização (*Goodwin & Sin, 1984*).

Tem sido grande o interesse na aplicação do filtro de Kalman estendido na estimativa de estados de processos que apresentam usualmente dificuldades em serem monitorados. Essa dificuldade tem surgido principalmente pela falta de instrumentos de medida de concentração precisos e em tempo real pois as medidas confiáveis desta grandeza, por exemplo cromatografia, só são disponíveis com um grande atraso. Aplicações no monitoramento de reatores CSTR (*Lynch & Ramirez, 1975*), processos biotecnológicos (*Gallegos & Gallegos, 1984; Stephanopoulos & San, 1984a; 1984b; 1984c; 1984d; Pons et al., 1988; Chattaway & Stephanopoulos, 1989; Gudi et al., 1994; Sargantanis & Karim, 1994*), reatores de polimerização (*Choi & Khan, 1988; Dimitratos et al., 1991; Kozub & McGregor, 1992; Eliçabe et al., 1995*), Reatores de Leito Fixo (*Sørensen et al., 1980; Chen & Sun, 1991*), evaporadores (*Molle & Himmelblau, 1987*) e processo de fabricação de semi-condutores (*Carroll & Ramirez, 1990*) têm motivado a pesquisa nesta área.

### 3.2.3 - Estimativa de Estado utilizando Observadores de Estado

Os métodos convencionais de estimativa de estado geralmente envolvem o ajuste de um conjunto de dados amostrados a um modelo do processo. Quando este está no estado estacionário o ajuste consiste na solução de um sistema não linear de equações. No entanto, se os dados pertencerem à fase dinâmica do sistema, o modelo é composto por equações diferenciais e no ajuste será necessário realizar derivações nos sinais medidos.

É importante notar que se deve evitar diferenciar uma variável de estado para gerar uma outra. A

diferenciação de um sinal sempre diminui a relação sinal para ruído porque o ruído geralmente flutua mais rapidamente do que o sinal de comando. Às vezes a relação sinal para ruído pode ser diminuída de várias vezes por um único processo de diferenciação. No entanto, há métodos disponíveis para estimar variáveis de estado não-mensuráveis sem um processo de diferenciação.

A estimativa de estados não-mensuráveis é comumente chamada *observação*. Um dispositivo (ou um programa de computador) que estima ou observa as variáveis de estado é chamado um *observador de estado*, ou simplesmente um *observador*. Se o observador de estado observa todas as variáveis de estado do sistema, independentemente se algumas variáveis de estado estão disponíveis para medida direta, é chamado um *observador de estado de ordem plena*. Há instantes em que isto não será necessário, quando se necessita apenas de observação das variáveis de estado não-mensuráveis mas não daquelas que são diretamente mensuráveis. Por exemplo, como as variáveis de saída são observáveis e elas estão linearmente relacionadas às variáveis de estado, não se necessita observar todas as variáveis de estado, mas apenas  $(n-m)$  variáveis de estado, onde  $n$  é a dimensão do vetor de estado e  $m$  é a dimensão do vetor de saída. O observador de estado que observa somente o número mínimo de variáveis de estado é denominado um *observador de estado de ordem mínima* ou, simplesmente, *observador de ordem mínima*.

Então, um **observador de estado** estima as variáveis de estado baseado nas medidas das variáveis de saída e de controle e o conceito de observabilidade representa um importante papel pois, os observadores de estado podem ser projetados se, e somente se, a condição de observabilidade for satisfeita. Deve-se ressaltar que o filtro de Kalman e suas variantes é um observador de estado particular, que possui certas propriedades estatísticas.

### **3.3 - Estimativa de Parâmetros**

#### **3.3.1 - Introdução**

Um dos problemas práticos encontrados no monitoramento e controle de processos químicos, além da falta de medida direta de determinados estados, é a dificuldade na determinação de certos parâmetros do modelo matemático. Esta dificuldade pode ser agravada quando esses parâmetros variam com o tempo, aumentando o grau de incerteza do modelo para controle. Uma das maneiras de contornar essa dificuldade é realizar a estimativa dos parâmetros tempo real, isto é, realizar de tempos em tempos

a atualização dos parâmetros do modelo utilizando os dados passados das entradas e saídas do processo, procedimento conhecido como *identificação do modelo ou do sistema*.

A estimativa dos parâmetros ou identificação do sistema pode ser realizada fora do tempo de operação (*off-line*) ou em tempo real (*on-line*). A estimativa *off-line* consiste em ajustar os parâmetros, dispondo-se de uma certa quantidade de informações das variáveis de estado, a um modelo do processo através da utilização de um método conveniente de otimização. Esse método procura minimizar uma função objetivo adequadamente escolhida e em geral envolve um procedimento iterativo com alto esforço computacional, embora já sejam disponíveis métodos sequenciais para a estimativa *off-line* (Solbrand et al., 1985).

A estimativa *on-line* é mais interessante do ponto de vista de controle, pois a utilização de um método sequencial requer um esforço computacional muito menor quando comparado com a estimativa *off-line* utilizando um algoritmo de otimização. Neste método, a amostragem de um novo dado é utilizada apenas para atualizar o modelo do processo (atualização dos parâmetros) e quando se parte de um valor inicial estimado, essa atualização propicia a convergência dos parâmetros aos seus valores exatos. Os algoritmos que propiciam este ajuste em tempo real do modelo aos novos dados são conhecidos como recursivos. Há muitos algoritmos de identificação recursivos propostos na literatura, sendo um dos mais comuns o dos **mínimos quadrados recursivos**, aplicável à equações à diferenças lineares e que será visto no item 3.3.3.

### **3.3.2 - Estimativa de Parâmetros de Modelos Estocásticos Espaço-de-Estados utilizando Filtro de Kalman Estendido**

Quando o modelo do processo possui parâmetros incertos e que necessitam ser estimados juntamente com os estados, o vetor de estados do filtro de Kalman pode ser aumentado de modo a incluir os parâmetros desconhecidos. Este procedimento é mostrado neste item, para o caso do modelo do processo ser da forma linear.

Considere o modelo espaço-de-estados estocástico linear e com dimensões finitas dado pela seguinte equação:

$$\begin{aligned}x(t+1) &= Ax(t) + Bu(t) + v_1(t); & x(0) &= x_0 \\ y(t) &= Cx(t) + v_2(t)\end{aligned}\quad (3.3.1)$$

$x(t_0)$  tem média  $\bar{x}_0$  e covariância  $P_0$  e

$$E\left\{\begin{bmatrix} v_1(t) \\ v_2(t) \end{bmatrix} \begin{bmatrix} v_1(\tau)^T & v_2(\tau)^T \end{bmatrix}\right\} = \begin{bmatrix} Q & S \\ S^T & R \end{bmatrix} \delta(t - \tau);$$

$$Q \geq 0, \quad R > 0$$

Em geral  $A$ ,  $B$ ,  $C$ ,  $Q$ ,  $R$  e  $S$  dependem todos do vetor de parâmetros  $\theta$  (vetor de parâmetros a serem estimados). Os parâmetros desconhecidos do sistema podem ser incluídos em um modelo na forma espaço-de-estados, admitindo que estes seguem a equação:

$$\theta(t+1) = \theta(t) \quad (3.3.2)$$

Deste modo a equação 3.3.1 pode ser escrita como:

$$\begin{aligned}x(t+1) &= A(\theta(t))x(t) + B(\theta(t))u(t) + v_1(t); & x(0) &= x_0 \\ y(t) &= C(\theta(t))x(t) + v_2(t)\end{aligned}\quad (3.3.3)$$

$x(t_0)$  tem média  $\bar{x}_0$  e covariância  $P_0$  e

$$E\left\{\begin{bmatrix} v_1(s) \\ v_2(s) \end{bmatrix} \begin{bmatrix} v_1(t)^T & v_2(t)^T \end{bmatrix}\right\} = \begin{bmatrix} Q(\theta(t)) & S(\theta(t)) \\ S(\theta(t))^T & R(\theta(t)) \end{bmatrix} \delta(t - s);$$

Pode-se pensar nas equações acima como sendo equações estocásticas na forma espaço-de-estados não lineares em termos do vetor composto  $(x(t), \theta(t))$ , e então aplicar o filtro de Kalman

estendido para a estimativa conjunta dos estados e dos parâmetros. Para isto, considere o seguinte vetor aumentado:

$$z(t) = \begin{pmatrix} x(t) \\ \theta(t) \end{pmatrix} \quad (3.3.4)$$

Tem-se então as seguintes equações de estado não-lineares:

$$\begin{aligned} z(t+1) &= f(z(t), u(t), v_1(t)) \\ y(t) &= h(z(t), u(t), v_2(t)) \end{aligned} \quad (3.3.5)$$

onde:

$$\begin{aligned} f(z(t), u(t), v_1(t)) &= \begin{bmatrix} A(\theta(t))x(t) + B(\theta(t))u(t) + v_1(t) \\ \theta(t) \end{bmatrix} \\ h(z(t), u(t), v_2(t)) &= C(\theta(t))x(t) + v_2(t) \end{aligned} \quad (3.3.6)$$

Definindo:

$$M(\hat{\theta}(t), \hat{x}(t), u(t)) = \frac{\partial}{\partial \theta} (A(\theta)\hat{x}(t) + B(\theta)u(t)) \Big|_{\theta=\hat{\theta}(t)}$$

$$D(\hat{\theta}(t), \hat{x}(t)) = \frac{\partial}{\partial \theta} (C(\theta)\hat{x}(t)) \Big|_{\theta=\hat{\theta}(t)}$$

e

$$M_t \stackrel{\Delta}{=} M(\hat{\theta}(t), \hat{x}(t), u(t)), \quad D_t \stackrel{\Delta}{=} D(\hat{\theta}(t), \hat{x}(t)), \quad A_t \stackrel{\Delta}{=} A(\hat{\theta}(t)), \quad B_t \stackrel{\Delta}{=} B(\hat{\theta}(t)), \quad C_t \stackrel{\Delta}{=} C(\hat{\theta}(t))$$

$$W_t \stackrel{\Delta}{=} [H(t)P(t)H(t)^T + \bar{R}(t)]$$

Então o filtro de Kalman estendido, para processos lineares, pode ser escrito explicitamente como:

1 - predição dos novos estados:

$$\hat{x}(t+1) = A_t \hat{x}(t) + B_t u(t) + L_t(t)[y(t) - C_t \hat{x}(t)]; \quad \hat{x}(0) = \hat{x}_0 \quad (3.3.7)$$

2 - predição dos novos parâmetros:

$$\hat{\theta}(t+1) = \hat{\theta}(t) + L_2(t)[y(t) - C_t \hat{x}(t)]; \quad \hat{\theta}(0) = \hat{\theta}_0 \quad (3.3.8)$$

onde:

$$L_1(t) = [A_t P_{11}(t) C_t^T + M_t P_{12}^T(t) C_t^T + A_t P_{12}(t) D_t^T + M_t P_{12}(t) D_t^T + S] W_t^{-1} \quad (3.3.9)$$

$$L_2(t) = [P_{12}^T(t) C_t^T + P_{22}(t) D_t^T] P_t^{-1} \quad (3.3.10)$$

$$W_t = C_t P_{11}(t) C_t^T + C_t P_{12}(t) D_t^T + D_t P_{12}^T(t) C_t^T + D_t P_{22}(t) D_t^T + R \quad (3.3.11)$$

$$P_{11}(t+1) = A_t P_{11}(t) A_t^T + A_t P_{12}(t) M_t^T + M_t P_{12}^T(t) A_t^T + M_t P_{12}(t) M_t^T - L_1(t) P_t(t) L_1^T(t) + Q; \quad (3.3.12)$$

$$P_{11}(0) = P_{11}^0$$

$$P_{12}(t+1) = A_t P_{12}(t) + M_t P_{22}(t) - L_1(t) P_t(t) L_2^T(t); \quad P_{12}(0) = P_{12}^0 \quad (3.3.13)$$

$$P_{22}(t+1) = P_{22}(t) - L_2(t) P_t(t) L_2^T(t); \quad P_{22}(0) = P_{22}^0 \quad (3.3.14)$$

É de se notar que o algoritmo acima depende do conhecimento das matrizes covariância dos ruídos (Q, S e R). Esta informação pode não ser disponível já que não é assumido um total conhecimento da dinâmica do processo, motivo da utilização dos modelos estocásticos. Tem sido observado através de simulações e aplicações práticas que o algoritmo acima pode fornecer estimativas tendenciosas e algumas vezes pode até mesmo divergir (*Goodwin & Sin 1984*). A não convergência do algoritmo é em geral resultado da combinação de diversos fatores dentre os quais uma especificação incorreta das covariâncias dos ruídos ou a dependência do ganho do filtro com os parâmetros estimados. Levando esses fatores em consideração, *Ljung (1979)* propôs uma modificação do algoritmo acima e que tem uma melhor robustez em termos de convergência das estimativas. Maiores detalhes acerca deste algoritmo podem ser encontrados em *Goodwin & Sin (1984)*.

No desenvolvimento acima considerou-se um modelo linear. No entanto, a mesma metodologia pode ser usada para o caso de modelos não lineares. A idéia básica é aumentar o vetor de estados pela

adição do(s) parâmetro(s) a ser(em) estimado(s):  $\theta(t+1) = \theta(t)$ . Deste modo, o algoritmo para o filtro de Kalman estendido, apresentado no item 3.2.1, pode ser aplicado diretamente (Caminal *et al.*, 1987; Johnson & Palsson, 1994).

Uma outra estratégia de estimativa conjunta de estados e parâmetros apresentada por Goodwin & Sin (1984) é utilizar o filtro de Kalman ou o filtro de Kalman estendido (dependendo do tipo de modelo), apenas na estimativa de estados e realizar a estimativa de parâmetros utilizando um estimador sequencial, em paralelo (Ramirez, 1987). Essa metodologia tem a vantagem de evitar possíveis problemas de convergência do filtro.

### 3.3.3 - Estimativa de Parâmetros de Modelos Estocásticos na forma de Equações à Diferenças Lineares

Há um grande número de algoritmos para identificação recursiva de modelos na forma de equações à diferenças lineares descritos na literatura, sendo o mais comum deles o algoritmo dos mínimos quadrados recursivos com suas inúmeras variantes, descrito a seguir.

Supondo um processo descrito pela equação à diferenças linear que relaciona a entradas  $u$  e a saída  $y$  do processo:

$$A(z^{-1})y(t) = B(z^{-1})u(t-1) + d \quad (3.3.15)$$

onde  $d$  representa a presença de uma perturbação e há o atraso de um tempo de amostragem entre a entrada e a saída. Nesta equação, pode-se isolar o termo  $y(t)$ , e escrevê-la na seguinte forma:

$$y(t) = \psi^T(t)\theta + \varepsilon(t) \quad (3.3.16)$$

onde

$\psi$  é o vetor que contém os dados de entrada e saída (regressor) de  $n$  e  $m$  tempos passados respectivamente, onde  $n$  e  $m$  representam a ordem do modelo:

$$\psi^T(t) = [y(t-1), y(t-2), y(t-n), \dots, u(t-1), u(t-2), u(t-m), 1] \quad (3.3.17)$$

2 -  $\theta$  é o vetor dos parâmetros a serem estimados:

$$\theta^T = [a_1, a_2, \dots, b_1, b_2, \dots, d] \quad (3.3.18)$$

onde  $a_i$  e  $b_i$  são os coeficientes do modelo descrito pela Equação 3.3.15.

3 -  $\varepsilon$  são as incertezas do modelo (erro) que é assumido ser estatisticamente independente das entradas e saídas do sistema.

O procedimento mais lógico para o problema de adaptação dos parâmetros é assumir um modelo que descreve como os parâmetros “verdadeiros”  $\theta_0$  mudam. Uma escolha típica é assumir que sua mudança ocorre de maneira randômica:  $\theta_0(t) = \theta_0(t-1) + w(t)$ , onde  $w(t)$  é considerado como sendo um ruído branco Gaussiano com matriz covariância  $R_1$ , ou seja,  $Ew(t)w^T(t) = R_1$  e que os dados observados devem se ajustar ao modelo linear:

$$y(t) = \psi^T(t)\theta_0(t) + \varepsilon(t) \quad (3.3.19)$$

Partindo destas considerações o algoritmo dos mínimos quadrados recursivos é proposto como sendo um procedimento para atualizar os parâmetros de modo que a equação linear represente a relação entre a entrada e a saída do processo.

### 3.3.3.1- Algoritmo dos Mínimos Quadrados Recursivos

O problema de estimativa de parâmetros é o de estimar os parâmetros ( $\hat{\theta}$ ) desconhecidos de tal modo que se satisfaça uma determinada restrição. No método dos mínimos quadrados essa restrição é a minimização da função mostrada abaixo:

$$J = \sum_{t=1}^{n_d} (y(t) - \hat{y}(t))^2 \quad (3.3.20)$$

onde  $\hat{y}$  é o valor da saída predito, baseado em  $\hat{\theta}$ , e  $y$  é o valor atual fornecido pelo instrumento de leitura;  $n_d$  é o número de pontos disponíveis;  $y - \hat{y}$  é o erro estimado. O método dos mínimos quadrados procura minimizar o erro quadrático entre a saída medida e a predita.

As equações para o cálculo dos mínimos quadrados recursivos são:

- atualização dos parâmetros:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + K(t)[y(t) - \hat{y}(t)] \quad (3.3.21)$$

- cálculo do ganho  $K(t)$

$$K(t) = \frac{P(t-1)\psi(t)}{I + \psi^T(t)P(t-1)\psi(t)} \quad (3.3.22)$$

- cálculo da covariança  $P(t)$

$$P(t) = [I - K(t)\psi^T(t)]P(t-1) \quad (3.3.23)$$

onde:  $\hat{y}(t) = \psi^T(t)\hat{\theta}(t-1)$ ;  $P$  é a matriz covariança do erro estimado (dimensão  $(n+m+1) \times (n+m+1)$ ).  $P(t)$  é uma matriz positiva que representa uma medida do erro estimado e seus elementos tendem a decrescer à medida que  $t$  aumenta.

O algoritmo acima é inteiramente especificado dados as estimativas iniciais para o vetor de parâmetros  $\hat{\theta}(0)$ , vetor de saída  $y(t)$  e uma estimativa inicial para  $P(0)$ .

### 3.3.3.2 - Mínimos quadrados recursivos com fator de esquecimento

O algoritmo dos mínimos quadrados recursivos apresentado no item anterior pode ser

modificado com a finalidade de manter sua sensibilidade às variações dos parâmetros do processo. A modificação mais conhecida é a que permite ponderar os novos dados mais do que os antigos e isto pode ser conseguido através da inclusão de um fator exponencial (chamado fator de esquecimento) no índice de desempenho:

$$J(\theta(t)) = \sum_{i=1}^t \lambda^{t-i} [\psi^T(i-I)\theta(i) - y(i)]^2 \quad (3.3.24)$$

onde  $\lambda$  é um fator exponencial de peso com valor entre zero e um:  $0 < \lambda \leq 1$ . Quando  $\lambda = 1$  todos os dados são ponderados de igual maneira. Para  $0 < \lambda < 1$ , mais peso é dado às novas medidas. Na realidade o efeito da presença do fator exponencial é prevenir que os elementos da matriz  $P$  tornem-se muito pequenos. Isto mantém a sensibilidade do algoritmo e permite que novos dados continuem a afetar os parâmetros estimados. O algoritmo completo, que satisfaz o índice de desempenho apresentado acima, é apresentado a seguir:

- atualização dos parâmetros:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + K(t)[y(t) - \hat{y}(t)] \quad (3.3.25)$$

- cálculo de  $K(t)$

$$K(t) = \frac{P(t-1)\psi(t)}{\lambda(t) + \psi^T(t)P(t-1)\psi(t)} \quad (3.3.26)$$

- cálculo de  $P(t)$

$$P(t) = \frac{1}{\lambda(t)} \left( P(t-1) + \frac{-P(t-1)\psi(t)\psi^T(t)P(t-1)}{\lambda(t) + \psi^T(t)P(t-1)\psi(t)} \right) \quad (3.3.27)$$

onde:  $\hat{y}(t) = \psi^T(t)\hat{\theta}(t-1)$ . O algoritmo é completamente especificado dados  $\lambda$ ,  $P(0)$ ,  $\theta(0)$  e a sequência de dados  $\psi(t)$ ,  $t = 1, 2, 3, \dots$

Além da introdução do fator de esquecimento no algoritmo dos mínimos quadrados recursivos há inúmeras outras modificações propostas na literatura (Isermann, 1982; Ydstie, 1987; Shah & Cluett, 1991).

### 3.3.3.3 - Algoritmo recursivo baseado no filtro de Kalman

Uma estimativa ótima de  $\theta$  pode ser realizada através do filtro de Kalman (Ljung, 1987), cujo algoritmo completo é apresentado a seguir.

A variação dos parâmetros pode ser modelada na forma espaço-de-estados da seguinte forma:

$$\begin{aligned}\theta(t+1) &= \theta(t) + \omega(t) \\ y(t) &= \psi^T(t)\theta(t) + v(t)\end{aligned}\tag{3.3.28}$$

Aplicando as equações do filtro de Kalman à equação acima com  $A(t) = I$ ,  $C(t) = \psi^T(t)$ , tem-se:

- atualização dos parâmetros:

$$\hat{\theta}(t) = \hat{\theta}(t-1) + K(t)[y(t) - \hat{y}(t)]\tag{3.3.29}$$

- cálculo de  $K(t)$

$$K(t) = \frac{P(t-1)\psi(t)}{R_2 + \psi^T(t)P(t-1)\psi(t)}\tag{3.3.30}$$

- cálculo de  $P(t)$

$$P(t) = P(t-1) + R_1 + \frac{-P(t-1)\psi(t)\psi^T(t)P(t-1)}{R_2 + \psi^T(t)P(t-1)\psi(t)} \quad (3.3.31)$$

onde:  $\hat{y}(t) = \psi^T(t)\hat{\theta}(t-1)$ ;  $R_1$  e  $R_2$  são as covarianças das incertezas dos parâmetros e das medidas, respectivamente.

O algoritmo é completamente especificado dados  $R_1$ ,  $R_2$ ,  $P(0)$ ,  $\theta(0)$  e a sequência de dados  $\psi(t)$ ,  $t = 1, 2, 3, \dots$

Uma das técnicas mais recentes de identificação de processos tem sido a utilização de Redes Neurais Artificiais (*Karjala & Himmelblau, 1994; Cheng et al., 1995; Megan & Cooper, 1995*) no reconhecimento de padrões com promissores desempenhos. A utilização desta estratégia parece caminhar no sentido de se prover um método universal de identificação e estimativa, apesar de que até o momento o treinamento em tempo real de redes neurais artificiais ainda continua sendo um problema ainda não completamente resolvido.

### 3.4 - Caso Estudo: Estimativa Recursiva de Estados e Parâmetros, utilizando Filtro de Kalman Estendido, de um Sistema Fermentativo em Batelada para Produção de Cerveja

#### 3.4.1 - Introdução

O procedimento mais usual para a estimativa de estados e parâmetros do modelo tem sido a utilização de um estimador de estado, como por exemplo o filtro de Kalman, acoplado a um estimador recursivo de parâmetros. Uma outra alternativa é utilizar o FKE (Filtro de Kalman Estendido) para realizar ambas as estimativas, além de outras técnicas de estimativa simultânea.

Um típico sistema que requer identificação simultânea dos estados do processo e parâmetros do modelo é o reator de fermentação em batelada, pois os parâmetros cinéticos, como por exemplo o fator de frequência da constante da taxa de reação (suposta seguir o modelo de Arrhenius, na dependência com a temperatura), podem mudar de batelada a batelada ou durante uma mesma fermentação, devido à alterações biológico-genéticas nos microrganismos fermentativos.

#### 3.4.2 - Modelo Matemático e Parâmetros Utilizados

Um modelo matemático para o reator de fermentação de cerveja foi desenvolvido por *Ramirez e Gee (1985)* baseado no trabalho de *Engasser et al. (1981)*. Assume-se que no meio fermentativo há três açúcares, a saber, glicose, maltose e maltotriose, como nutrientes limitantes. As taxas de consumo dos três açúcares são dados pelos seguintes balanços materiais, baseados no modelo cinético de Monod:

Glicose:

$$\frac{dG}{dt} = \frac{-V_G G}{K_G + G} X \quad (3.4.1)$$

Maltose:

$$\frac{dM}{dt} = \frac{-V_M M}{(K_M + M)(K_I G + G)} X \quad (3.4.2)$$

Maltotriose:

$$\frac{dN}{dt} = \frac{-V_N N}{(K_N + N)} \frac{Kl_G}{(Kl_G + G)} \frac{Kl_M}{(Kl_M + M)} X \quad (3.4.3)$$

onde:

$G$  = concentração de glicose, mol/m<sup>3</sup>

$M$  = concentração de maltose, mol/m<sup>3</sup>

$N$  = concentração de maltotriose, mol/m<sup>3</sup>

$X$  = concentração de biomassa, mol/m<sup>3</sup>

$V_i$  = constante da taxa de consumo da espécie  $i$ , 1/h

$K_i$  = constante de Michaelis para a espécie  $i$ , mol /m<sup>3</sup>

$Kl_i$  = constante da taxa de inibição para a espécie  $i$ , mol/m<sup>3</sup>

As taxas de produção de biomassa e etanol são equações algébricas em função das concentrações dos açúcares e, portanto, não serão consideradas variáveis de estado necessárias ao modelo dinâmico. Essas taxas estão relacionadas às concentrações individuais de açúcar através das relações:

$$X = X_o - R_{XG}(G - G_o) - R_{XM}(M - M_o) \quad (3.4.4)$$

$$E = -R_{EG}(G - G_o) - R_{EM}(M - M_o) - R_{EN}(N - N_o) \quad (3.4.5)$$

onde:

$R_{Xi}$  = produção estequiométrica de biomassa por mol de açúcar reagido, mol de biomassa/mol de açúcar,

$R_{Ei}$  = produção estequiométrica de etanol por mol de açúcar reagido, mol de etanol/mol de açúcar.

A taxa de mudança na temperatura do meio fermentativo é dada por:

$$\frac{dT}{dt} = \frac{1}{\rho C_p} \left[ \Delta H_{FG} \frac{dG}{dt} + \Delta H_{FM} \frac{dM}{dt} + \Delta H_{FN} \frac{dN}{dt} - u(T - T_c) \right] \quad (3.4.6)$$

O controlador utilizado em malha fechada foi um *feedback* proporcional:

$$u = K_p (T - T_{set}) \quad (3.4.7)$$

onde  $u$  é a taxa de resfriamento dada por:

$$u = \frac{UA}{V} \quad (3.4.8)$$

onde:

$C_p$  = capacidade calorífica da mistura, kJ/kg.°C

$\rho$  = densidade da mistura, kg/m<sup>3</sup>

$T$  = temperatura, °C

$\Delta H_{Fi}$  = calor de fermentação, kJ/mol

$u$  = taxa de resfriamento do fermentador, kJ/h.m<sup>3</sup>.°C

$U$  = coeficiente global de transferência de calor, kJ/h.m<sup>2</sup>.°C

$A$  = área de transferência de calor, m<sup>2</sup>

$V$  = volume da mistura fermentativa, m<sup>3</sup>

$T_c$  = temperatura do fluido refrigerante, °C

Assume-se que todas as constantes das taxas cinéticas seguem o modelo de Arrhenius na dependência com a temperatura:

$$V_i = V_{i0} \exp[-E_{vi}/R(T+273.15)] \quad (3.4.9)$$

$$K_i = k_{i0} \exp[-E_{ki}/R(T+273.15)] \quad (3.4.10)$$

$$Kl_i = kl_{i0} \exp[-E_{lki}/R(T+273.15)] \quad (3.4.11)$$

onde:

$V_{io}$  = fator de frequência da taxa de velocidade, 1/h

$k_{io}$  = fator de frequência da constante de Michaelis, mol/m<sup>3</sup>

$kl_{io}$  = fator de frequência da constante de inibição, mol/m<sup>3</sup>

$E_{vi}$  = energia de ativação da taxa de velocidade, cal/mol

$E_{ki}$  = energia de ativação da constante de Michaelis, cal/mol

$E_{l_{ki}}$  = energia de ativação da constante de inibição, cal/mol

Os parâmetros do modelo para a fermentação de cerveja em batelada foram determinados por *Gee e Ramirez (1987)* e são mostrados nas Tabelas 3.1 e 3.2.

Tabela 3.1 - Parâmetros Reacionais e Cinéticos

Parâmetros reacionais			
Açúcar	$R_{Ei}$	$R_{Xi}$	$\Delta H_{Fi}$ (kJ/mol)
Glicose	1,92	0,134	-91,2
Maltose	3,84	0,268	-226,3
Maltotriose	5,76	0,402	-361,3
Constantes de Arrhenius			
Parâmetros	Energia de ativação		ln do fator de frequência
	(kcal/mol)		
$V_G$	22,6		35,77
$V_M$	11,3		16,4
$V_N$	7,16		10,59
$K_G$	-68,6		-121,3
$K_M$	-14,4		-19,15
$K_N$	-19,9		-26,78
$Kl_G$	10,2		23,33
$Kl_M$	26,3		55,61

Tabela 3.2 - Condições iniciais e Parâmetros do Equipamento.

$G(t_0) = 70 \text{ g mol/m}^3$	$X(t_0) = 175 \text{ g mol/m}^3$
$M(t_0) = 220 \text{ g mol/m}^3$	$T(t_0) = 8 \text{ }^\circ\text{C}$
$N(t_0) = 40 \text{ g mol/m}^3$	
$A = 0.188 \text{ m}^2$	$u_{\min} = 0 \text{ kJ/m}^3 \text{ h }^\circ\text{C}$
$C_p = 4.016 \text{ kJ/kg }^\circ\text{C}$	$u_{\max} = 40 \text{ kJ/m}^3 \text{ h }^\circ\text{C}$
$\rho = 1040 \text{ kg/m}^3$	$V = 0,1 \text{ m}^3$
$K_p = 1000 \text{ kJ/h }^\circ\text{C m}^3$	$T_c = 0 \text{ }^\circ\text{C}$

As equações 3.4.1, 3.4.2, 3.4.3 e 3.4.6 constituem o modelo dinâmico do sistema e utilizando-se de um método adequado de integração, como por exemplo o algoritmo de Runge-Kutta de 5ª ordem, obtêm-se os dados, considerados corretos, correspondentes à resposta dinâmica do processo fermentativo, que pode ser vista nas Figuras 3.1 a 3.3.

A Figura 3.1 mostra o consumo de açúcar, onde pode ser visto que há primeiro o consumo de glicose, seguido do de maltose e depois maltotriose. A Figura 3.2 mostra a evolução da temperatura do meio reacional com o tempo. Nota-se que há um aumento gradual da temperatura de 8 °C, condição inicial, até o *set point* de 12 °C quando permanece estável, com pequena oscilação. O resfriamento só começa quando a temperatura atinge 12 °C. A Figura 3.3 mostra a produção de álcool e de biomassa onde se nota que a taxa de produção de álcool desacelera quando a glicose é totalmente consumida.

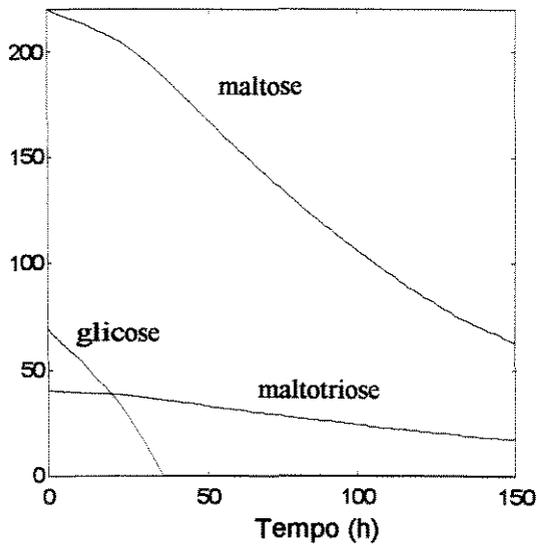


Figura 3.1 - Concentração de açúcar (mol/m<sup>3</sup>).

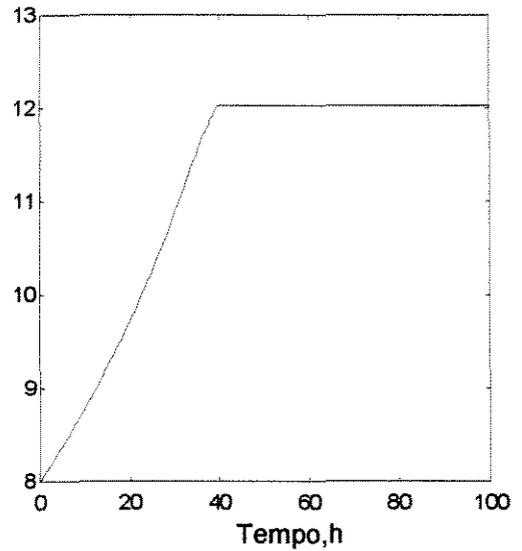


Figura 3.2 - Temperatura do meio reacional (°C).

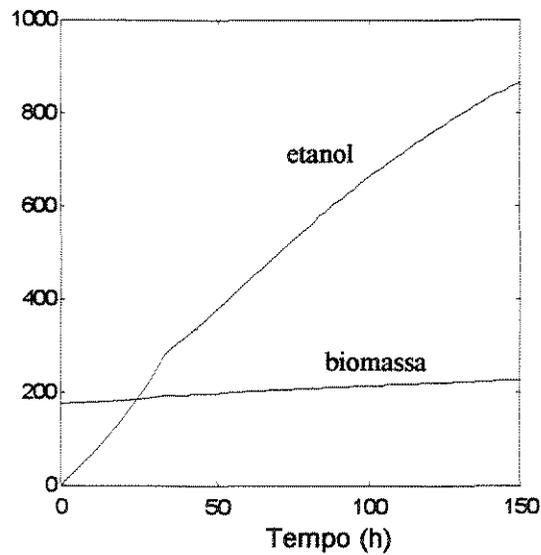


Figura 3.3 - Concentração de etanol e biomassa produzidos (mol/m<sup>3</sup>).

### 3.4.3 - Estimativa de Estados e Parâmetros

Como a proposta deste trabalho é que as estimativas sejam feitas de maneira recursiva as equações do modelo dinâmico necessitam ser discretizadas a fim de constituírem o *modelo do processo para o filtro de Kalman*. Essa discretização foi feita utilizando a aproximação de Euler de 1ª ordem aplicada às equações 3.4.1 a 3.4.3 e 3.4.6. Tem-se assim o seguinte modelo na forma discreta:

concentração de glicose:

$$G(t+1) = G(t) + \left( \frac{-V_G G(t)}{K_G + G(t)} X(t) \right) \Delta t \quad (3.4.12)$$

concentração de maltose:

$$M(t+1) = M(t) + \left( \frac{-V_M M(t)}{(K_M + M(t))} \frac{Kl_G}{(Kl_G + G(t))} X(t) \right) \Delta t \quad (3.4.13)$$

concentração de maltotriose:

$$N(t+1) = N(t) + \left( \frac{-V_N N(t)}{(K_N + N(t))} \frac{Kl_G}{(Kl_G + G(t))} \frac{Kl_M}{(Kl_M + M(t))} X(t) \right) \Delta t \quad (3.4.14)$$

temperatura do meio reacional:

$$T(t+1) = T(t) + \left( \frac{1}{\rho C_p} \left[ \Delta H_{FG} G(t+1) + \Delta H_{EM} M(t+1) + \Delta H_{FN} N(t+1) - u(T(t) - T_c) \right] \right) \Delta t \quad (3.4.15)$$

concentração de biomassa:

$$X(t) = X_o - R_{XG}(G(t) - G_o) - R_{XM}(M(t) - M_o) \quad (3.4.16)$$

concentração de etanol:

$$E(t) = -R_{EG}(G(t) - G_o) - R_{EM}(M(t) - M_o) - R_{EN}(N(t) - N_o) \quad (3.4.17)$$

Na estimativa dos parâmetros, considera-se que os mesmos obedecem a equação na forma:

$$\theta(t+1) = \theta(t) + w(t) \quad (3.4.18)$$

Sendo o parâmetro a ser estimado  $V_{Go}$ , o vetor de estados  $z$  terá então a seguinte forma:

$$z(t+1) = \begin{bmatrix} G(t+1) \\ M(t+1) \\ N(t+1) \\ T(t+1) \\ V_{Go}(t+1) \end{bmatrix} \quad (3.4.19)$$

Nota-se que o vetor de estados  $z$ , foi aumentado de modo a incluir o parâmetro a ser estimado como se o mesmo fosse um estado do sistema. Este artifício permite que os parâmetros desconhecidos do modelo sejam estimados de maneira recursiva e pela utilização direta das equações do filtro de Kalman estendido.

A equação 3.4.19 constitui então o modelo interno do filtro de Kalman. Como este modelo é muito próximo do modelo de simulação espera-se que a matriz  $Q$  tenha um valor bastante baixo, pois como já mencionado, essa matriz reflete o grau de incerteza do modelo empregado pelo filtro. Propõe-se neste trabalho que seja realizada a medida apenas de concentração de glicose e temperatura do meio reacional. A matriz observação  $C$  (ou a função  $h$ ) tem então a seguinte forma:

$$h = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

Objetivando distanciar o modelo de simulação em relação ao modelo do filtro, corrompeu-se os dados de leitura com um ruído branco de média zero, distribuição normal e desvio padrão  $2 \text{ gmol/m}^3$  para concentração de glicose e  $0,25 \text{ }^\circ\text{C}$  para a temperatura. Deste modo, a matriz  $R$  tem então os seguintes valores:

$$R = \begin{bmatrix} 4 & 0 \\ 0 & 0,0625 \end{bmatrix} = \text{diag}\{4 \ 0,0625\}$$

Considera-se que o estado inicial é conhecido de forma exata, a menos do parâmetro estimado. A matriz  $P_0$ , que representa as incertezas do estado inicial, então é:

$$P_0 = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & P_{vgo} \end{bmatrix} = \text{diag}\{0 \ 0 \ 0 \ 0 \ P_{vgo}\}$$

onde  $P_{vgo}$  é um número suficientemente grande para permitir a convergência do parâmetro estimado.

O valor correto do parâmetro  $V_{Go}$  a ser estimado é 35,77. Nas simulações considerou-se um valor inicial para esse parâmetro igual a 40, portanto um valor aproximadamente 12 % superior ao correto.

As matrizes  $G$ ,  $S$  e  $J$  têm os seguintes valores:

$$G = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{bmatrix} = I(5,5)$$

$$S = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{bmatrix} \text{ e } J = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$

e  $H = J$ .

#### 3.4.4 - Resultados e Discussão

Utilizando as equações do filtro de Kalman estendido aplicadas ao modelo descrito

anteriormente (equação 3.4.19) e  $P_0 = \text{diag}\{ 0 \ 0 \ 0 \ 0 \ 10^4\}$ ,  $\mathbf{R}$ ,  $\mathbf{G}$ ,  $\mathbf{J}$  e  $\mathbf{H}$  com valores apresentados acima, tempo de amostragem de 30 min e

$$Q = \begin{bmatrix} 0,01 & 0 & 0 & 0 & 0 \\ 0 & 0,01 & 0 & 0 & 0 \\ 0 & 0 & 0,01 & 0 & 0 \\ 0 & 0 & 0 & 0,01 & 0 \\ 0 & 0 & 0 & 0 & 0,01 \end{bmatrix} = I(5,5) * 0,01$$

obteve-se os resultados mostrados nas Figuras 3.4 a 3.9, onde a cor preta denota o valor correto da variável obtida da integração do modelo dinâmico, a cor vermelha o valor amostrado (valor exato corrompido) e a cor azul o valor estimado.

Como pode ser observado na Figura 3.4, após um curto intervalo de tempo, devido ao valor inicial incorreto de  $V_{G0}$ , há uma concordância perfeita entre a concentração de glicose estimada e seu valor correto. O mesmo se dá com a concentração de etanol produzido, mostrado na Figura 3.5. Para os outros dois açúcares, maltose e maltotriose, a concordância entre o valor estimado e o exato é excelente em todo o intervalo de tempo. Isto se deve ao fato do modelo do filtro ser bastante próximo ao modelo de simulação e os valores de concentração desses açúcares não terem sido utilizados como dados de leitura, portanto, não foram corrompidos.

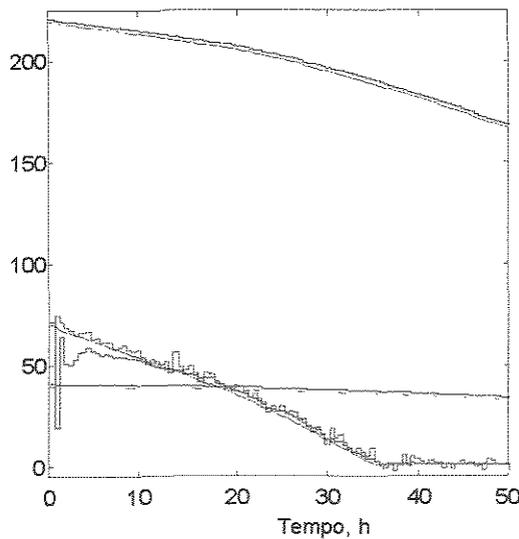


Figura 3.4- Concentração de glicose, maltose e maltotriose. (--- valor exato; --- valor amostrado; --- valor estimado).

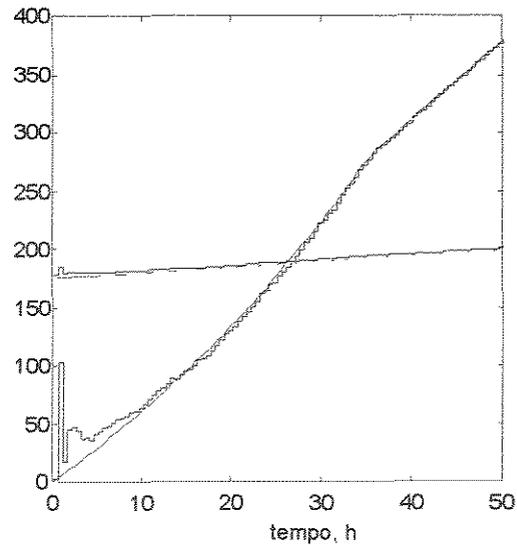


Figura 3.5- Concentração de biomassa e etanol. (--- valor exato; --- valor estimado).

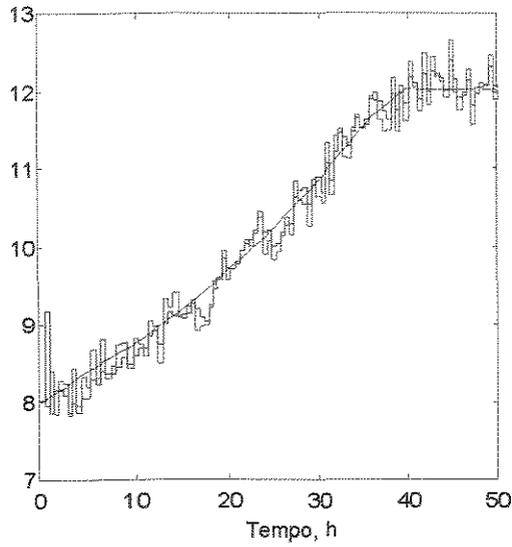


Figura 3.6- Temperatura do meio reacional (--- valor exato; ... valor amostrado; -.- valor estimado).

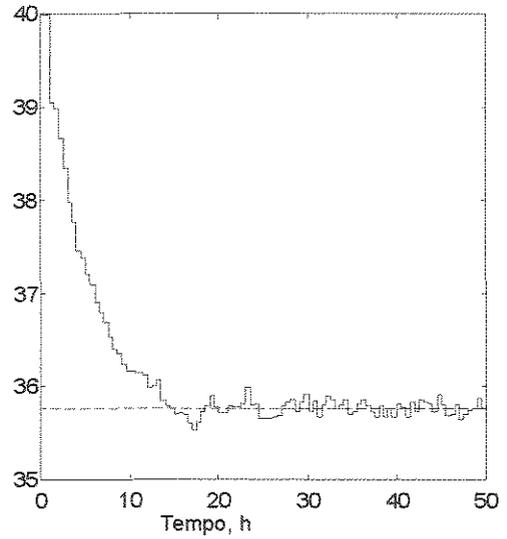


Figura 3.7- Parâmetro estimado.

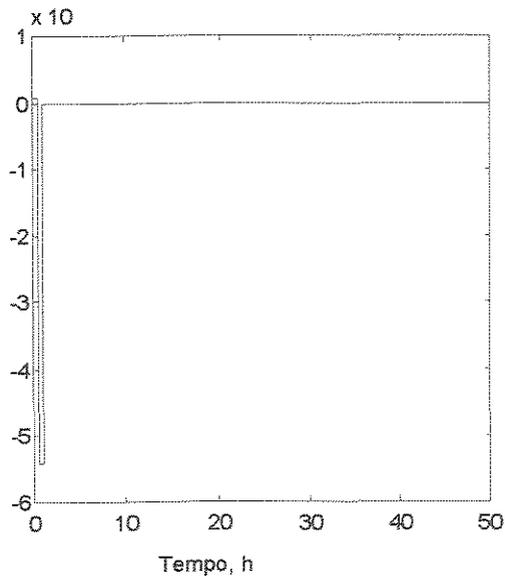


Figura 3.8- Covariância do parâmetro estimado.

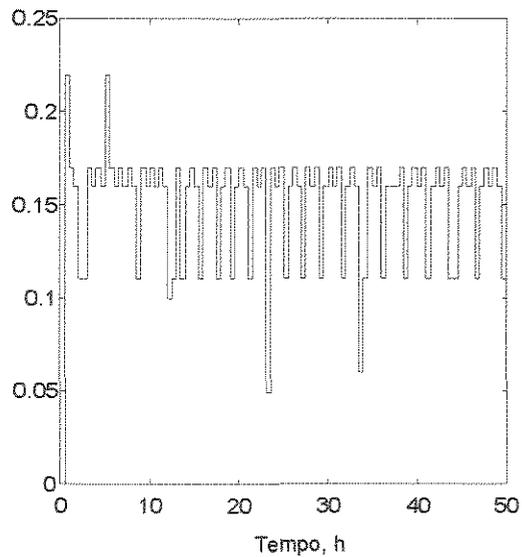


Figura 3.9- Tempo de CPU gasto para realizar os cálculos em cada intervalo de amostragem.

A Figura 3.6 mostra o valor estimado para a temperatura do sistema. Observa-se que para ambas as variáveis amostradas o filtro consegue eliminar com bastante sucesso as incertezas nos seus valores. A Figura 3.7 mostra o parâmetro estimado que, apesar de uma estimativa inicial incorreta, converge rapidamente para o seu valor correto e fica oscilando em torno do mesmo.

O valor da covariância  $P_0$  para o parâmetro estimado pode ser visto na Figura 3.8. No caso de um sistema real, no qual não se conhece o valor exato do parâmetro a ser estimado, essa variável ( $P_0$ ) reflete uma medida da distância entre o valor atual estimado do parâmetro e o seu valor estimado no estado estacionário e seu valor pode ser utilizado como um critério de parada da estimativa recursiva. Outro critério que também pode ser utilizado é a diferença entre o valor calculado atual do parâmetro estimado e o seu valor no intervalo de amostragem anterior. Quando essa diferença for menor do que uma determinada tolerância desejada a estimativa está completa.

A Figura 3.9 mostra o tempo de CPU gasto por um PC 486 DX2, 66 Mz, efetuar todos os cálculos requeridos entre duas amostragens. Esse tempo, como pode ser verificado nessa figura, é inferior a 3 s que é muito menor que o tempo de amostragem (30 min), mostrando assim que o algoritmo do filtro de Kalman estendido possui plenas condições de ser implementado em um processo real.

As Figuras 3.10 a 3.13 mostram o resultado da estimativa quando a matriz covariância do processo possui um valor alto:  $Q = I(5,5) * 10$ , ou seja, um valor superestimado. Os demais parâmetros foram mantidos com os mesmos valores da simulação anterior.

Um alto valor para a matriz  $Q$ , como o adotado, informa ao filtro de Kalman estendido que as equações do modelo têm um alto grau de incerteza, portanto, não deve corrigir muito o valor amostrado em função da diferença entre valor amostrado e valor predito pelo modelo. Como esses valores (os amostrados) foram corrompidos, a estimativa dos estados e parâmetros mostra-se muito mais oscilatória e com valores piores do que os valores amostrados. Nota-se também que o parâmetro estimado converge para seu valor correto, porém oscila em torno desse valor de forma bem acentuada chegando mesmo a divergir após 35 h.

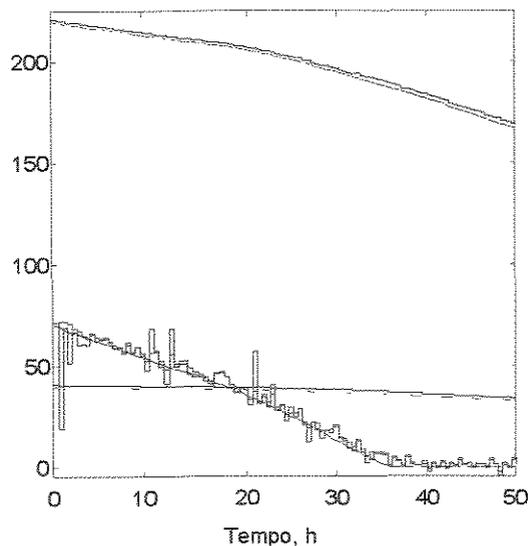


Figura 3.10 - Concentração de glicose, maltose e maltotriose. (--- valor exato; --- valor amostrado; --- valor estimado). Valor incorreto de  $Q$ .

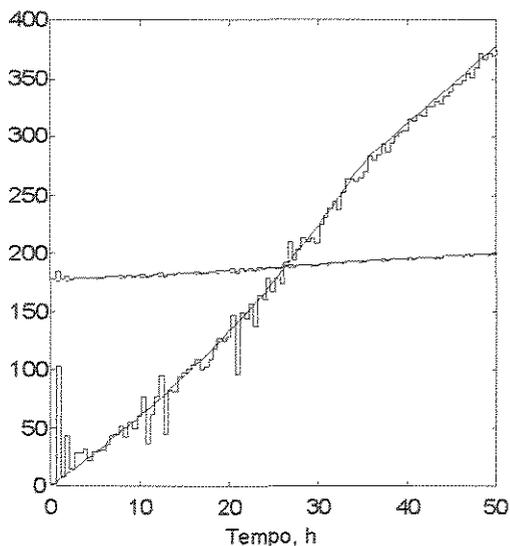


Figura 3.11- Concentração de biomassa e etanol. (--- valor exato; --- valor estimado). Valor incorreto de  $Q$ .

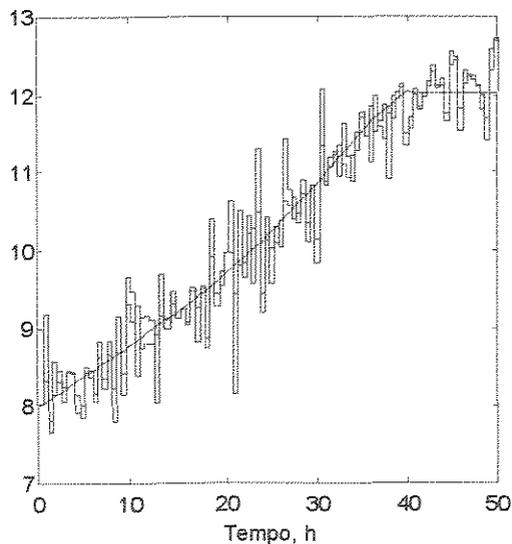


Figura 3.12- Temperatura do meio reacional (--- valor exato; --- valor amostrado; --- valor estimado). Valor incorreto de  $Q$ .

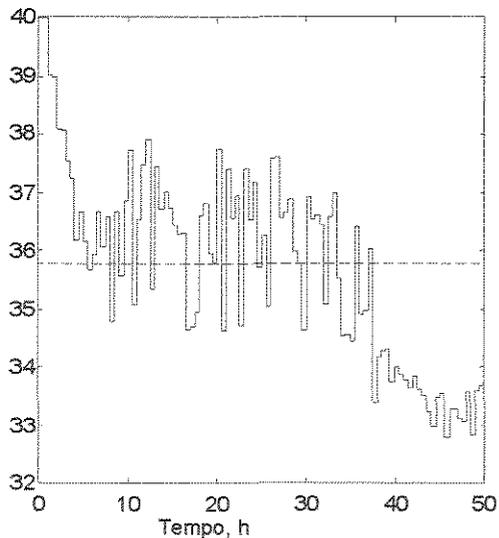


Figura 3.13- Parâmetro estimado quando se utiliza  $Q$  superestimado.

Os demais gráficos são similares à simulação anterior.

A Figura 3.14 mostra o parâmetro estimado para diferentes valores de  $P_0$ :

(1)  $P_0 = \text{diag} \{ 0 \ 0 \ 0 \ 0 \ 10^4 \}$

(2)  $P_0 = \text{diag} \{ 0 \ 0 \ 0 \ 0 \ 10 \}$

(3)  $P_0 = \text{diag} \{ 0 \ 0 \ 0 \ 0 \ 10^{-1} \}$

(4)  $P_0 = \text{diag} \{ 0 \ 0 \ 0 \ 0 \ 10^{-4} \}$

Para este caso em particular a velocidade de convergência do parâmetro estimado não se mostrou sensível à  $P_0$ , pois para todos os casos essa velocidade foi praticamente a mesma.

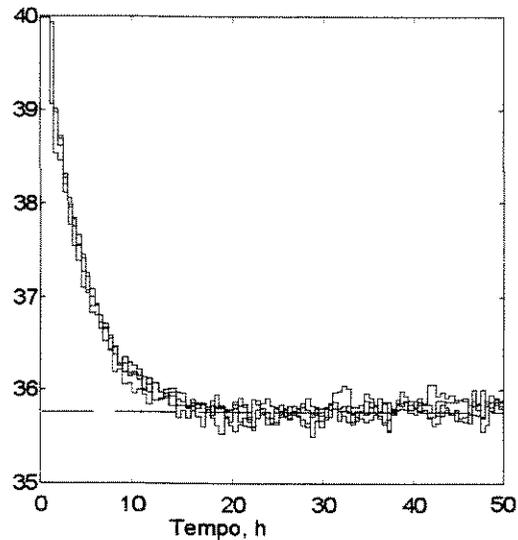


Figura 3.14- Parâmetro estimado para diferentes valores de  $P_0$ .

Uma especificação incorreta para o valor de  $R$  produz resultados similares aos produzidos por um valor incorreto de  $Q$ . A Figura 3.15 mostra os resultados para o parâmetro estimado quando se utilizou  $P_0 = \text{diag} \{ 0 \ 0 \ 0 \ 0 \ 10 \}$ ,  $Q = I(5,5) * 0,01$ , e  $R = \text{diag} \{ 0,01 \ 0,0001 \}$ . Como  $R$  foi ajustado para valores bem menores do que as variâncias dos ruídos empregados, o filtro “confia” muito nos valores (corrompidos) amostrados em detrimento ao valor predito pelo modelo, causando grandes oscilações nos estados e parâmetro estimados.

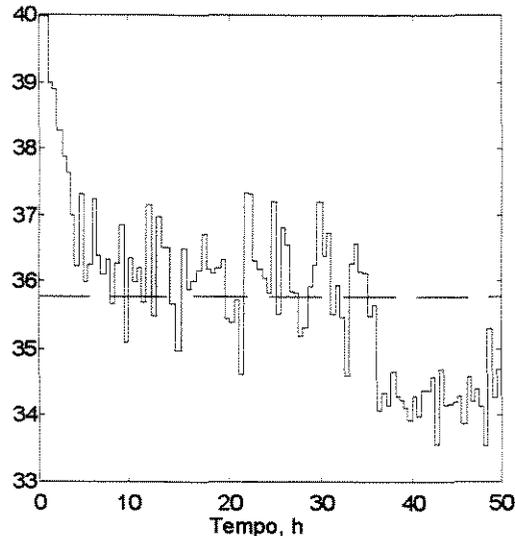


Figura 3.15 - Parâmetro estimado quando se utiliza R subestimado.

Já quando se utiliza um R superestimado, ou seja, com valores bem acima daqueles que correspondem ao ruído empregado, como por exemplo  $R = \text{diag}\{10 \ 1\}$  os valores estimados (estados e parâmetros) convergem para seus valores corretos, porém com uma velocidade muito menor, quando comparado com os resultados produzidos utilizando o valor correto de R. Esses resultados podem ser vistos nas Figuras 3.16 a 3.19.

Um valor superestimado de R informa ao filtro que o ruído dos instrumentos de leitura é maior do que o realmente empregado e que portanto deve corrigir mais vigorosamente os valores amostrados. Nota-se que essa correção mais vigorosa é benéfica do ponto de vista que produz resultados mais suavizados, ou seja, com menos oscilações. Os demais parâmetros empregados foram os mesmos da simulação anterior. ( $P_0 = \text{diag}\{0 \ 0 \ 0 \ 0 \ 10\}$ ,  $Q = I(5,5)*0,01$ )

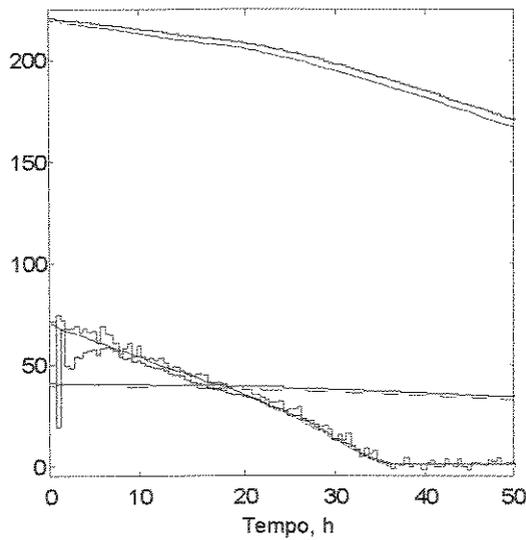


Figura 3.16- Concentração de glicose, maltose e maltotriose. (--- valor exato; --- valor amostrado; --- valor estimado). Valor incorreto de R.

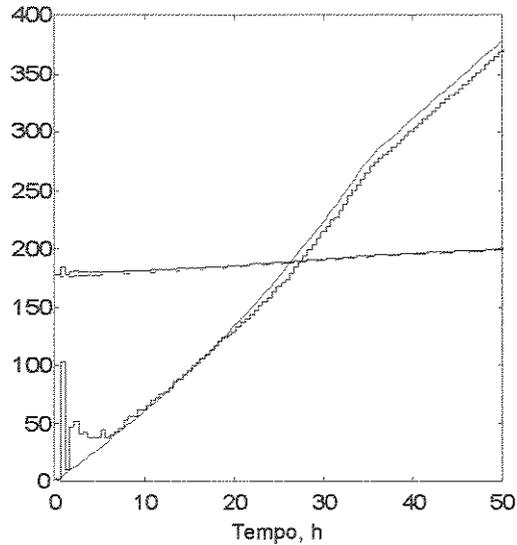


Figura 3.17- Concentração de biomassa e etanol. (--- valor exato; --- valor estimado). Valor incorreto de R.

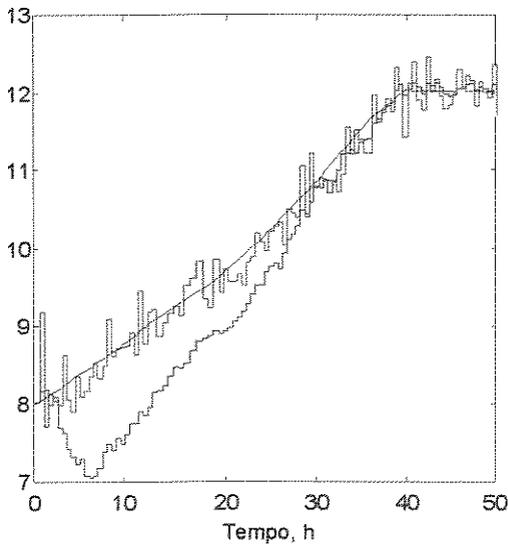


Figura 3.18- Temperatura do meio reacional (--- valor exato; --- valor amostrado; --- valor estimado). Valor incorreto de R.

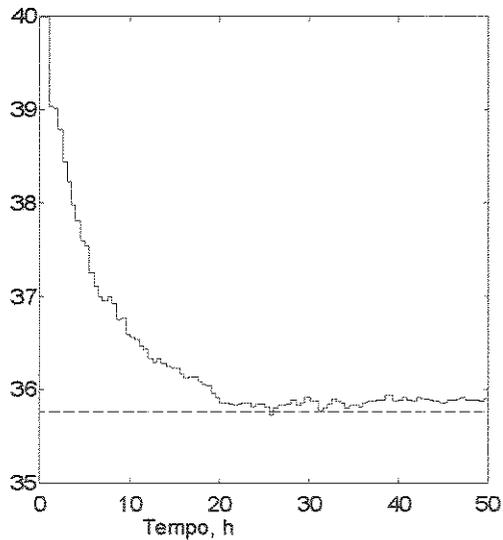


Figura 3.19- Parâmetro estimado quando se utiliza R superestimado.

Para todas as simulações anteriores utilizou-se um tempo de amostragem de 30 min. Objetivando

investigar a influência dessa variável nas estimativas, esse tempo foi reduzido para 5 min e os resultados podem ser vistos nas Figuras 3.20 a 3.23. Observa-se nesses resultados que a convergência foi mais rápida e sem grandes flutuações, principalmente no início da estimativa. Essa melhora dos resultados é justificada por diversos fatores. O primeiro deles, e talvez o mais importante, é que como o modelo discreto utilizado pelo filtro de Kalman foi obtido a partir da discretização do modelo dinâmico utilizando Euler, esta aproximação tende ao resultado correto à medida que o tempo de discretização diminui, portanto resultando em um modelo para o filtro mais confiável. Outro fator é que com amostragens menores as atuações do filtro são mais frequentes, evidentemente, evitando predições com horizontes de tempo muito grandes. Os parâmetros utilizados foram:  $P_0 = \text{diag}\{0 \ 0 \ 0 \ 0 \ 10\}$ ,  $Q = I(5,5)*0,01$ ,  $R = \text{diag}\{4 \ 0,0625\}$ .

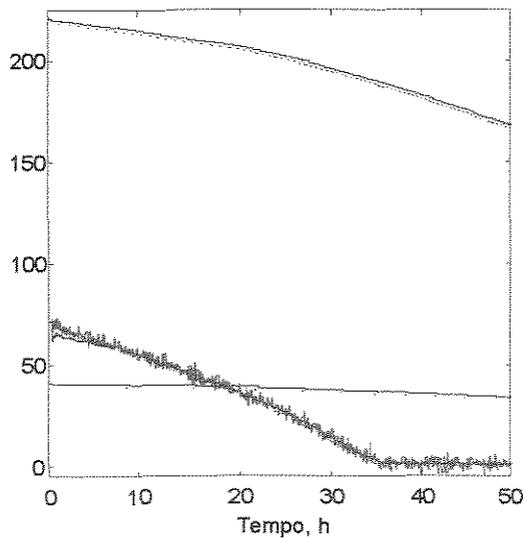


Figura 3.20- Concentração de glicose, maltose e maltotriose. (--- valor exato; --- valor amostrado; --- valor estimado). Tempo de amostragem de 5 min.

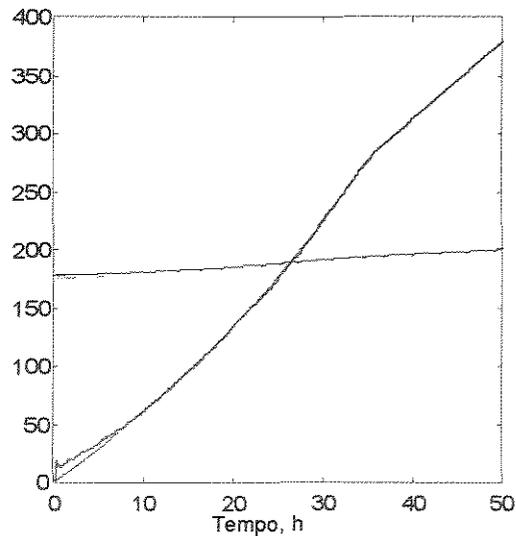


Figura 3.21- Concentração de biomassa e etanol. (--- valor exato; --- valor estimado). Tempo de amostragem de 5 min.

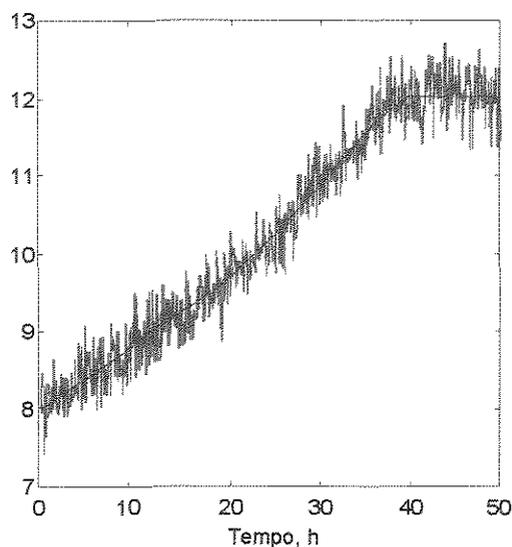


Figura 3.22- Temperatura do meio reacional (--- valor exato; --- valor amostrado; --- valor estimado). tempo de amostragem de 5 min.

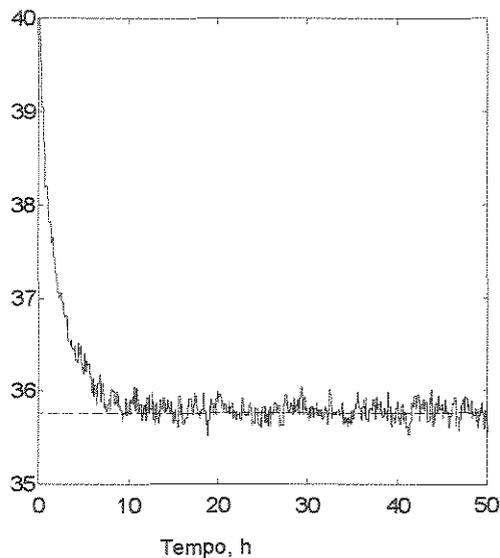


Figura 3.23 - Parâmetro estimado quando se utiliza tempo de amostragem de 5 min.

Utilizando os mesmos parâmetros anteriores porém aumentando o tempo de amostragem para 1 h, a estimativa fica mais lenta e com maiores oscilações no início, quando o parâmetro ainda não convergiu ao seu valor correto. As Figuras 3.24 a 3.27 mostram os resultados.

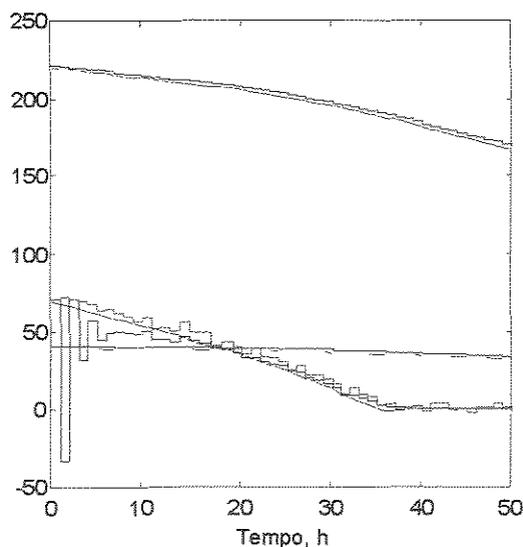


Figura 3.24- Concentração de glicose, maltose e maltotriose. (--- valor exato; --- valor amostrado; --- valor estimado). Tempo de amostragem de 1h.

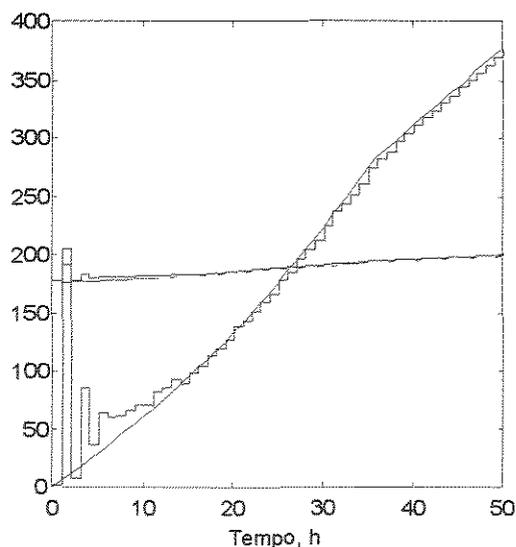


Figura 3.25- Concentração de biomassa e etanol. (--- valor exato; --- valor estimado).

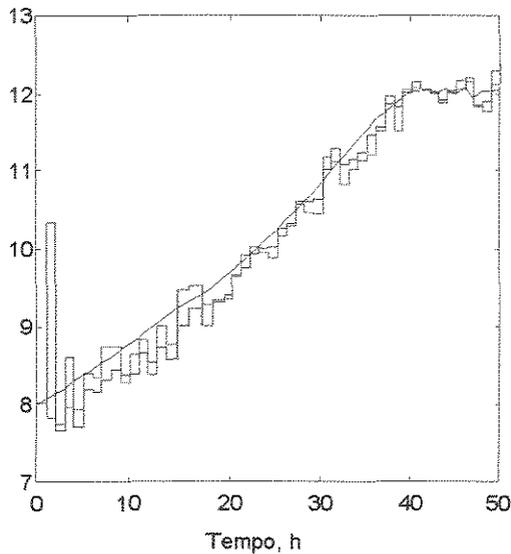


Figura 3.26- Temperatura do meio reacional (--- valor exato; --- valor amostrado; --- valor estimado). Tempo de amostragem: 1 h.

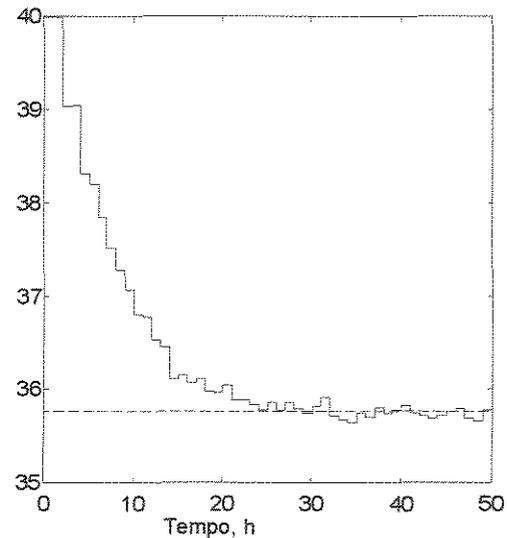


Figura 3.27- Parâmetro estimado para tempo de amostragem de 1h.

Como pode ser observado nas Figuras 3.26 3.27, apesar da oscilação inicial ser mais vigorosa quando comparada com resultados utilizando um tempo de amostragem menor, ainda assim há a convergência dos estados e parâmetros estimados, porém com uma velocidade menor.

Objetivando investigar a capacidade do filtro de Kalman estendido na estimativa simultânea de dois parâmetros,  $V_{Go}$  e  $V_{Mo}$  foram considerados desconhecidos e estimados inicialmente como sendo 40.0 e 20.0 respectivamente (os valores reais são 35.77 e 16.4 respectivamente). Como pode ser observado nas Figuras 3.28 e 3.29 os parâmetros convergem rapidamente para os seus valores corretos sendo que a convergência é acelerada com a diminuição do tempo de amostragem. Os parâmetros do filtro utilizados foram:  $Q = \text{diag} \{0,01 \ 0,01 \ 0,01 \ 0,01 \ 0,03 \ 0,07\}$ ;  $P_0 = \text{diag}\{0 \ 0 \ 0 \ 0 \ 1.10^3 \ 1.10^3\}$ ;  $S = 0$  e  $R$  igual aos casos anteriores.

A Figura 3.30 mostra o desempenho do filtro de Kalman na estimativa de um parâmetro que varia linearmente com o tempo. O parâmetro considerado desconhecido foi  $V_{Go}$  e os parâmetros do filtro utilizados foram os mesmos mencionados anteriormente na simulação da Figura 3.7. Observa-se

que o estimador consegue acompanhar as variações do parâmetro estimado porém necessita-se de tempos em tempos reinicializar a matriz covariância  $P_0$ .

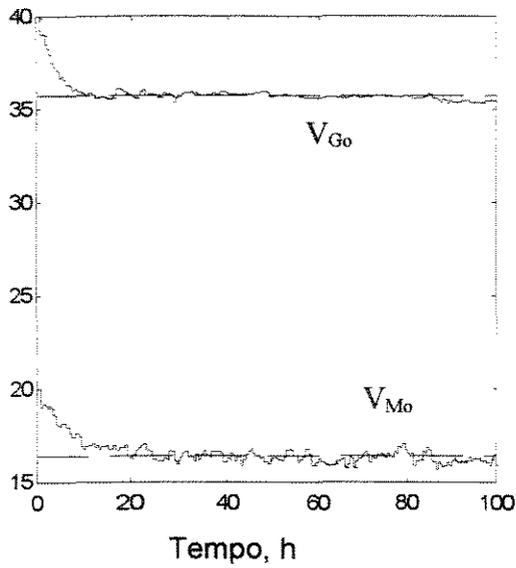


Figura 3.28 - Estimativa simultânea de dois parâmetros do modelo (tempo de amostragem de 0.5 h).

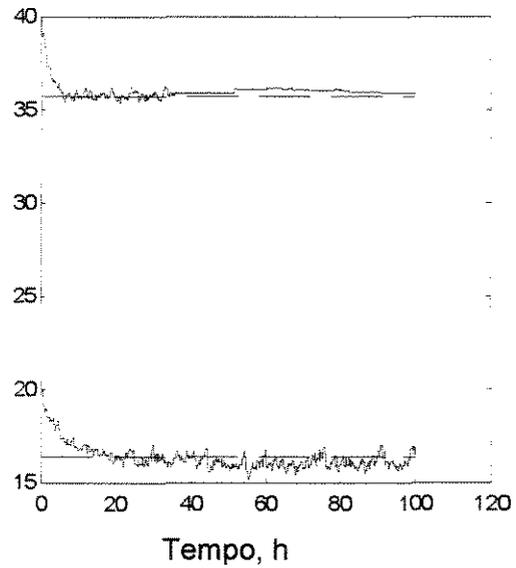


Figura 3.29 - Estimativa simultânea de dois parâmetros do modelo (tempo de amostragem de 0.2 h).

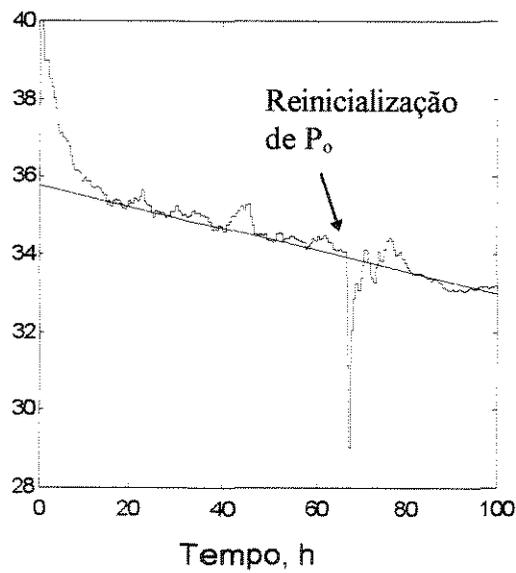


Figura 3.30 - Estimativa de parâmetro tempo-variante.

### **3.5 - Conclusões**

A identificação de processos em tempo real é uma ferramenta importante no monitoramento e controle de sistemas químicos e correlatos, pois permite a estimativa de estados inacessíveis ou de difícil e/ou caras medidas, a filtragem de medidas portadoras de ruídos e a estimativa de parâmetros com valores incertos.

Para modelos escritos na forma espaço-de-estados o filtro de Kalman provê uma estimativa ótima dos estados em sistemas estocásticos lineares e uma extensão deste algoritmo, o filtro de Kalman estendido, permite a estimativa conjunta de estados e parâmetros de modelos lineares ou não.

Os modelos na forma de equações à diferenças lineares podem ser identificados utilizando o algoritmo dos quadrados mínimos recursivos ou uma de suas variantes.

Os desenvolvimentos mais recentes na área de identificação em tempo real de sistemas estão na área da aplicação de redes neurais artificiais para o reconhecimento de padrões.

Finalmente, foi aplicado com sucesso o filtro de Kalman estendido na estimativa de estados e parâmetros de um processo biotecnológico fermentativo em batelada, que é um típico sistema que requer a estimativa conjunta de estados e parâmetros. Mostrou-se condições de convergência do filtro, influência dos parâmetros de projeto deste algoritmo, capacidade de estimativa simultânea de mais de um parâmetro e parâmetros tempo-variantes.

# CAPÍTULO IV

## PROJETO DE CONTROLADORES ADAPTATIVOS AUTO-AJUSTÁVEIS

### **4.1 - Introdução**

Qualquer sistema de controle deve ser estável. Esta é uma exigência primordial. Além da estabilidade absoluta um sistema de controle deve ter uma estabilidade relativa aceitável; assim, a resposta deve apresentar certo amortecimento. Além disso, a velocidade de resposta deve ser mais ou menos rápida e o sistema de controle deve ser capaz de reduzir erros a zero ou a algum valor tolerável. Qualquer sistema de controle útil deve satisfazer a estes requisitos.

A exigência de estabilidade relativa aceitável e a exigência de precisão no estado estacionário tendem a ser incompatíveis e um bom projeto de sistema de controle tem que balancear estas duas exigências:

Este capítulo apresenta três métodos de projeto de controladores adaptativos auto-ajustáveis e estáveis. O primeiro método objetiva minimizar a variância da variável de saída e por isso é chamado de controlador de variância mínima. Este foi o método de projeto utilizado por *Åström & Wittenmark (1973)* na proposta inicial do *Self-Tuning Regulator*. O segundo método é aplicável a sistemas descritos na forma espaço-de-estados e provê um projeto ótimo: é o controle LQG. E, finalmente, o terceiro método é o que utiliza o critério de imposição dos pólos em malha fechada.

Pela extensão dos assuntos, apresenta-se aqui apenas uma descrição objetiva dos critérios de projeto, sendo fornecidos ao longo do capítulo referências adicionais que apresentam um tratamento mais detalhado do assunto.

### **4.2 - Projeto de Sistemas de Controle Moderno**

Na teoria convencional de controle, apenas os sinais de entrada, saída e de erro são considerados

importantes; a análise e projeto dos sistemas de controle são feitos usando-se funções de transferência, juntamente com uma variedade de técnicas tais como a técnica do lugar das raízes e os diagramas de Bode.

A principal desvantagem da teoria de controle convencional é que, de modo geral, ela é aplicável apenas para sistemas lineares, invariantes no tempo e tendo uma única entrada e uma única saída. Ela é impotente para sistemas variantes no tempo, sistemas não lineares (exceto os mais simples) e sistemas de múltiplas entradas e múltiplas saídas. Portanto, as técnicas convencionais (os métodos do lugar das raízes e de resposta em frequência) não se aplicam ao projeto de sistemas de controle ótimos e adaptativos, que são principalmente variantes no tempo e/ou não lineares.

O projeto de sistemas de controle pela teoria convencional é baseado nos procedimentos de tentativa e erro que, em geral, não produzem sistemas de controle ótimos. O projeto de sistemas pela teoria moderna de controle via métodos de espaço-de-estados, por outro lado, permite ao engenheiro projetar tais sistemas tendo pólos de malha fechada desejados (ou equações características desejadas) ou sistemas de controle ótimos com respeito a índices de desempenho requeridos. Além disso, a teoria moderna de controle permite ao projetista incluir condições iniciais, se necessário, no projeto. No entanto, o projeto pela teoria moderna de controle (via métodos de espaço-de-estados) requer descrição matemática precisa (acurada) da dinâmica do sistema. Isto está em contraste com os métodos convencionais, onde, por exemplo, as curvas de resposta em frequência experimentais que não têm precisão suficiente, podem ser incorporadas ao projeto sem suas descrições matemáticas.

Do ponto de vista computacional, os métodos de espaço-de-estados são particularmente adequados para implementação em computadores digitais por causa da abordagem no domínio do tempo. Isto libera o engenheiro de cálculos maçantes que seriam de outra forma necessárias e permite que ele dedique seus esforços apenas para os aspectos analíticos do problema. Esta é uma das vantagens dos métodos de espaço-de-estados.

Finalmente, é importante notar que não é necessário que as variáveis de estado representem grandezas físicas do sistema. Podem-se escolher como variáveis de estado grandezas que não

representam grandezas físicas, bem como aquelas que não são mensuráveis nem observáveis. Tal liberdade de escolha de variáveis de estado é outra vantagem dos métodos de espaço-de-estados.

O projeto de sistemas de controle tem como objetivo prover uma regra para a determinação da decisão de controle presente, sujeita a certas limitações, que minimizará alguma medida de um desvio do comportamento ideal. Tal medida é normalmente provida por um **critério de otimização, ou índice de desempenho**. Na maioria dos casos particulares o comportamento do sistema é otimizado escolhendo-se o vetor de controle de tal forma que o índice de desempenho é minimizado (ou maximizado, conforme o caso).

O índice de desempenho é importante porque determina, em grande parte, a natureza do controle ótimo resultante. Isto é, o controle resultante pode ser linear, não linear, estacionário ou variante no tempo, dependendo da forma do índice de desempenho adotado e cabe ao engenheiro formular esse índice baseado nos requisitos do problema. Portanto, ele influencia a natureza do sistema resultante. Os requisitos do problema normalmente incluem não apenas requisitos de desempenho mas também restrições na forma do controle para assegurar realizabilidade física.

A escolha do índice de desempenho mais apropriado para um dado problema não é uma tarefa fácil, especialmente em sistemas complexos.

### **4.3 - Controle Adaptativo de Variância Mínima**

#### **4.3.1 - O Self-Tuning Regulator**

No STR original de *Åström e Wittenmark (1973)*, o controlador com retroalimentação foi projetado para minimizar a variância da variável de saída  $y$ . Os controladores de variância mínima representam um caminho natural na solução dos problemas de controle de qualidade em aplicações onde as perturbações são importantes. Pela redução da variância da variável de saída o *set point* pode ser movido próximo a uma restrição limitante.

Considere o modelo do processo descrito pela equação ARMAX abaixo:

$$A(q^{-1})y(t) = B(q^{-1})u(t-k) + C(q^{-1})\xi(t) + d(t) \quad (4.3.1)$$

onde os polinômios A e B possuem a mesma ordem, ou seja,  $m = n$ . Esta consideração pode ser feita sem perda de generalidade pois sempre pode-se escolher determinado parâmetro desses polinômios como sendo zero. Assume-se também que todas as raízes de B e C estão localizadas dentro do círculo unitário no plano complexo, isto é, todas estão localizadas na região estável.

A lei de controle adaptativo com variância mínima é então dada por:

$$u(t) = \frac{-F(q^{-1})}{\hat{B}(q^{-1})E(q^{-1})} y(t) \quad (4.3.2)$$

onde E e F são polinômios de ordem  $k-1$  e  $n-1$ , respectivamente, com  $e_0 = 1$ .

Esses polinômios podem ser determinados de maneira única através da identidade:

$$\hat{C}(q^{-1}) = \hat{A}(q^{-1})E(q^{-1}) + q^{-k}F(q^{-1}) \quad (4.3.3)$$

sendo que os polinômios  $\hat{A}$ ,  $\hat{B}$  e  $\hat{C}$  são estimados em tempo real. A desvantagem desta formulação é que a identidade acima tem que ser resolvida em todos os intervalos de amostragem para a determinação de E e F. Uma alternativa para contornar este problema é basear os cálculos do projeto do controle de variância mínima em um modelo preditivo que pode ser derivado combinando as equações (4.3.1) e (4.3.3). O modelo preditivo para o STR tem a forma:

$$y^*(t+k) = -\alpha_1 y(t) - \dots - \alpha_n y(t-n+j) = \beta_0 [u(t) + \beta_1 u(t-j) + \dots + \beta_1 u(t-j)] \quad (4.3.4)$$

onde  $j = n + k - 1$ . A lei de controle com variância mínima pode ser derivada através do rearranjo de (4.3.4), especificando  $y^*(t+k) = 0$  e utilizando os parâmetros  $\hat{\alpha}$  e  $\hat{\beta}$  com base nos dados passados de  $y(t)$  e  $u(t)$ , resultando no *Self-Tuning Regulator*:

$$u(t) = \frac{1}{\hat{\beta}_0} [\hat{\alpha}_1 y(t) + \dots + \hat{\alpha}_n y(t-n+1)] - \hat{\beta}_1 u(t-1) - \dots - \hat{\beta}_l u(t-l) \quad (4.3.5)$$

Em resumo, a cada intervalo de amostragem realiza-se os seguintes cálculos:

1. Os parâmetros estimados  $\hat{\alpha}(t)$  e  $\hat{\beta}(t)$  são atualizados a partir de dados de entrada/saída do processo utilizando um método recursivo de estimativa de parâmetros;
2. A ação de controle atual,  $u(t)$ , é então calculada utilizando a Equação 4.3.5.

O STR descrito pela Equação 4.3.5 não é aplicável à sistemas de controle com *set points* diferentes de zero, não possui ação integral ou controle antecipado. No entanto, todas essas características podem ser incluídas em seu desempenho. Em geral assume-se um valor conhecido para  $\beta_0$  ao invés de estimá-lo em linha, com a finalidade de facilitar a identificação em malha fechada.

As principais desvantagens reveladas com a aplicação do STR em simulações e também em casos práticos, de acordo com *Seborg et al. (1986)* têm sido:

1. A sintonia do controlador em tempo real pode ser difícil de ser alcançada;
2. Um tempo de atraso  $k$  desconhecido ou variante no tempo pode levar um desempenho pobre ou até mesmo instável da malha de controle;
3. O STR não é aplicável diretamente a processos com resposta inversa, onde  $B$  tem um zero fora do círculo unitário;
4. A dificuldade de uma escolha acertada de  $\beta_0$  para o caso de processos com dinâmica incerta.

Em algumas situações onde a atuação do STR causa comportamento oscilatório ou ações de

controle muito vigorosas, a única alternativa prática para a melhoria do desempenho pode ser o aumento no tempo de amostragem, que nem sempre é um parâmetro conveniente de ser ajustado.

### 4.3.2 - O Self-Tuning Controller

O STC (*Self-Tuning Controller*) foi proposto por *Clarke et al.*, (1975) como sendo um aprimoramento do STR ordinário. Mostra-se a seguir uma apresentação informal do seu equacionamento.

Considere o seguinte modelo ARMAX:

$$A(q^{-1})y(t) = B(q^{-1})u(t - k) + C(q^{-1})\xi(t) + d(t) \quad (4.3.6)$$

com  $m = n$  (número de entradas igual ao número de saídas) e  $d = 0$  (ausência de perturbação da carga).

O STC é expresso em termos de uma variável de saída auxiliar  $\phi$  definida como:

$$\phi(t) = P(q^{-1})y(t) + Q(q^{-1})u(t - k) - R(q^{-1})y_r(t) \quad (4.3.7)$$

onde  $y_r$  é o *set point* e P, Q e R são polinômios que necessitam ser especificados na etapa de projeto.

A lei de controle usada no STC é projetada para minimizar a variância da variável auxiliar  $\phi$ . Essa lei de controle, a qual é chamada de lei de controle de variância mínima generalizada ou lei de controle preditiva, tem a seguinte forma:

$$u(t) = \frac{Ry_r(t) - \hat{\phi}_y^*(t + k)}{Q} \quad (4.3.8)$$

onde  $\hat{\phi}_y^*(t + k)$  é a predição estimada para  $\phi(t + k) = P(q^{-1})y(t)$  feita no tempo  $t$ . Esta predição é dada de maneira ótima por:

$$\hat{\phi}_y^* = \frac{\hat{F}y_f(t) + \hat{G}u(t)}{\hat{C}} \quad (4.3.9)$$

onde  $y_f = y/P_d$  e  $G = E.B$ . Os polinômios E e F são determinados de maneira única utilizando a identidade:

$$CP = AE + z^{-k}F / P_d \quad (4.3.10)$$

O polinômio F tem grau  $[(n+1)+\text{grau de } P_d]$ , sendo o grau de F  $(k-1)$ , o que significa que G tem grau  $(n+k-1)$ . Os graus de F e G são importantes já que seus coeficientes são estimados em tempo real no STC. A equação característica em malha fechada é:  $PB + QA = 0$ . Nota-se que o termo de atraso  $q^{-k}$  não aparece na equação característica, pois foi compensado pela utilização da lei de controle preditiva.

Os parâmetros dos polinômios  $\hat{F}$ ,  $\hat{G}$  e  $\hat{C}$  são calculados em linha utilizando um estimador recursivo como, por exemplo, mínimos quadrados estendido. Se é assumido que  $C(q^{-1}) = 1$ , então o algoritmo dos mínimos quadrados recursivos pode ser utilizado na estimativa dos parâmetros.

Se P, Q e R são escolhidos como sendo escalares tal que  $P = R = 1$  e  $Q = \lambda^*(1-q^{-1})$ , pode-se mostrar que o STC minimiza a seguinte função custo quadrática:

$$J = E\{[y(t+k) - y_r(t)]^2 + \lambda^* [u(t) - u(t-1)]^2\} \quad (4.3.11)$$

O escalar  $\lambda^*$  é um parâmetro de projeto, ou seja, necessita ser ajustado convenientemente para tornar a ação de controle mais ou menos vigorosa. Pela penalização do incremento aplicado em  $u(t)$ , o controle resultante contém uma ação de controle integral que provê menores *off sets*.

A lei de controle de variância mínima generalizada (STC) apresentada neste item possui várias vantagens quando comparada com a lei de controle de variância mínima (STR), dentre as quais:

1. Os parâmetros são sintonizados mais facilmente e
2. Pode ser aplicada a processos com resposta inversa.

Tal como o STR, se o tempo de atraso do processo não for bem conhecido ou for variável no tempo, o STC pode levar a um desempenho pobre em malha fechada.

Os controladores adaptativos originais utilizam o mesmo tempo de amostragem para a estimativa dos parâmetros do modelo, cálculo dos parâmetros do controlador e cálculo da ação de controle. Isto é chamado de uma *combinação sincronizada*. Mas, também pode-se usar *combinações desincronizadas* que podem prover:

a) *diferentes tempos de amostragem*. O algoritmo de controle e a estimativa de parâmetros podem ter diferentes tempos de amostragem. Por exemplo, o algoritmo de controle pode tomar decisões a pequenos intervalos de tempo a fim de proporcionar um melhor controle e a estimativa de parâmetros ser realizada a tempos maiores.

b) *projeto condicionado do controlador*. O cálculo ou mudança dos parâmetros do controlador pode depender de certas condições. Por exemplo, quando há uma mudança brusca nos parâmetros do processo, ou a excitação por sinais externos, ou o resultado de uma simulação em malha-fechada sob estas condições.

Antes de inicializar um algoritmo de controle adaptativo os seguintes parâmetros necessitam ser especificados inicialmente:

- To tempo de amostragem
- m ordem do modelo do processo
- d tempo morto do modelo do processo
- $\lambda$  fator de esquecimento (mudanças rápidas nos parâmetros do processo requerem um fator de esquecimento pequeno).

$\lambda^*$  peso da ação de controle. Uma escolha adequada desta variável permite tomar ações de controle mais suaves ou mais vigorosas.

O valor do fator de esquecimento do algoritmo de identificação pode ser escolhido utilizando as seguintes regras heurísticas (*Isermann, 1989*):

- processos com dinâmica constante ou que variam muito lentamente:  $\lambda = 0.99$ ;
- processos com dinâmica que varia muito lentamente e perturbações estocásticas:  
 $0.95 \leq \lambda \leq 0.99$ ;
- mudanças nas variáveis seguindo uma referência tipo onda quadrada:  $0.85 \leq \lambda \leq 0.90$ ;

Os menores valores são válidos para modelos de baixa ordem ( $m=1,2$ ) e valores maiores para modelos de alta ordem.

Uma considerável vantagem dos controladores adaptativos é que todos os parâmetros de projeto podem ser mudados na operação em tempo real. Portanto, o resultado ocasionado por essas mudanças pode ser observado imediatamente.

Além do STC, o STR serviu de base ao desenvolvimento de inúmeros outros tipos de critérios de projeto, todos variantes do STR (*Allidina & Hughes, 1982; Fuchs, 1982; Mäkilä, 1982; Zanker & Wellstead, 1982; Pérez-Correa & Kershenbaum, 1989; Desai & Mahalanabis, 1992; Sakai, 1992*).

#### **4.4 - Controle Adaptativo Ótimo LQG**

Classicamente, sistemas de controle são inicialmente projetados e então sua estabilidade é examinada. Uma abordagem diferente desta é onde as condições para a estabilidade são formuladas em primeiro lugar e então o sistema é projetado dentro destas limitações. Se o segundo critério de estabilidade de Lyapunov for utilizado para formar a base do projeto de um controlador ótimo, então o sistema funcionará com certeza, isto é, a saída do sistema será continuamente dirigida para seu valor desejado. Portanto, o sistema projetado tem uma configuração com características de estabilidade inerentes. Para uma grande classe de sistemas de controle, pode-se mostrar uma relação direta entre as

funções de Lyapunov e os índices de desempenho quadráticos usados na síntese de sistemas de controle ótimo. O controle LQG (*Linear Quadratic Gaussian*), descrito neste item, é uma classe desses sistemas com estabilidade garantida em malha fechada.

A lei de controle com variância mínima procura minimizar a média quadrática do erro entre a saída desejada e a saída real do processo. Similarmente, pode-se definir uma função custo que leve em consideração não só a saída atual mas também as  $N$  futuras saídas produzidas pelo sistema em malha fechada e previstas pelo modelo do processo. Desse modo define-se uma nova função custo que é composta por todos os estados do sistema e entradas e que deve ser minimizada para todos os instantes de amostragem. Nessa função podem-se incluir também variáveis matriciais que irão atuar como pesos de modo a minimizar mais um estado em detrimento a outro e minimizar também a ação de controle objetivando evitar atuações bruscas na variável manipulada.

A solução deste problema é um caso de otimização em que se deseja minimizar uma função custo sujeito à restrições, que são as equações do modelo do processo. Para o caso de sistemas descritos por modelos estocásticos, a lei de controle que minimiza a função custo quadrática, leva ao chamado **problema geral de controle ótimo quadrático estocástico**. Se o modelo for linear e com perturbações estocásticas pertencentes à distribuição normal, o problema é chamado **controle LQG**, cujo desenvolvimento é apresentado a seguir.

#### 4.4.1 - Problema Regulador

Dado um modelo linear, na forma espaço-de-estados, como o apresentado a seguir,

$$\begin{aligned}x(t+1) &= Ax(t) + Bu(t) + v_1(t); & x(0) &= x_0 \\ y(t) &= Cx(t) + v_2(t)\end{aligned}\tag{4.4.1}$$

onde  $v_1(t), v_2(t)$  e  $x_0(t)$  são variáveis randômicas com distribuição normal;  $X_0(t)$  tem média  $\bar{x}_0$ , covariância  $P_0$  e não é correlacionada com  $\{v_1(t)\}$  e  $\{v_2(t)\}$ . Os ruídos  $\{v_1(t)\}$  e  $\{v_2(t)\}$  tem média zero e covariância dada por:

$$E\left\{\begin{bmatrix} v_1(t) \\ v_2(t) \end{bmatrix} \begin{bmatrix} v_1(s)^T & v_2(s)^T \end{bmatrix}\right\} = \begin{bmatrix} Q & 0 \\ 0 & R \end{bmatrix} \delta(t-s)$$

Definindo a função custo:

$$\bar{J}_N = E\{x(N)^T \Omega_N x(N) + \sum_{t=0}^{N-1} (x(t)^T \Omega x(t) + u(t)^T \Gamma u(t))\} \quad (4.4.2)$$

onde  $\Omega$  e  $\Gamma$  são parâmetros de projeto e podem ser mudados em tempo real durante a ação de controle de modo a pesar mais ou menos estados, saídas, etc. A escolha das matrizes de ponderação  $\Omega$  e  $\Gamma$  é de certo modo arbitrária. Embora a minimização de um índice de desempenho quadrático “arbitrário” possa parecer não ter muita significância, a vantagem da técnica de controle ótimo quadrático é que o sistema resultante é um sistema estável. *Isermann et al.* (1985) recomenda as seguintes faixas de valores para esses parâmetros:  $1 \leq \Omega \leq 3$  e  $0,05 \leq \Gamma \leq 0,5$ .

A lei de controle  $u(t)$  que minimiza  $\bar{J}_N$  sujeita às restrições do modelo linear é dada por:

$$\begin{aligned} \hat{x}(t+1) &= A\hat{x}(t) + K(t)[y(t) - C\hat{x}(t)] + Bu(t) \\ \hat{x}(t_0) &= \bar{x}_0 \end{aligned} \quad (4.4.3)$$

com  $u(t)$  dado de maneira ótima por:

$$u(t) = -L(t)\hat{x}(t) \quad (4.4.4)$$

onde:

$\hat{x}(t)$  é o estado estimado ótimo

$K(t)$  é o ganho do filtro de Kalman

$L(t)$  é o ganho da lei de controle *feedback* linear dado por:

$$L(t) = [\Gamma + B^T S(t+1)B]^{-1} B^T S(t+1)A \quad (4.4.5)$$

e  $\{S(t)\}$  satisfaz a seguinte equação matricial de Riccati:

$$S(t) = \Omega + L(t)^T \Gamma L(t) + (A - BL(t))^T S(t+1)(A - BL(t)) \quad (4.4.6)$$

com a condição de fronteira:  $S(N) = \Omega_N$

Observa-se que  $u(t)$  é uma função de  $\{y(t-1), y(t-2), \dots, y(0), u(t-1), u(t-2), \dots, u(0)\}$ .

A lei de controle LQG utiliza o chamado *princípio da separação* no cálculo de  $u(t)$ . Este princípio admite que a estimativa ótima dos estados utilizando o filtro de Kalman é independente do cálculo da ação de controle ótimo, ou seja, os dois cálculos são realizados independentemente. Isto pode ser facilmente verificado analisando as equações do controle LQG. Como pode ser visto, os cálculos de  $S(t)$  e  $L(t)$  não dependem das incertezas do modelo, ou seja, o cálculo da ação de controle não é afetado pela presença dos ruídos  $\{v_1(t)\}$  e  $\{v_2(t)\}$  do processo.

A equação de Riccati necessita ser resolvida antes do cálculo de  $u(t)$ . Isto é possível pois tanto  $S(t)$  quanto  $L(t)$  não dependem do valor dos estados estimados  $\hat{x}(t)$ . A solução desta equação inicia-se com um valor conhecido (ou desejado) de  $S(t)$  em  $t = N$  e calcula-se os valores de  $S(t)$  até  $t = 0$ . Na prática, porém, para efeito de simplificação nos cálculos, admite-se que  $S(t)$  converge para um valor constante, correspondente ao valor no estado estacionário, quando o tempo é muito grande. Considerada essa hipótese, existem várias maneiras de se resolver numericamente ou algebricamente esta equação neste estado estacionário atingido. Uma dessas maneiras é realizar um cálculo iterativo até que se atinja uma solução constante.

A figura 4.1 mostra o princípio da separação, usado no projeto do controlador LQG.

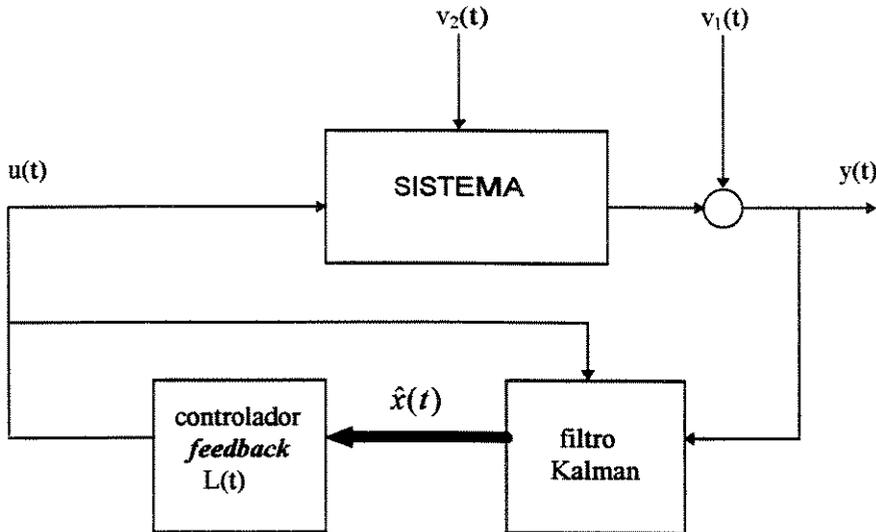


Figura 4.1 - Solução para o problema do controle ótimo LQG (princípio da separação) (Goodwin & Sin, 1984).

A literatura cita várias aplicações do controle LQG a processos industriais (Johnson, 1993).

#### 4.4.2 - Problema Servo

A lei de controle  $u(t) = -L(t)\hat{x}(t)$  provê uma ação de controle ótima no sentido do sistema rejeitar perturbações, ou seja, para o caso regulador, no qual deseja-se que o sistema permaneça em um determinado *set point*, independentemente das perturbações que venha a sofrer. Para o caso de se desejar que o sistema siga uma determinada trajetória, conhecido por problema servo (ou supervisor), as equações de projeto necessitam ser alteradas de modo a incluir o novo estado desejado. Isto pode ser feito, dentre outras maneiras, aumentando o vetor de estados de modo a incluir uma variável auxiliar que é definida como sendo o somatório do erro entre a saída desejada e a saída real, provendo assim o sistema de controle de uma ação integral que procura minimizar possíveis desvios entre o estado desejado e o estado atingido (*off sets*) (Goodwin & Sin, 1984).

Seja  $y^*$  a nova saída desejada para o sistema, constante no tempo. Considere a seguinte variável  $z(t)$ , que acumula o somatório do erro entre a saída desejada e a saída real:

$$z(t) = \sum_{j=0}^{t-1} [y^* - y(j)] \quad (4.4.7)$$

A equação acima pode ser escrita na forma iterativa como:

$$z(t+1) = z(t) + y^* - y(t); \quad z(0) = 0 \quad (4.4.8)$$

Deste modo o vetor de estados pode ser aumentado de modo a incluir  $z(t)$ :

$$x'(t) = \begin{bmatrix} x(t) \\ z(t) \end{bmatrix} \quad (4.4.9)$$

A lei de controle resultante tem a forma:

$$u(t) = K\hat{x}'(t) = \begin{bmatrix} K_1 & K_2 \end{bmatrix} \begin{bmatrix} \hat{x}(t) \\ z(t) \end{bmatrix} \quad (4.4.10)$$

onde  $\hat{x}(t)$  é o estado estimado de maneira ótima, utilizando o filtro de Kalman.

A lei de controle LQG, como já mencionado anteriormente, objetiva minimizar os estados e a ação de controle e, portanto, todas essas variáveis necessitam ser escritas na **forma de variáveis desvio** em relação a um estado de referência que pode ser tanto o estado estacionário (problema regulador) ou um novo estado desejado (problema servo).

A utilização do controle LQG tem a grande vantagem que obedecidas algumas considerações, o sistema em malha fechada tem estabilidade garantida. Se as matrizes  $\Omega$  e  $\Gamma$  da função custo forem positivas e definidas, o sistema invariante no tempo,  $\bar{S}$  a solução da equação de Riccati no estado estacionário (matriz positiva e definida), então a estratégia de controle ótimo  $u(t) = -L(t)\hat{x}(t)$ , produz um sistema em malha fechada assintoticamente estável. A demonstração desse teorema pode ser

encontrada em *Åström & Wittenmark (1984)* e envolve a aplicação do critério de estabilidade de Lyapunov.

Nos desenvolvimentos acima considerou-se um sistema linear e com parâmetros fixos no tempo. No entanto, quando se aplica o controle LQG a processos não lineares, este deve ser linearizado ao longo de uma trajetória, fazendo com que os parâmetros do sistema linear resultante modifiquem-se em cada ponto de linearização. Deste modo os algoritmos anteriores devem ser modificados para considerar a variação dos parâmetros. Este procedimento é descrito por *Willigenburg (1992)*.

A resolução da equação matricial de Riccati não é a única técnica disponível para o cálculo do ganho do controlador. Este pode ser calculado por outras estratégias, como por exemplo, a imposição de pólos, apresentada no próximo item.

#### **4.5 - Controle Adaptativo com Imposição de Pólos**

Uma técnica para projetar sistemas reguladores sub-ótimos consiste em construir um sistema de malha fechada assintoticamente estável especificando as localizações (posições) desejadas para os pólos de malha fechada. Isto pode ser realizado pelo uso de realimentação de estados, isto é, admitindo que o vetor de controle seja  $u = -Kx$  (onde  $u$  é sem restrições). Determina-se então a matriz de ganho realimentado  $K$  tal que o sistema tenha uma equação característica desejada. Este esquema de projeto é conhecido como imposição de pólos. A equação do sistema em malha fechada é dada por:

$$x(t+1) = (A - BK)x(t) \quad (4.5.1)$$

As características da resposta em regime transiente e a estabilidade são determinados pelos autovalores da matriz  $A - BK$ . Se a matriz  $K$  for escolhida adequadamente, então a matriz  $A - BK$  pode ser forçada a ter um comportamento assintoticamente estável, e para todo  $x(0) \neq 0$  é possível fazer  $x(t)$  tender para 0 quando  $t$  tende para infinito.

Sendo  $\mu_1, \mu_2, \mu_3$  os autovalores desejados para um sistema de ordem 3 ( $n = 3$ ), por exemplo,  $K$

pode ser determinado a partir da igualdade:

$$|sI - A + BK| = (s - \mu_1)(s - \mu_2)(s - \mu_3) \quad (4.5.2)$$

Uma vez que ambos os membros desta equação característica são polinômios em  $s$ , igualando os coeficientes das potências semelhantes de  $s$  em ambos os membros, é possível determinar os valores de  $k_1$ ,  $k_2$  e  $k_3$ . Esta abordagem é conveniente se  $n = 2$  ou  $3$ . (Para  $n = 4, 5, 6, \dots$ , esta abordagem pode tornar-se muito tediosa). Existem outras abordagens no cálculo do  $K$ , como por exemplo a denominada fórmula de Ackermann (Ogata, 1993).

É importante notar que a matriz  $K$  não é única para um dado sistema, mas depende das localizações (posições) selecionadas dos pólos de malha fechada desejados (que determinam a velocidade e o amortecimento da resposta). Nota-se que a seleção dos pólos em malha fechada desejados ou a equação característica desejada é um compromisso entre a rapidez da resposta do vetor de erro e a sensibilidade às perturbações e ruídos da medição. Isto é, se for aumentada a velocidade da resposta de erro, então os efeitos adversos de perturbações e ruídos de medição geralmente aumentam. Na prática a escolha dos pólos deve ser acompanhada de extensas simulações em computador para se procurar um melhor desempenho do sistema em malha fechada.

Como uma alternativa para o projeto de controladores adaptativos baseado na otimização de um dado índice de desempenho, surgiu o *Self-Tuning Controller* com projeto baseado na técnica de imposição ou localização dos pólos.

O controlador com localização de pólos tem a seguinte forma geral (Seborg et al., 1986):

$$\bar{F}(q^{-1})u(t) = \bar{H}(q^{-1})y_r(t) - \bar{G}(q^{-1})y(t) \quad (4.5.3)$$

onde:

$$\begin{aligned}
 \bar{F}(q^{-1}) &= 1 + \bar{f}_1 q^{-1} + \dots + \bar{f}_n q^{-n} \\
 \bar{G}(q^{-1}) &= \bar{g}_0 + \bar{g}_1 q^{-1} + \dots + \bar{g}_n q^{-n} \\
 \bar{H}(q^{-1}) &= \bar{h}_0 + \bar{h}_1 q^{-1} + \dots + \bar{h}_n q^{-n}
 \end{aligned}
 \tag{4.5.4}$$

Dado um modelo de processo na forma:

$$A(q^{-1})y(t) = B(q^{-1})u(t - k) + C(q^{-1})\xi(t) + d(t) \tag{4.5.5}$$

a função de transferência em malha fechada é dada por:

$$y(t) = \frac{\bar{F}C}{A\bar{F} + \bar{G}Bq^{-k}} \xi(t) + \frac{\bar{H}B}{A\bar{F} + \bar{G}Bq^{-k}} y_r(t) \tag{4.5.6}$$

onde  $\bar{F}$  e  $\bar{G}$  são selecionados de tal modo que os pólos em malha fechada estão em uma localização desejada como especificado pelo polinômio  $T(q^{-1})$ , definido como:

$$T(q^{-1}) = 1 + t_1 q^{-1} + \dots + t_n q^{-n} \tag{4.5.7}$$

Os polinômios de  $n$ -ésima ordem  $\bar{F}(q^{-1})$  e  $\bar{G}(q^{-1})$  são determinados tal que satisfaçam a relação:

$$A\bar{F} + \bar{G}Bq^{-k} = TC \tag{4.5.8}$$

A equação acima é conhecida como *equação de Diophantine*.

Uma vantagem do controlador com localização de pólos é que ele pode ser sintonizado convenientemente através da escolha da localização dos pólos em malha fechada, o que faz com que seja garantida a estabilidade do sistema de controle. Outro fato importante é que este tipo de controlador pode ser aplicado a processos com resposta inversa.

Maiores detalhes acerca desta técnica de projeto podem ser encontrados em *Åström & Wittenmark (1980)*, *Clarke (1982)*, *Gawthrop (1982)*, *Åström & Wittenmark (1984)* e *Elliott et al. (1984)*.

#### **4.6 - Conclusões**

Apresentou-se neste capítulo as principais técnicas que podem ser utilizadas no projeto do controlador adaptativo auto-ajustável. Mostrou-se que existem dois critérios básicos para a formulação de uma técnica de projeto: (i) projeto baseado em um critério de desempenho, em geral, quadrático; (ii) projeto baseado na localização dos pólos do sistema em malha fechada. Dentre os métodos de projeto derivados utilizando o primeiro critério destaca-se o controlador de variância mínima e o controlador LQG.

O maior interesse está nos controladores projetados utilizando a metodologia do LQG, pois permite o projeto ótimo de sistemas estocásticos e produz sempre sistemas de controle estáveis em malha fechada.

Todos os critérios de projeto necessitam ser acompanhados de um estimador de parâmetros do modelo e se pode utilizar, *a priori*, qualquer método descrito no Capítulo 3, sendo que o LQG necessita do conhecimento de todos os estados e, quando não são inteiramente conhecidos, necessitam ser estimados em tempo real utilizando um filtro ou um observador de estados.

## CAPÍTULO V

# CONTROLE DE UM PROCESSO CONTÍNUO DE FERMENTAÇÃO ALCOÓLICA EM ESCALA INDUSTRIAL

### 5.1 - Introdução

Os processos biotecnológicos apresentam, em geral, relações não lineares entre as grandezas envolvidas, possuem parâmetros que variam ao longo do tempo devido a mudanças genéticas ocorridas nos microrganismos ou mudanças de condições operacionais, resposta dinâmica complexa, como por exemplo resposta inversa, além da presença de tempo morto e atraso nos instrumentos de leitura, principalmente relacionados com medidas de concentração. Estas características dificultam, ou até mesmo em alguns casos impossibilitam, a utilização de estratégias clássicas de controle ou, quando possíveis, geralmente apresentam resultados insatisfatórios.

O controle adaptativo é uma estratégia de controle avançado que procura contornar as dificuldades citadas acima, gerando uma ação de controle baseada no modelo do processo identificado em tempo real e em linha, ou seja, alguns dos parâmetros do modelo de valor incerto são determinados, a partir dos dados de entrada e saída do sistema, de maneira recursiva. Deste modo, o controlador é capaz de continuar atuando com bom desempenho, mesmo na presença de perturbações, erros de modelagem (ruídos de processo), erros de leitura (ruídos de instrumento), dinâmica complexa, etc. Diversos trabalhos experimentais e simulações têm mostrado a capacidade do controle adaptativo em controlar sistemas complexos como os reatores fermentativos ( *Fan et al., 1973; Gallegos & Gallegos, 1984; Lee et al., 1991; Roux et al., 1992; Chen et al., 1995; Boskovic & Narendra, 1995*).

Neste capítulo investiga-se o comportamento de um sistema contínuo de fermentação alcoólica, sob ação de controle adaptativo. O sistema é constituído de um típico processo industrial de grande porte, composto por quatro fermentadores de mistura, ligados em série e operando com reciclo de células. O processo é alimentado com uma mistura composta de açúcares redutores mais fontes de nitrogênio e sais minerais, conhecido como **mosto**, e por transformação biológica, produz-se etanol como produto final. A taxa de reação considerada para consumo de substrato, produção de células e

etanol teve seus parâmetros determinados e validados industrialmente em trabalho anterior (Andrietta, 1994).

O controle adaptativo é implementado utilizando a metodologia de modelos espaço-de-estados, sendo o controlador projetado usando os algoritmos LQG (Linear Quadratic Gaussian) e variância mínima.

Apresentam-se resultados para a resposta dinâmica do sistema em malha fechada à variações no tempo de amostragem, presença de atraso nos instrumentos de medida, capacidade do controlador em rejeitar perturbações ou levar o sistema para novo “set-point”. Todos os resultados foram comparados com o desempenho do controlador PID clássico.

## **5.2 - Descrição do Processo Simulado**

O processo de fermentação alcoólica contínua, mostrado esquematicamente na Figura 5.1, pode ser dividido em três partes:

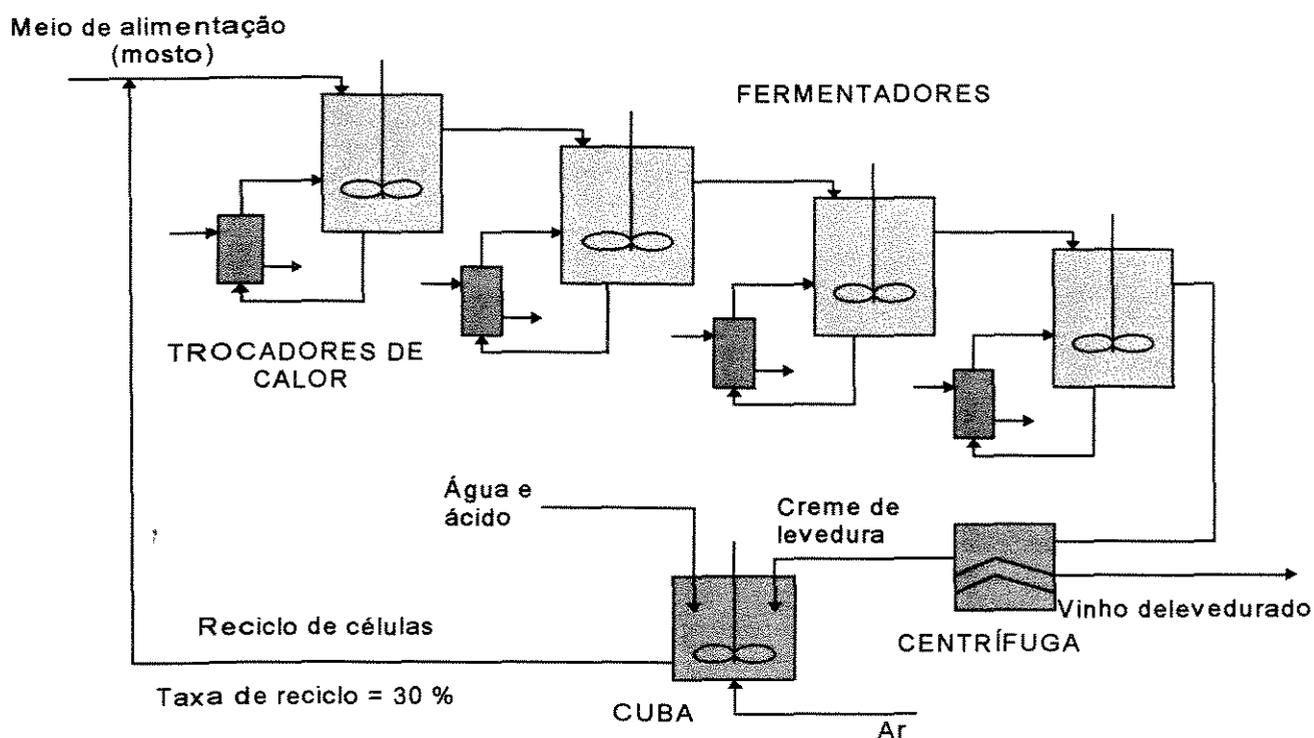
- 1 - unidade de tratamento ácido;
- 2 - unidade de separação de células de levedura e
- 3 - fermentadores.

Como se observa nessa figura, as células de leveduras, após terem sido submetidas ao tratamento ácido (fermento tratado), deixam a unidade de tratamento e são misturadas com o meio de alimentação (mosto) sendo então enviadas aos fermentadores. A fração entre a vazão de fermento tratado e a vazão total de alimentação dos fermentadores é chamada de *taxa de reciclo*.

O processo de fermentação considerado neste trabalho é constituído por quatro fermentadores de mistura, ligados em série e providos de um sistema de agitação. Cada reator possui um sistema externo de troca térmica cujo objetivo é manter a temperatura do fluido reagente constante.

Após ocorrida a transformação dos açúcares em etanol, o vinho fermentado contendo células de levedura (vinho bruto) é enviado para a unidade de separação. Esta unidade é constituída de centrífugas

de pratos que trabalham a uma velocidade angular aproximada de 8 000 rpm. Estas centrífugas recebem o vinho bruto contendo de 30 a 45 g de células por litro e fornecem dois produtos: uma fase leve e outra pesada. A fase pesada contendo entre 160 a 200 g de células por litro é chamada de *leite* ou *creme de levedura*. Este creme é enviado para a unidade de tratamento ácido. A fase leve, praticamente isenta de células de levedura (a concentração máxima permitida é 3 g de células por litro), é chamada de vinho delevedurado e é enviado ao tanque pulmão da unidade de destilação, também chamada de dorna volante.



**Figura 5.1** - Esquema geral do processo de fermentação alcoólica contínua em escala industrial, com reciclo de células (Andrietta, 1994).

A unidade de tratamento ácido é constituída de 2, 3 ou 4 tanques, equipados com sistemas de agitação, denominados *cubas*. O tratamento é contínuo e consiste em se receber o creme de levedura na primeira cuba, diluí-lo com água de boa qualidade na proporção de 1:1 e em seguida ajustar-se o pH do creme diluído a 2,0 - 2,5 utilizando ácido sulfúrico concentrado. O volume total das cubas é o suficiente para se obter um tempo de tratamento entre 1 e 2 horas.

### 5.3 - Modelagem Matemática, Parâmetros e Condições Iniciais do Processo Simulado

O desenvolvimento do modelo matemático para o processo fermentativo considerado neste trabalho bem como a determinação dos seus parâmetros foram efetuados por *Andrietta (1994)*, onde encontram-se mais detalhes acerca do processo e condições de projeto dos equipamentos. As equações do modelo consistem em balanços de massa e energia para os componentes da mistura reacional e balanço de energia no sistema de troca térmica. Considerou-se os reatores como sendo de mistura perfeita, que segundo *Rodrigues et ali (1992)* é uma boa aproximação para zonas de estagnação de até 10 % do volume total do reator. Através de análises de alguns reatores industriais agitados, os volumes de zonas de estagnação foram considerados desprezíveis.

No balanço de massa desprezou-se o “hold up” de gás, pois na prática seu valor é bastante baixo, em geral não superior a 2 % do volume útil do reator. Também foi desprezado o volume de células, já que segundo a literatura (*Monbouquette, 1992*) este volume é desprezível para reatores operando com um volume de células em torno de 10 % (30 g/l massa seca).

#### 1. Balanço de massa para cada reator i:

- **Balanço de massa global**

Assumindo que a densidade do líquido reagente seja constante para cada reator, tem-se:

$$\frac{dV_i}{dt} = \frac{F_{i-1}\rho_{i-1}}{\rho_i} - F_i \quad (5.3.1)$$

- **Balanço de substrato**

Para o sistema em regime transiente, tem-se:

$$\frac{d(V_i S_i)}{dt} = F_{i-1} S_{i-1} - F_i S_i + \frac{-V_i X_i}{Y_{X/S}} \mu_i \quad (5.3.2)$$

onde  $\mu_i$  é o modelo cinético adotado, que é derivado do modelo de Monod e portanto restrito aos casos em que se assume crescimento balanceado:

$$\mu_i = \mu_{\max,i} \frac{S_i}{S_i + K_S} \left(1 + \frac{-P_i}{P_{\max}}\right)^n \left(1 + \frac{-X_i}{X_{\max}}\right)^m \quad (5.3.3)$$

Este modelo é válido para processos contínuos de fermentação alcóolica no estado estacionário, ou então, para processos com dinâmica lenta, que é o caso dos processos fermentativos.

A velocidade máxima de crescimento da levedura tem sua dependência com a temperatura descrita pela equação de Arrhenius:

$$\mu_{\max,i} = A \cdot \exp\left(\frac{-E}{RT}\right) \quad (5.3.4)$$

A tolerância da levedura ao etanol é descrita pela variável  $P_{\max}$ , cujo valor é dependente da temperatura somente se esta for maior que 32 °C, temperatura esta conhecida como *temperatura crítica superior*:

$$\begin{aligned} P_{\max} &= 103, \text{ se } T \leq 32 \text{ °C} \\ P_{\max} &= k_o \cdot \exp(aT), \text{ se } T > 32 \text{ °C} \end{aligned} \quad (5.3.5)$$

Os valores dos parâmetros cinéticos utilizados estão sumarizados na Tabela 5.1.

Tabela 5.1 - Valores dos parâmetros cinéticos do modelo.

PARÂMETRO	VALOR
A	$4,50 \cdot 10^{10}$
R	1,987 cal/K.mol
n	3
m	0,9
E	$1,54 \cdot 10^4$ cal/K.mol
$k_o$	895,6
$X_{\max}$	100 g/l
a	- 0,0676 1/°C
$K_S$	1,6 g/l
$Y_{X/S}$	0,033
$Y_{P/S}$	0,445

- **Balanço de etanol**

$$\frac{d(V_i P_i)}{dt} = F_{i-1} P_{i-1} - P_i F_i + V_i X_i \left( \frac{Y_{P/S}}{Y_{X/S}} \right) \mu_i \quad (5.3.6)$$

- **Balanço de células**

$$\frac{d(V_i X_i)}{dt} = F_{i-1} X_{i-1} - F_i X_i + V_i X_i \mu_i \quad (5.3.7)$$

## 2. Balanço de energia para o reator i:

- **Fluido reagente no reator i**

$$\frac{d(V_i T_i)}{dt} = F_{i-1} T_{i-1} - F_i T_i + F_{c_i} (T_{c_i} - T_i) + \frac{-V_i \Delta H_{X_i}}{\rho C_p Y_{X/S}} \mu_i \quad (5.3.8)$$

- **Fluido reagente no trocador de calor**

Considerando  $V_{c_i}$  constante, tem-se:

$$\frac{dT_{c_i}}{dt} = \left( \frac{F_{c_i}}{V_{c_i}} \right) (T_i - T_{c_i}) - \left( \frac{U A_i}{V_{c_i} \rho C_p} \right) LMDT \quad (5.3.9)$$

sendo LMDT a temperatura média logarítmica, dada pela expressão:

$$LMDT = \frac{(T_r - T_{j_i}) - (T_{c_i} - T_{j_e})}{\ln \left( \frac{T_r - T_{j_i}}{T_{c_i} - T_{j_e}} \right)} \quad (5.3.10)$$

- **Fluido refrigerante no trocador de calor i:**

Considerando  $V_{j_i}$  constante, tem-se:

$$\frac{dT_{j_i}}{dt} = \left( \frac{F_{j_i}}{V_{j_i}} \right) (T_{j_e} - T_{j_i}) + \left( \frac{UA_i}{V_{j_i} \rho_j C_{p_j}} \right) LMDT \quad (5.3.11)$$

As equações acima constituem um sistema de equações diferenciais ordinárias de primeira ordem. Para a solução numérica dessas equações necessita-se conhecer uma condição inicial para cada uma delas. Esta condição inicial será um estado estacionário de referência, apresentado na Tabela 5.2.

Tabela 5.2 - Estado Estacionário de Referência

REATOR	S, g/l	P, g/l	X, g/l	T, °C	Tc, °C	Tj, °C
1	54,237	41,829	29,373	33,5	31,205	30,180
2	21,443	56,423	30,455	33,5	31,280	30,109
3	5,045	63,719	30,996	33,5	31,342	30,051
4	0,883	65,572	31,133	33,5	31,856	29,562

A Tabela 5.3 apresenta os parâmetros de projeto utilizados nas simulações do modelo dinâmico do sistema.

Os valores das variáveis de processo assumidos neste trabalho são aqueles possíveis de serem obtidos nas unidades industriais, e capazes de fornecer valores aceitáveis de produtividade, sem comprometer a viabilidade econômica e operacional da planta.

Tabela 5.3 - Parâmetros de projeto

REATOR	A, m <sup>2</sup>	V, m <sup>3</sup>	Fc, m <sup>3</sup> /h	Fj, m <sup>3</sup> /h	Vc, m <sup>3</sup> /h	Vj, m <sup>3</sup> /h
1	76,361	210,374	400	400	20	20
2	63,242	268,037	350	350	20	20
3	31,061	316,663	180	180	20	20
4	6,869	208,208	60	60	20	20

As principais variáveis a serem definidas são:

**a) concentração de ART no meio de alimentação (mosto):** a concentração de açúcares redutores totais (ART) no meio de alimentação deve ser tal que a concentração de etanol obtida esteja dentro de uma faixa que não tenha efeitos negativos para a fermentação e nem para a destilação. Em geral, concentrações de etanol em torno de 65 a 70 g/l são recomendadas para que se consiga bons valores de produtividade fermentativa, sem acarretar grandes problemas no processo de destilação. Para se atingir estes patamares de concentração de etanol na indústria, a concentração de ART no meio de alimentação deve estar em torno de 180 g/l.

**b) taxa de reciclo:** a taxa de reciclo é definida como sendo a **fração entre a vazão de fermento tratado e a vazão total de alimentação do fermentador**, sendo que o utilizado com maior frequência nas unidades industriais é de 30%. Este valor foi adotado tendo como base o utilizado nos processos batelada-alimentada, onde o volume de fermento tratado corresponde a 1/3 do volume total do fermentador.

**c) concentração de células no reciclo:** a concentração de células no reciclo é fixada em 90 g/l na maioria das unidades industriais e está ligada diretamente ao desempenho das unidades separadoras bem como à quantidade de água adicionada na cuba de tratamento.

**d) concentração de células no creme de levedura:** para que se possa manter a concentração de células no reciclo igual a 90 g/l e a adição do volume de água recomendado durante o tratamento ácido, a concentração de células no creme de levedura deve ser de 180 g/l.

**e) concentração de células no vinho de levedura:** as separadoras centrífugas de uso industrial, em geral, permitem apenas uma pequena perda de células de levedura no vinho de levedura, sendo esta perda uma função das condições operacionais da máquina. Perdas de até 3 g/l de células são consideradas normais. Acima deste valor, recomenda-se a lavagem da máquina.

**f) temperatura de operação:** normalmente utiliza-se uma temperatura onde o volume do reator necessário para se obter a conversão desejada e a área de troca térmica requerida pelo sistema de

resfriamento, combinados, forneçam um custo mínimo. Para o caso em estudo, este valor foi estabelecido em 33,5 °C.

*g) temperatura da água de resfriamento:* como esta variável é função de vários fatores, adotou-se o valor de 28 °C, que corresponde ao valor máximo da temperatura da água captada diretamente de rios e lagoas, prática essa comum na indústria alcooleira.

A Tabela 5.4 resume o valor das variáveis de processo assumidos neste trabalho.

Tabela 5.4 - Valores das variáveis de processo

<i>VARIÁVEIS</i>	<i>VALORES</i>
concentração de ART no mosto	180 g/l
taxa de reciclo	30 %
concentração de células no creme	180 g/l
concentração de células no reciclo	90 g/l
conc. de células no vinho delevedurado	3 g/l
temperatura do fluido de resfriamento	28 °C

As vazões de fluido dentro dos trocadores de calor foram calculadas para cada reator de maneira a maximizar a troca térmica e minimizar o custo operacional. A Tabela 5.5 apresenta as vazões para cada reator.

Tabela 5.5 - Vazões dos fluidos de reagente e de refrigeração para cada reator.

<i>REATOR</i>	<i>vazão de fluido reagente, m<sup>3</sup>/h</i>	<i>vazão de fluido de resfriamento, m<sup>3</sup>/h</i>
1	400	400
2	350	350
3	180	180
4	60	60

Os demais parâmetros necessários para a integração das equações estão apresentados na Tabela 5.6.

Tabela 5.6 - Parâmetros do modelo matemático

<i>PARÂMETRO</i>	<i>VALOR</i>
$\Delta H$	- 157,57 kcal/h
$\rho$	950 kg/m <sup>3</sup>
$C_p$	1 cal/g. °C
$U$	3 500 kcal/h. °C.m <sup>2</sup>
$\rho_j$	1000 kg/m <sup>3</sup>
$C_{p_j}$	1 cal/g. °C

### 3. Equações para o reciclo

Como neste sistema fermentativo há reciclo do fermento tratado, duas correntes juntam-se antes da entrada no primeiro reator para formar a corrente de alimentação do processo: a corrente de alimentação (mosto) e a corrente de reciclo. A vazão de entrada ( $F_O$ ), concentração de substrato ( $S_E$ ), concentração de etanol ( $P_E$ ) e concentração de células ( $X_E$ ) que entram no primeiro reator, são fornecidas pelas seguintes relações:

$$F_O = \frac{F_M}{1 - R} \quad (5.3.12)$$

$$F_R = F_O - F_M \quad (5.3.13)$$

$$F I_1 = \frac{F_R X_R}{X_L} \quad (5.3.14)$$

$$F_A = F_R - F I_1 \quad (5.3.15)$$

$$S_R = \frac{F I_1 S_4}{F_R} \quad (5.3.16)$$

$$S_E = \frac{F_R S_R + F_M S_M}{F_O} \quad (5.3.17)$$

$$X_E = \frac{X_R F_R}{F_O} \quad (5.3.18)$$

$$P_R = \frac{F I_1 P_1}{F_R} \quad (5.3.19)$$

$$P_E = \frac{F_R P_R}{F_O} \quad (5.3.20)$$

## 5.4 - Projeto do Sistema de Controle

### 5.4.1 - Objetivos do Controle

No projeto do sistema de controle proposto para o sistema em estudo levou-se em consideração dois objetivos de controle principais:

1. Manter constante a temperatura dos reatores;
2. Manter constante a concentração de ART efluente (problema regulatório) ou fazer com que o valor desta variável siga uma determinada trajetória estabelecida (problema supervisorio).

### 5.4.2 - Configuração do Sistema de Controle

O sistema de controle é constituído de duas malhas de uma entrada e uma saída (*SISO - Single-input, Single-output*).

A primeira malha de controle tem como objetivo manter constante a temperatura dos reatores através da manipulação da vazão da água de resfriamento. Esta malha de controle foi implementada utilizando um controlador proporcional *feedback* que atua na válvula controladora da vazão de maneira proporcional ao erro entre a temperatura do reator e o valor desejado (*set point*) para esta variável. “Cada reator possui uma malha de controle independente e a atuação do controlador se dá sobre uma válvula modulante localizada na tubulação de água de resfriamento e em outra localizada na tubulação que conduz o fluido reagente aos trocadores. A intenção desta dupla atuação é manter as vazões de fluido reagente e de resfriamento no trocador de calor iguais, visando maximizar a eficiência deste. O valor máximo destas vazões foram fixados como sendo o dobro dos de referência, ou seja, 800, 700,

360 e 120 m<sup>3</sup>/h para os reatores 1, 2, 3 e 4 respectivamente. Esta limitação se deve ao fato de que industrialmente não se pode trabalhar com equipamentos superdimensionados devido aos altos custos tanto de aquisição como de operação e manutenção.” (Andrietta, 1994).

As constantes para a malha de controle da temperatura foram determinadas como sendo:  $Kc_1 = 20$ ;  $Kc_2 = 15$ ;  $Kc_3 = 10$  e  $Kc_4 = 2$  °C para o reator 1, 2, 3 e 4 respectivamente (Andrietta, 1994). Deste modo, a vazão de fluido refrigerante é alterada de acordo com a expressão matemática:

$$F_{ji} = F_{ji-1} + Kc(T - T_{set}) \quad (5.4.1)$$

A segunda malha de controle tem uma grande importância econômica, pois interfere diretamente no rendimento do processo. Entre as variáveis passíveis à manipulação a mais indicada seria a alteração dos volumes dos reatores. No entanto, a utilização desta variável como variável manipulada provoca sérios problemas operacionais (Andrietta, 1994). Devido a estas limitações operacionais optou-se por utilizar a vazão do meio de alimentação como variável manipulada. Esta malha consiste de um analisador de açúcares (sacarose, glicose e frutose) em linha que se comunica com o controlador que, por sua vez, atua na válvula de controle localizada na linha do meio de alimentação. Uma malha secundária mantém a relação (vazão de meio de alimentação)/(vazão de fermento) constante, atuando na vazão de fermento tratado.

A concentração de ART no efluente dos reatores pode ser determinada utilizando um cromatógrafo líquido de alta pressão, equipado com coletor e injetor automáticos. O tempo de análise é aproximadamente de 10 minutos. Devido a este fato, adotou-se um tempo de atraso em todas as estratégias de controle implementadas, ou seja, o sistema de controle toma decisões no tempo  $t$  baseado em valores de concentração de ART do intervalo de amostragem  $t - 1$ .

O processo a ser controlado possui uma dinâmica muito lenta. Propõe-se então, neste trabalho, que a variável manipulada seja a concentração de ART que sai do primeiro reator de modo a tornar mais rápida a detecção de perturbações e acelerar a ação de controle, já que se utilizou a estratégia de retroalimentação nas duas malhas de controle.

### 5.4.3 - Controle Adaptativo Utilizando Modelo Linear com projeto LQG

Como já mencionado no Capítulo 4, o projeto de controladores utilizando o método LQG tem a vantagem de levar a um sistema estável em malha fechada pois este método foi desenvolvido a partir do 2º critério de estabilidade de Lyapunov. Apesar desse método ter sido desenvolvido para sistemas lineares com parâmetros fixos no tempo, a sua aplicação pode ser estendida também a sistemas não lineares desde que estes estejam representados por um modelo linear. Há várias maneiras de se obter um modelo linear de um sistema, sendo a principal delas a linearização do sistema em torno de um ponto que pode ser tanto o estado estacionário de referência quanto um outro estado convenientemente escolhido. Um sistema linear obtido por linearização em torno de um estado arbitrário possui parâmetros que variam ao longo do tempo, já que a linearização se dá em todos os intervalos de amostragem. Esta característica é importante no projeto dos sistemas de controle pois a maior parte da teoria de controle desenvolvida até o momento é aplicável somente a *sistemas lineares com parâmetros fixos no tempo*. Devido a essas características o projeto de controle de um sistema não linear representado por um modelo linear com parâmetros que variam em função do tempo, utilizando o procedimento LQG, obviamente não conduz a um sistema de controle ótimo e nem mesmo a garantia da estabilidade em malha fechada continua válida.

O projeto de sistemas de controle baseado no método LQG pode ser feito utilizando um modelo para controle na forma espaço-de-estados ou na forma polinomial. Devido ao fato de que a teoria deste método ter sido desenvolvida utilizando uma modelagem na forma espaço-de-estados, este é o procedimento natural na formulação de controladores adaptativos LQG e foi o método empregado por *Fan et al. (1973)* no controle de um sistema de tratamento biológico de resíduos. Esta formulação tem a vantagem do modelo para controle ser proveniente das equações de balanço de massa, energia e quantidade de movimento que descrevem a dinâmica do processo e portanto parte de uma base física. Deste modo, é possível realizar uma avaliação crítica do estimador de parâmetros já que estes possuem um significado físico real. Mais recentemente, *Roux et al. (1992)* utilizaram um modelo na forma polinomial para representar o processo. Este modelo é identificado em linha utilizando um estimador sequencial de parâmetros e então é convertido na forma espaço-de-estados para a aplicação do algoritmo de projeto LQG. A grande desvantagem deste procedimento é que esta classe de modelo do processo não permite uma contribuição ao entendimento da dinâmica do sistema pois os parâmetros do

modelo não possuem significado físico, como mencionado pelos próprios autores.

No presente trabalho adotou-se uma sistemática mista entre as duas metodologias descritas anteriormente. Partindo-se das equações matemáticas que descrevem o primeiro reator chega-se a um conjunto de equações discretas na forma linear com parâmetros que devem ser ajustados por um estimador sequencial. Estes parâmetros representam na verdade um conjunto de parâmetros físicos agrupados e por este motivo deixam de ter significado físico direto.

A proposta deste trabalho é que o processo seja controlado por computador; para tanto as equações que descrevem o *modelo para controle*, necessitam ser discretizadas. Como esse modelo não necessita ser um modelo rigoroso, algumas simplificações foram feitas nas equações do modelo dinâmico para adequá-las aos algoritmos de identificação, estimativa e controle utilizados. Serão apresentadas apenas as equações para o primeiro reator, já que para os demais a forma é análoga. Utilizando a aproximação de Euler de primeira ordem, pode-se escrever para a Equação 5.3.2, como sendo:

$$S_1(t + I) = S_1(t) + \frac{\Delta h}{V_1} F_0 S_E + \frac{-\Delta h}{V_1} F_1 S_1(t) - \Delta h \frac{\mu_1(t)}{Y_{X/S}} X_1(t) \quad (5.4.2)$$

onde  $\Delta h$  é o tempo de amostragem.

Para fins de identificação em linha necessita-se definir os parâmetros que serão identificados de maneira recursiva. A escolha dos parâmetros identificados, bem como das variáveis medidas deve ser feita de modo a que se obtenha um modelo linear. O vetor abaixo apresenta os parâmetros a ser estimados para a primeira equação:

$$\theta^T(t) = \left[ I, S_E, I, \frac{\mu_1(t)}{Y_{X/S}} \right] = [\theta_1, \theta_2, \theta_3, \theta_4] \quad (5.4.3)$$

O vetor que contém as variáveis medidas pode ser escrito como:

$$\phi^T(t) = \left[ S_1(t), \frac{\Delta h}{V_1} F_0, \frac{-\Delta h}{V_1} F_1 S_1(t), -\Delta h X_1(t) \right] \quad (5.4.4)$$

Deste modo, pode-se escrever a Equação 5.4.2 na forma linear:

$$S_1(t+I) = \phi^T(t) \cdot \theta(t) \quad (5.4.5)$$

Desde que o modelo foi escrito na forma linear, pode-se aplicar qualquer algoritmo de identificação em linha, cuja forma geral é:

$$\hat{\theta}(t) = \hat{\theta}(t-I) + L(t) \left[ y(t) - \phi^T(t) \hat{\theta}(t-I) \right] \quad (5.4.6)$$

O fator que diferencia cada algoritmo é o modo do cálculo do ganho  $L(t)$  (Capítulo 3).

De maneira análoga, define-se abaixo os vetores de dados de leitura e dos parâmetros para as outras variáveis de processo no primeiro reator.

Para a concentração de etanol:

$$P_1(t+I) = P_1(t) + P_E \frac{\Delta h}{V_1} F_0 + \frac{-\Delta h F_1 P_1(t)}{V_1} + \Delta h X_1(t) \frac{Y_{P/S}}{Y_{X/S}} \mu_1(t) \quad (5.4.7)$$

que pode ser escrita como:

$$P_1(t+I) = \left[ P_1(t), \frac{\Delta h}{V_1} F_0, \frac{-\Delta h}{V_1} F_1 P_1(t), \Delta h X_1(t) \right] \left[ I, P_E, I, \frac{Y_{P/S}}{Y_{X/S}} \mu_1 \right]^T \quad (5.4.8)$$

Para a concentração de células:

$$X_1(t+I) = X_1(t) + X_E \frac{\Delta h}{V_1} F_O - F_1 X_1(t) \frac{\Delta h}{V_1} + \mu_1(t) \Delta h X_1(t) \quad (5.4.9)$$

que é equivalente a:

$$X_1(t+I) = \left[ X_1(t), \frac{\Delta h}{V_1} F_O, -F_1 X_1(t) \frac{\Delta h}{V_1}, \Delta h X_1(t) \right] \begin{bmatrix} I, X_E, I, \mu_1(t) \end{bmatrix}^T \quad (5.4.10)$$

e para a temperatura do fluido reagente:

$$T_1(t+I) = T_1(t) + T_O \frac{\Delta h}{V_1} F_O + \frac{-\Delta h}{V_1} F_1 T_1 + \frac{-\Delta h}{V_1} F_{C_1} T_1 + \frac{-\Delta h X_1(t) \mu_1(t)}{\rho C_p Y_{X/S}} \Delta h \quad (5.4.11)$$

que também é equivalente a:

$$T_1(t+I) = \left[ T_1(t), \frac{\Delta h}{V_1} F_O, \frac{-\Delta h}{V_1} F_1 T_1, \frac{-\Delta h}{V_1} T_1, \frac{-\Delta h X_1(t)}{\rho C_p} \right] \begin{bmatrix} I, T_O, I, F_{C_1}, \frac{\mu_1(t) \Delta h}{Y_{X/S}} \end{bmatrix}^T \quad (5.4.12)$$

As equações acima podem ser escritas na forma espaço-de-estados (forma matricial) como sendo:

$$\begin{bmatrix} S_1(t+I) \\ P_1(t+I) \\ X_1(t+I) \\ T_1(t+I) \end{bmatrix} = \begin{bmatrix} \theta_1^1 & 0 & \theta_4^1 \Delta h & 0 \\ 0 & \theta_1^2 & \theta_4^2 \Delta h & 0 \\ 0 & 0 & \theta_1^3 - \theta_4^3 \Delta h & 0 \\ 0 & 0 & \frac{-\theta_5^4 \Delta h}{\rho C_p} & \theta_1^4 - \theta_4^4 \frac{\Delta h}{V_1} \end{bmatrix} \begin{bmatrix} S_1(t) \\ P_1(t) \\ X_1(t) \\ T_1(t) \end{bmatrix} + \begin{bmatrix} (\theta_2^1 - \theta_3^1 S_1) \frac{\Delta h}{V_1} \\ (\theta_2^2 - \theta_3^2 P_1) \frac{\Delta h}{V_1} \\ (\theta_2^3 - \theta_3^3 X_1) \frac{\Delta h}{V_1} \\ (\theta_2^4 - \theta_3^4 T_1) \frac{\Delta h}{V_1} \end{bmatrix} F_O \quad (5.4.13)$$

que está na forma:

$$x(t+I) = Ax(t) + Bu(t) \quad (5.4.14)$$

onde o índice superior nos parâmetros  $\theta$  da Equação 5.4.13 indica a que variável de estado o parâmetro  $\theta_i$  se refere. A identificação é feita separadamente para cada equação e uma vez estimados os parâmetros em cada intervalo de amostragem, determina-se as matrizes A e B da Equação 5.4.14; o valor “ótimo” da variável manipulada ( $u$ , que no caso é a vazão de mosto  $F_o$ ) é calculado usando o algoritmo LQG (Linear Quadratic Gaussian), que envolve a solução da Equação de Riccati.  $F_o$  é dada por:

$$F_{oi} = F_{oi-1} - K(x - x^*) \quad (5.4.15)$$

onde  $x^*$  é o vetor dos estados no estado estacionário de referência. O cálculo de K é realizado utilizando a função **dlqr(A,B,Q,R)** do Matlab (Control System Toolbox) que encontra a solução da equação discreta de Riccati no estado estacionário e que minimiza a equação:

$$J = \sum (x'Qx + u'Ru) \quad (5.4.16)$$

sujeito à restrição imposta pelo modelo (Equação 5.4.14). Deve-se ressaltar que uma solução da equação de Riccati no estado estacionário só pode ser calculada se, e somente se, o sistema tiver quantidade nula de estados não-controláveis. Isto é verificado através das funções **CAB = ctrb(A,B)** que calcula a matriz controlabilidade CAB do sistema descrito por A e B e **NENC = length(A) - rank(CAB)** que calcula o número de estados não-controláveis (NENC). As matrizes Q e R são variáveis de projeto e representam na verdade pesos adicionados aos estados e às entradas.

#### 5.4.4 - Controle Adaptativo utilizando Modelo Não-Linear

Uma outra maneira de se realizar o controle adaptativo baseado em um modelo não linear foi proposta por *Goodwin et ali. (1982)*, que utilizou este procedimento no controle de um sistema de tratamento de águas residuais e em um sistema de neutralização de pH. Este procedimento consiste em calcular  $F_M$  (variável manipulada) através da equação abaixo, que foi derivada da Equação 5.4.2, na qual isolou-se a variável  $F_o$ , e da Equação 5.4.12:

$$F_M = \frac{S_1^*(t+1) - \theta_1 S_1(t) + \theta_4 \Delta h X_1(t)}{\theta_2 \frac{\Delta h}{V_1} - \theta_3 \frac{\Delta h}{V_1} S_1(t)} (1 - R) \quad (5.4.17)$$

onde  $S_1^*(t+1)$  é o “set-point” desejado.

Outra metodologia bastante similar à descrita anteriormente foi proposto por *Polihronakis et al. (1993)* e utiliza como critério de projeto a minimização da variância do erro entre a saída desejada e a prevista pelo modelo (Equação 5.4.2). Uma variável auxiliar  $\phi$  pode ser definida como:

$$\phi(t+1) = S_1(t+1) - S_1^*(t) + q \cdot (1 - z^{-1}) F_M(t) \quad (5.4.18)$$

onde  $S_1(t+1)$  é considerado como o valor correto da variável de saída  $S_1$ ,  $S_1^*$  é o “set point” desejado para a concentração de substrato  $S_1$ ,  $q$  é um fator escalar (fator de amortecimento) e  $z^{-1}$  é o operador deslocamento à ré (*back shift operator*). Se o objetivo de controle for escolhido como sendo a minimização da variância da variável  $\phi(t)$ , a lei de controle é especificada pela escolha do sinal de controle  $F_M(t)$  que satisfaz a equação  $\phi(t+1) = 0$ . Tem-se então a Equação 5.4.19, derivada a partir das Equações 5.4.2 e 5.4.18:

$$F_M(t) = \frac{\Delta h \theta_4 X_1(t) + S_1^*(t) - \theta_1 S_1(t) + q \cdot F(t-1)}{q + \frac{\Delta h}{V_1 (1 - R)} (\theta_2 - \theta_3 S_1(t))} \quad (5.4.19)$$

O último termo na Equação 5.4.18 é usado para reduzir a magnitude da ação de controle através da penalização da variável  $F_M$  (fator de amortecimento). Na realidade, este fator introduz uma ação integral na ação de controle. Um aumento de  $q$  tende a tornar a ação de controle menos vigorosa e em contrapartida uma diminuição no valor desta variável leva a ações de controle mais vigorosas. O termo  $(1 - z^{-1})$  provê uma ação integral de modo a proporcionar a eliminação de *offsets* no caso de problemas supervisórios. Como pode ser notado a flexibilidade deste controlador é grande frente à sua simplicidade.

### 5.4.5 - Controle por retroalimentação de estados utilizando Técnicas de Otimização no projeto do controlador

Tendo em vista a necessidade de em alguns casos práticos de aplicação de sistemas de controle desejar-se que a variável controlada siga de perto uma trajetória requerida, neste item propõe-se um controlador que é uma mistura das estratégias “feedback” e “feedforward”, com constantes ajustadas utilizando técnicas de otimização. Embora o procedimento utilizado não seja adaptativo, esta técnica pode ser estendida para o caso em que a otimização seja realizada em linha e em tempo real, tornando assim o controle adaptativo. Uma limitação deste procedimento é que ele requer um modelo acurado do processo e acredita-se que a utilização de modelos baseados em redes neurais acoplados com técnicas de otimização podem levar a excelentes sistemas de controle para processos com dinâmicas complexas e que requerem um controle acurado da variável controlada. Para estes casos podem ser dados como exemplo determinados sistemas biotecnológicos em que a temperatura possui influência fundamental no desempenho do sistema e que deve estar circunscrita dentro de uma determinada faixa de valores para que não haja prejuízo aos organismos vivos presentes ou ocorra o desnaturamento de enzimas.

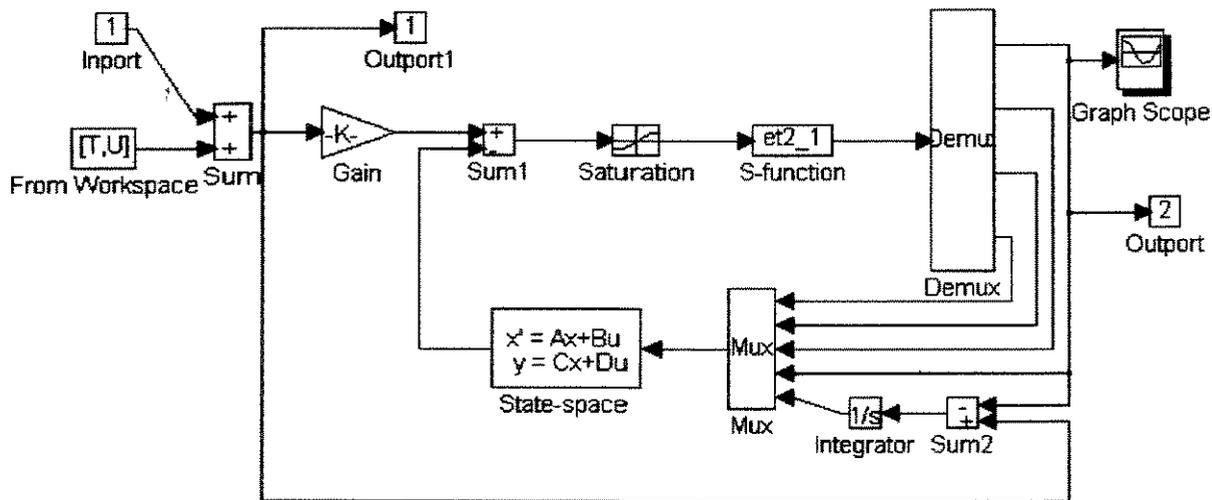


Figura 5.2 - Esquema do sistema de controle proposto utilizando o Simulink/Matlab 4.0.

O sistema de controle em malha fechada possui uma entrada e múltiplas saídas (*SIMO - Single-Input, Multiple-Output*) como mostrado na Figura 5.2. Esta figura mostra como implementar este

problema usando o software Matlab™ 4.0 acoplado com o *Simulink* e o *Optimization Toolbox*. A ação de controle  $F_M$  é calculada por:

$$F_M = K_1 x^* - \left[ K_2 x + K_3 \int_0^t (x^* - x) dt \right] \quad (5.4.20)$$

onde  $x$  é o vetor dos estados na saída e  $x^*$  é a trajetória desejada. A vantagem desta técnica é que ela pode ser facilmente estendida para problemas com múltiplas entradas e múltiplas saídas onde  $K_1$  transforma-se então em um vetor.

As constantes  $K_i$  da ação de controle acima são calculadas usando o algoritmo de otimização dos mínimos quadrados não lineares (função *leastsq* disponível no *Optimization Matlab Toolbox*). Esta função realiza uma busca de valores para os parâmetros  $K_i$  do controlador de modo a minimizar o quadrado do erro entre a saída desejada e a saída real. Como se observa na Equação 5.4.20 o sistema de controle é analógico, porém a versão digital desta técnica também pode ser implementada.

O problema é estabelecido matematicamente como sendo:

$$\underset{X}{\text{minimize}} \sum_{i,j} F(X)^* F(X)$$

onde  $X$  é um vetor e  $F(X)$  uma matriz. Problemas deste tipo ocorrem em um grande número de aplicações práticas, especialmente quando se quer ajustar um modelo a um conjunto de dados disponíveis, isto é, estimativa de parâmetros em modelos não lineares.

O algoritmo de otimização utiliza o método de Levenberg-Marquardt na busca dos novos valores dos parâmetros a serem ajustados e foi escolhido devido à sua robustez e eficiência quando comparado como outros métodos. Maiores detalhes acerca deste algoritmo podem ser encontradas no *Optimization Toolbox User's Guide (1992)*.

O objetivo do controle é fazer com que a variável manipulada (concentração de ART efluente do 4º reator) siga uma trajetória requerida, através da manipulação da vazão da corrente de entrada ao processo.

## 5.5 - Resultados e Discussão

### 5.5.1 - Controlador adaptativo LQG, controlador adaptativo baseado em modelo não linear e controlador PID digital

As Figuras 5.3 a 5.27 mostram o desempenho do controlador PID (Anexo II) e dos controladores adaptativos para o caso supervisório e regulatório. O controlador PID foi sintonizado através da manipulação das suas constantes até se encontrar um conjunto de valores que produzissem um desempenho satisfatório ( $K_c = 4$ ,  $\tau_I = 0,3$  e  $\tau_D = 0,1$ ). Semelhante metodologia foi empregada na sintonia dos controladores adaptativos.

Objetivando investigar o desempenho dos controladores utilizados serão considerados os seguintes casos:

1. Controle supervisório: o “set point” varia com o tempo segundo uma trajetória requerida para a variável controlada (concentração de ART no 1º reator,  $S_1$ ). O valor de  $S_1$  no estado estacionário de referência é 53,68 g/l. Entre 0 e 20 h  $S_1$  deve elevar-se para 60 g/l; entre 20 e 40 h deve voltar novamente para 53,68 e finalmente entre 40 e 60 h deve elevar-se novamente a 60 g/l, caracterizando assim uma onda quadrada;
2. Controle regulatório: o “set point” é mantido fixo e o sistema sofre perturbações. Adotou-se como perturbações mudanças no valor de  $S_o$  (de 180 para 198 g/l ou 162 g/l, conforme o tipo de perturbação ser negativa ou positiva) e de  $K_s$  (de 1,6 para 2,0 g/l).
3. Magnitude (intensidade) do esforço requerido pelo controlador ao elemento final de controle, geralmente uma válvula.
4. Influência dos parâmetros de projeto (ver tabela a seguir).

**Tabela 5.7** - Parâmetros de projeto que devem ser ajustados nas estratégias de controle implementadas.

TIPO DE CONTROLADOR	PARÂMETROS DE PROJETO
PID	tempo de amostragem, $K_c$ , $\tau_I$ , e $\tau_D$
adaptativo baseado em modelo não linear	tempo de amostragem, $q$
adaptativo LQG	tempo de amostragem, $Q$ , $R$

Como pode ser visto na Tabela 5.7, o controlador que possui o menor número de parâmetros a serem ajustados é o controlador adaptativo baseado em modelo não linear (CNL), que possui apenas dois parâmetros. A estratégia utilizada na sintonia deste controlador e do controlador adaptativo LQG foi a de obter através de simulações um valor razoável para os parâmetros que devem ser ajustados e a partir destes valores verificar a sensibilidade do desempenho do controlador para mudanças nos valores dos parâmetros de projeto, ou seja, investigar o quão sensível é o controlador a uma escolha não muito acertada de seus parâmetros ajustáveis. Das três estratégias de controle empregadas o PID é o mais sensível a uma escolha incorreta dos seus parâmetros, seguido pelo LQG e pelo CNL em ordem decrescente de sensibilidade.

A Figura 5.3 mostra o desempenho do PID para o problema supervisório e com constantes bem sintonizadas através de simulações. No entanto, pequenas alterações nos valores dessas constantes podem levar a um comportamento completamente instável do sistema em malha fechada. A Figura 5.25 e 5.26 mostram o desempenho do PID quando sua constante derivativa foi mudada de 0,1 para 1 para os casos supervisório e regulatório citados anteriormente.

As Figuras 5.4 e 5.5 mostram a influência do parâmetro  $q$  do CNL no desempenho deste controlador para o caso supervisório. Verifica-se que grandes valores de  $q$  (da ordem de 10) levam a uma resposta subamortecida que não consegue atingir o *set point* requerido dentro do intervalo de tempo proposto enquanto que baixos valores de  $q$  (da ordem de 0,3) levam a uma resposta oscilatória. Como regra geral pode-se dizer que  $q = 1$  é uma boa estimativa inicial para este parâmetro, sendo que

para o sistema em estudo (com amostragem de 12 min)  $q$  entre 2 e 4 representa o melhor conjunto de valores que proporcionam uma resposta não muito lenta, porém não-oscilatória. O parâmetro  $q$  pode ser visto como sendo um fator de amortecimento no cálculo da variação no valor da variável manipulada. Este termo foi introduzido com a finalidade de tornar a ação de controle integral, ou seja, a nova atuação do controle leva em consideração a sua situação anterior, evitando assim, mediante uma escolha adequada de  $q$ , que o sistema tome ações de controle bruscas, incapazes de serem atingidas na prática. Percebe-se que quando  $q = 0$  (eliminação da ação integral) o sistema de controle torna-se instável.

A Figura 5.6 mostra a influência do tempo de amostragem no desempenho do controlador, mantido  $q$  fixo, onde se observa que a medida que se aumenta o valor desta variável, o sistema vai se tornando mais amortecido.

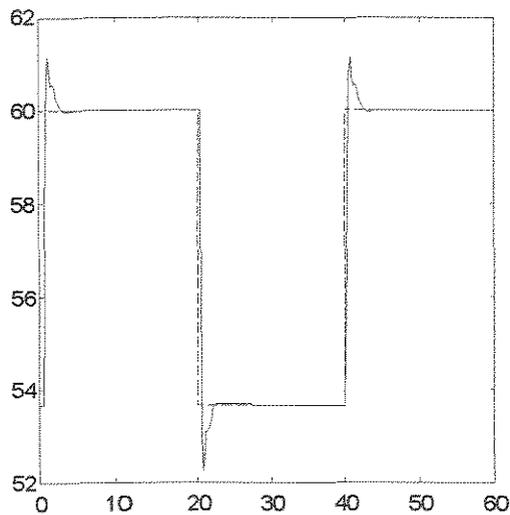
As Figuras 5.7, 5.8 e 5.9 mostram o desempenho do sistema de controle CNL para o caso regulatório. Verifica-se que à medida que se aumenta o valor de  $q$  o sistema demora mais a retornar ao estado estacionário original, porém em compensação, oscila bem menos. Novamente, valores baixos de  $q$  levam a uma resposta mais oscilatória, principalmente quando a perturbação é positiva.

A Figura 5.10 mostra o desempenho do controlador implementado segundo a Equação 5.4.17. Como se pode perceber nesta figura, esta estratégia de controle adaptativo baseada em modelo não-linear não se revelou conveniente para este sistema. Isto se deve ao fato de que nesta técnica, não há um fator que impede mudanças repentinas e bruscas requeridas pelo controlador, desestabilizando o sistema.

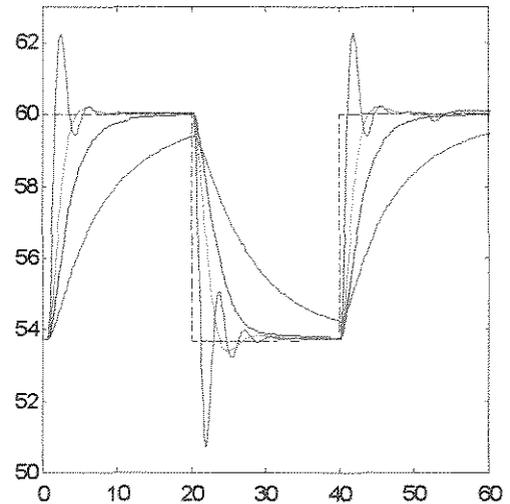
No controlador adaptativo LQG adotou-se a seguinte estratégia de sintonia: primeiramente considerou-se  $Q = R = I$  (onde  $I$  é uma matriz identidade), ou seja, todos os estados e entrada com o mesmo peso unitário. Em seguida, fixou-se  $R = 1$  e variou-se o 1º elemento da matriz diagonal  $Q$ . As Figuras 5.11 e 5.12 mostram a influência de  $Q_{11}$  no desempenho do controlador e verifica-se que este parâmetro possui efeito inverso quando comparado com o controlador CNL, ou seja, para baixos valores de  $Q_{11}$  o sistema torna-se mais subamortecido e altos valores de  $Q_{11}$  tendem a tornar o sistema mais oscilatório. Para o caso regulador verifica-se que quanto maior o valor de  $Q_{11}$ , menor é a amplitude de oscilação, porém maior é sua frequência quando a perturbação é positiva e quando esta é negativa o sistema somente consegue retornar ao estado estacionário de referência para altos valores de  $Q_{11}$ .

Quanto ao esforço requerido na ação de controle, verifica-se que o PID toma ações de controle muito bruscas, o que é muito difícil de ser conseguido na prática e que os controladores adaptativos possuem um desempenho muitíssimo superior neste aspecto (Figuras 5.18 e 5.19).

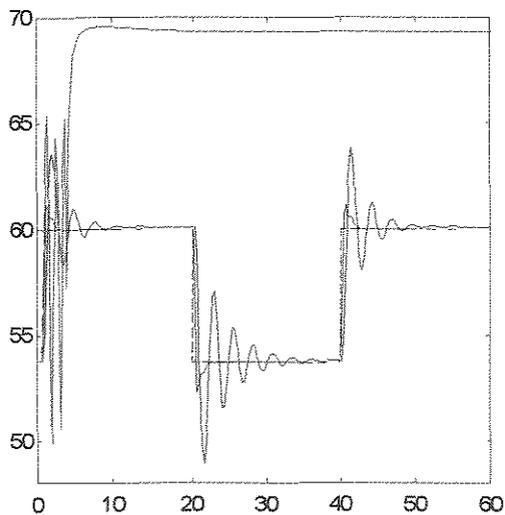
As Figuras 5.20 a 5.24 mostram o comportamento da concentração de ART e etanol no 4<sup>o</sup> reator para diversos casos. Verifica-se que somente o controle regulatório do primeiro reator não é suficiente para manter os demais reatores no “set point” de referência desejado. Isto é explicado pela multiplicidade de estados estacionários em reatores químicos com troca térmica e uma análise mais detalhada deste fenômeno foge ao escopo deste trabalho. Sugere-se que a implementação do controle no primeiro reator seja feita de maneira a considerar também a saída no quarto reator, em um caso prático de aplicação das estratégias de controle aqui apresentadas em uma planta industrial.



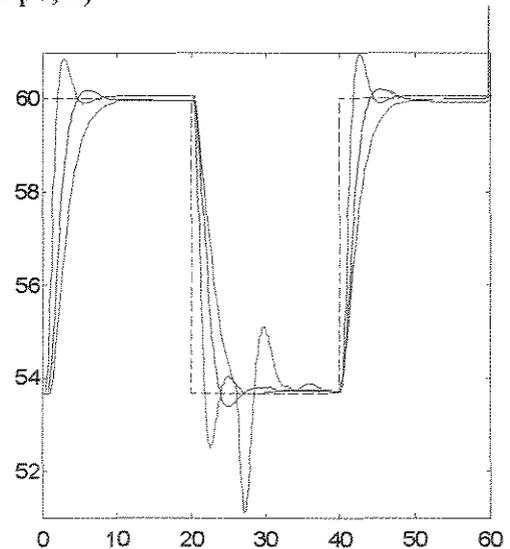
**Figura 5.3** - Controle PID supervisorio da concentração de ART no 1º reator;  $K_c = 4$ ,  $\tau_I = 0,3$  e  $\tau_D = 0,1$ ; tempo de amostragem: 12 min. (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



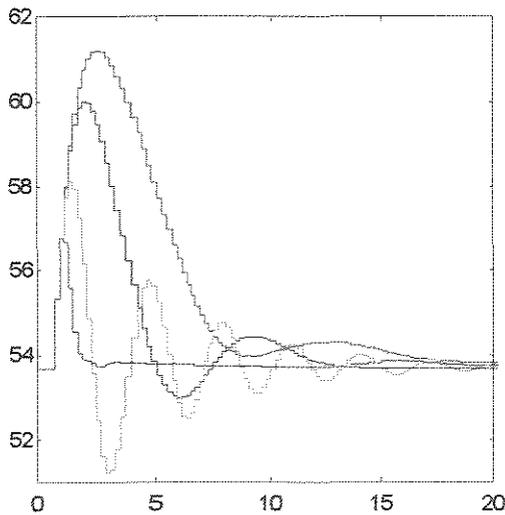
**Figura 5.4** - Controle Adaptativo supervisorio baseado em modelo não-linear da concentração de ART no 1º reator; vermelho:  $q = 10$ ; azul:  $q = 4$ ; verde:  $q = 2$ ; rosa:  $q = 0,5$ ; tempo de amostragem: 12 min. (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



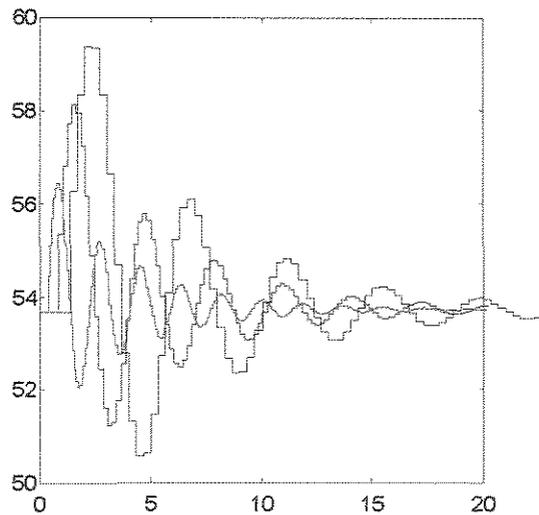
**Figura 5.5** - Controle Adaptativo supervisorio baseado em modelo não-linear da concentração de ART no 1º reator; azul:  $q = 0,3$ ; vermelho:  $q = 0$ ; tempo de amostragem: 12 min. (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



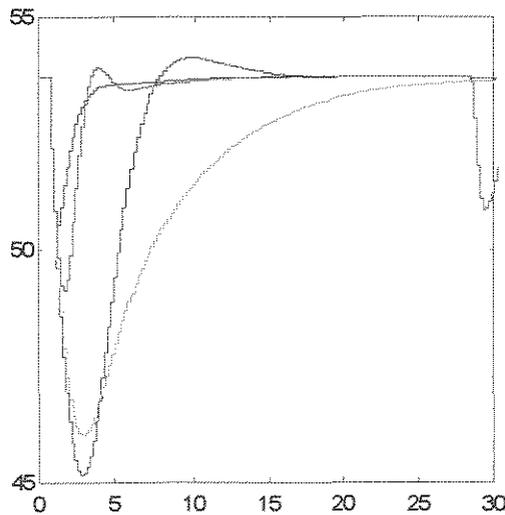
**Figura 5.6** - Controle Adaptativo supervisorio baseado em modelo não-linear da concentração de ART no 1º reator; influência do tempo de amostragem para um valor fixo de  $q = 2$ : vermelho: 5 min; azul: 12 min; preto: 20 min (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



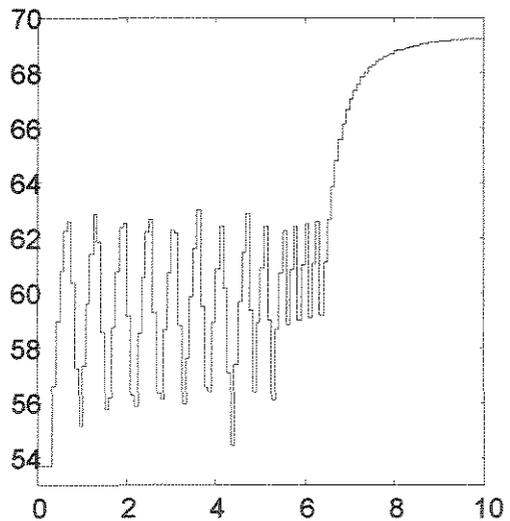
**Figura 5.7** - Controle Adaptativo regulatório baseado em modelo não-linear da concentração de ART no 1º reator; Perturbação em  $S_0 = 198$  g/l e  $K_s = 2$  g/l; tempo de amostragem de 12 min; vermelho:  $q = 4$ ; azul:  $q = 2$ ; verde:  $q = 0,5$ ; **preto**: PID (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



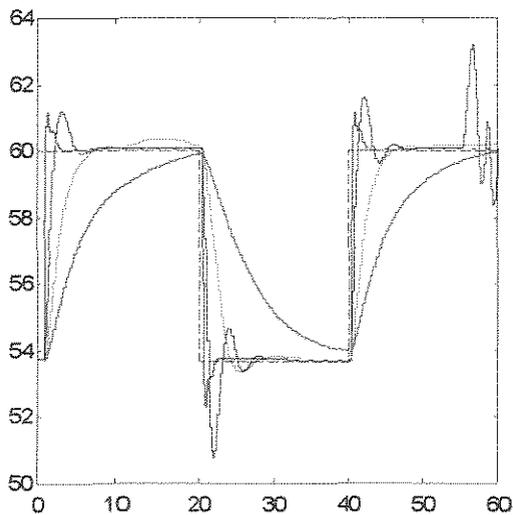
**Figura 5.8** - Controle Adaptativo regulatório baseado em modelo não-linear da concentração de ART no 1º reator; Perturbação em  $S_0 = 198$  g/l e  $K_s = 2$  g/l; influência do tempo de amostragem: vermelho: 5 min; azul: 12 min; **preto**: 20 min;  $q = 0,5$  (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



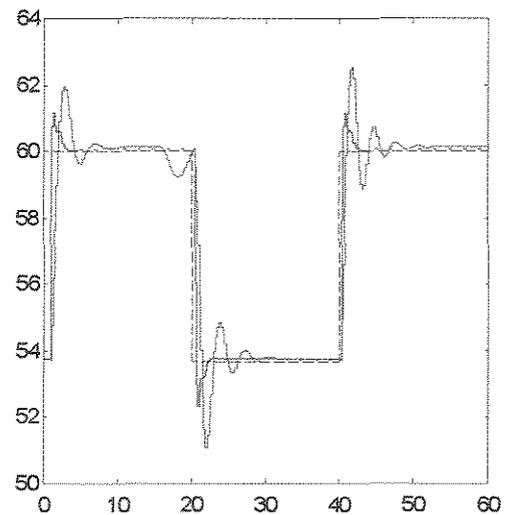
**Figura 5.9** - Controle Adaptativo regulatório baseado em modelo não-linear da concentração de ART no 1º reator; Perturbação em  $S_0 = 162$  g/l e  $K_s = 2$  g/l; verde:  $q = 4$ ; **preto**:  $q = 2$ ; vermelho:  $q = 0,5$ ; azul: PID; tempo de amostragem de 12 min (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



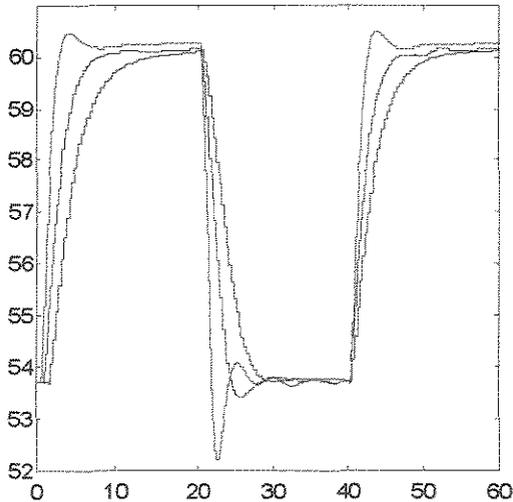
**Figura 5.10** - Controle Adaptativo supervisorio baseado em modelo não-linear da concentração de ART no 1º reator; tempo de amostragem de 5 min (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



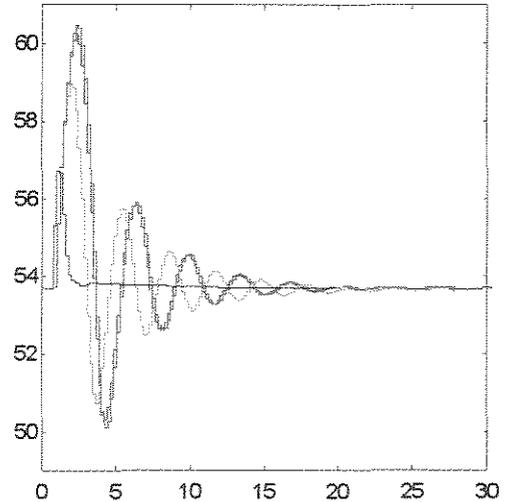
**Figura 5.11** - Controle Adaptativo LQG supervisorio da concentração de ART no 1º reator; tempo de amostragem de 12 min; azul: PID; preto:  $Q_{11} = 0,8$ ; verde:  $Q_{11} = 0,1$ ; vermelho:  $Q_{11} = 0,01$ ; (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



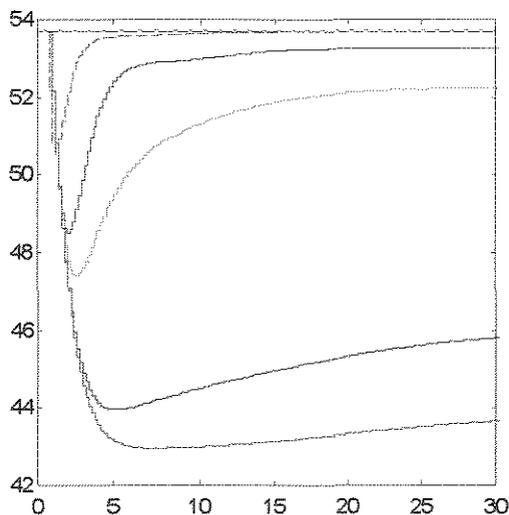
**Figura 5.12** - Controle Adaptativo LQG supervisorio da concentração de ART no 1º reator; tempo de amostragem de 12 min; azul: PID; vermelho:  $Q_{11} = 1,5$ ; (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



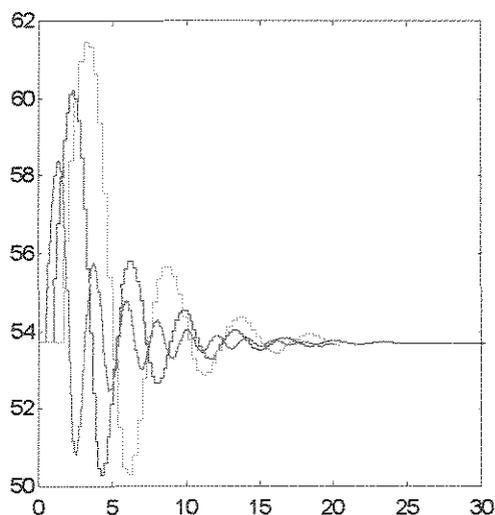
**Figura 5.13** - Controle Adaptativo LQG supervisorio da concentração de ART no 1º reator;  $Q_{11} = 0,1$ ;  $K_I = 50$ ; influência do tempo de amostragem - azul: 20 min; preto: 12 min; vermelho: 5 min (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



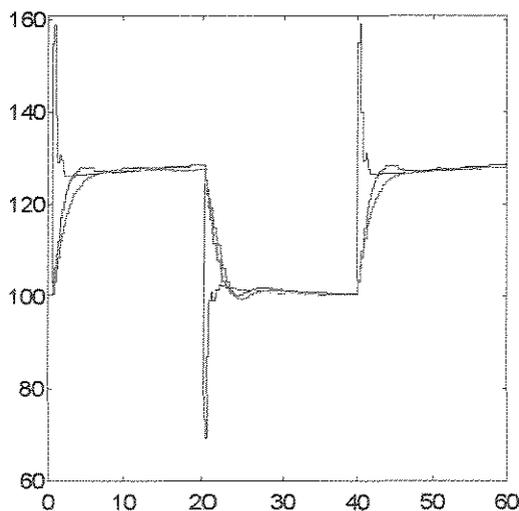
**Figura 5.14** - Controle Adaptativo LQG regulatório da concentração de ART no 1º reator; Perturbação em  $S_o = 198$  g/l e  $K_s = 2$  g/l; tempo de amostragem de 12 min; vermelho:  $Q_{11} = 0,05$ ; azul:  $Q_{11} = 0,1$ ; verde:  $Q_{11} = 1$ ; preto: PID (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



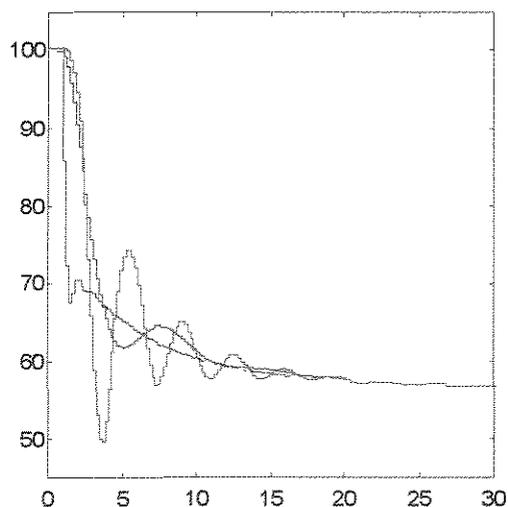
**Figura 5.15** - Controle Adaptativo LQG regulatório da concentração de ART no 1º reator; Perturbação em  $S_0 = 162$  g/l e  $K_s = 2$  g/l; tempo de amostragem de 12 min; vermelho:  $Q_{11} = 0,05$ ; azul:  $Q_{11} = 0,1$ ; verde:  $Q_{11} = 1$ ; preto:  $Q_{11} = 3$ ; vermelho pontilhado: PID (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



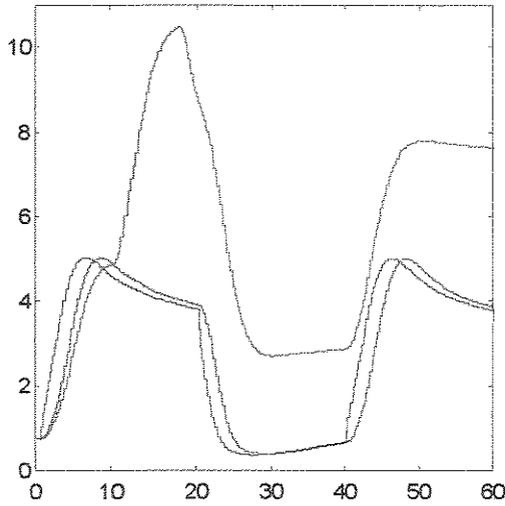
**Figura 5.16** - Controle Adaptativo LQG regulatório da concentração de ART no 1º reator; Perturbação em  $S_0 = 198$  g/l e  $K_s = 2$  g/l; influência do tempo de amostragem: verde: 20 min; azul: 12 min; vermelho: 5 min;  $Q_{11} = 0,1$  (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



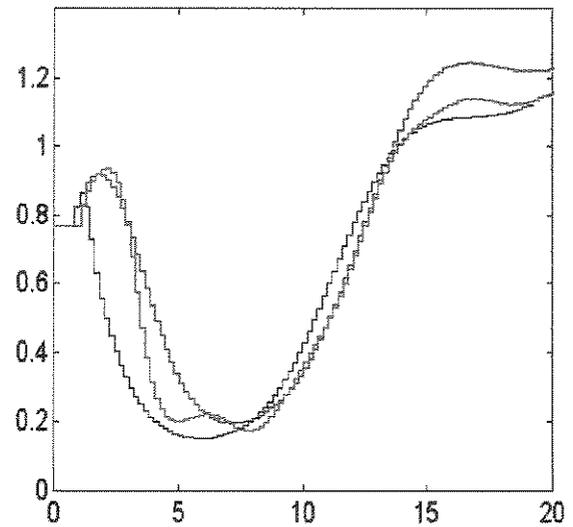
**Figura 5.17** - Controle Adaptativo supervisorio da concentração de ART no 1º reator. Comportamento da variável manipulada; preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$  e  $K_I = 5$ ; 12 min (Eixo Y: vazão de mosto,  $m^3/h$ ; Eixo X: tempo, h)



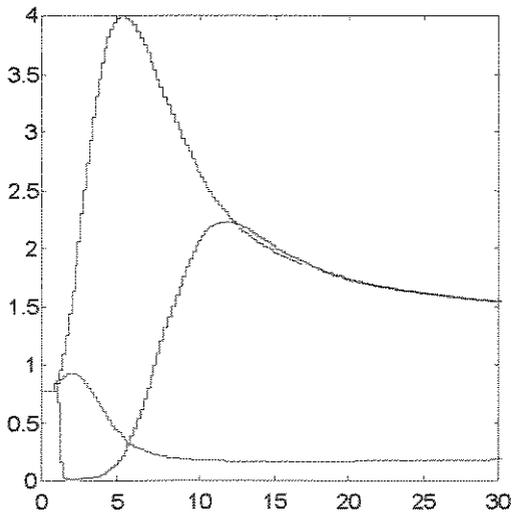
**Figura 5.18** - Controle Adaptativo regulatório da concentração de ART no 1º reator. Comportamento da variável manipulada; preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$  e  $K_I = 5$ ; 12 min; perturbação:  $S_0 = 198$  g/l;  $K_s = 2$  g/l (Eixo Y: vazão de mosto,  $m^3/h$ ; Eixo X: tempo, h)



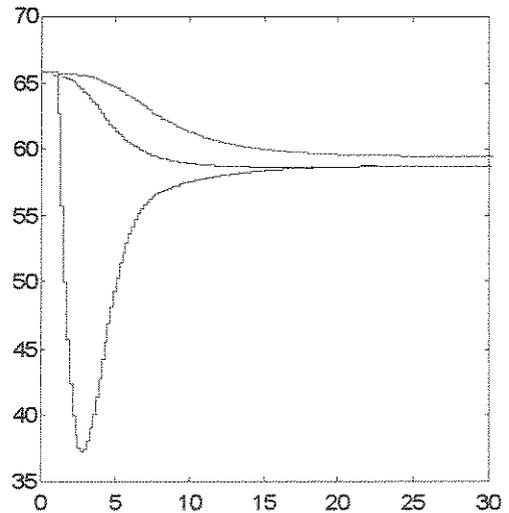
**Figura 5.19** - Concentração de ART no 4º reator. Controle supervisorio no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h).



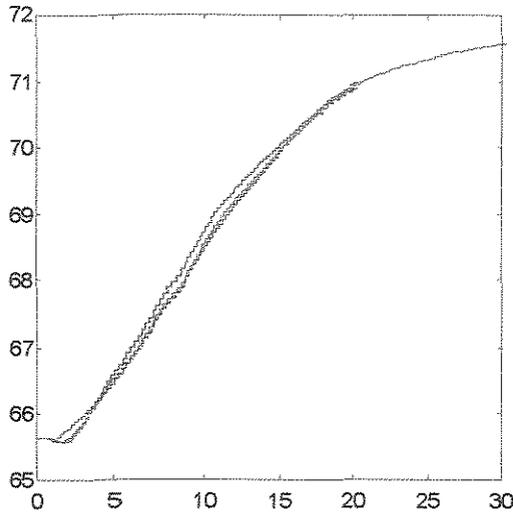
**Figura 5.20** - Concentração de ART no 4º reator. Controle regulatório no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_0 = 198$  g/l;  $K_s = 2$  g/l (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h).



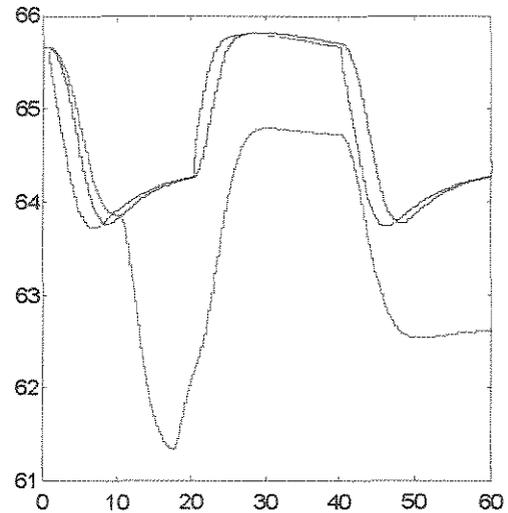
**Figura 5.21** - Concentração de ART no 4º reator. Controle regulatório no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_0 = 162$  g/l;  $K_s = 2$  g/l (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h).



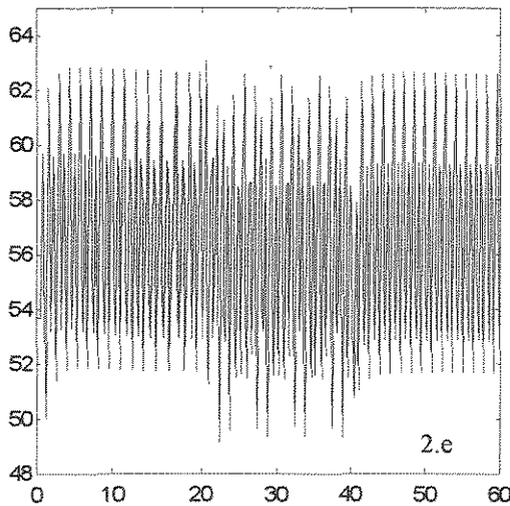
**Figura 5.22** - Concentração de etanol no 4º reator. Controle regulatório no 1º reator; Preto: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_0 = 162$  g/l;  $K_s = 2$  g/l (Eixo Y: concentração de etanol, g/l; Eixo X: tempo, h).



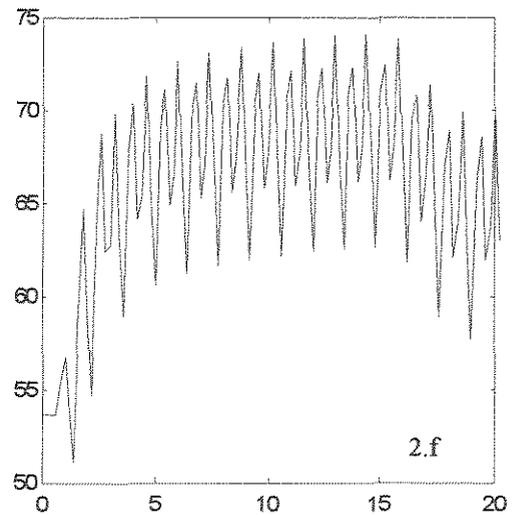
**Figura 5.23** - Concentração de etanol no 4º reator. Controle regulatório no 1º reator; **Preto**: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; perturbação:  $S_0 = 198$  g/l;  $K_s = 2$  g/l (Eixo Y: concentração de etanol, g/l; Eixo X: tempo, h).



**Figura 5.24** - Concentração de etanol no 4º reator. Controle supervisorio no 1º reator; **Preto**: PID; azul: adaptativo baseado em modelo não-linear com  $q = 2$ ; vermelho: LQG com  $Q_{11} = 0,1$ ; amostragem de 12 min; (Eixo Y: concentração de etanol, g/l; Eixo X: tempo, h).



**Figura 5.25** - Controle Adaptativo supervisorio da concentração de ART no 1º reator. Controlador PID mal sintonizado.  $K_c = 4$ ;  $\tau_i = 0,3$ ;  $\tau_D = 1$  (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)



**Figura 5.26** - Controle Adaptativo regulatório da concentração de ART no 1º reator. Controlador PID mal sintonizado.  $K_c = 4$ ;  $\tau_i = 0,3$ ;  $\tau_D = 1$ ; perturbação:  $S_0 = 198$  g/l;  $K_s = 2$  g/l (Eixo Y: concentração de ART, g/l; Eixo X: tempo, h)

### 5.5.2 - Controlador projetado utilizando técnicas de otimização

As Figuras 5.26 e 5.27 mostram o desempenho do sistema de controle em malha fechada. A saída desejada é uma rampa, descrita pela função:

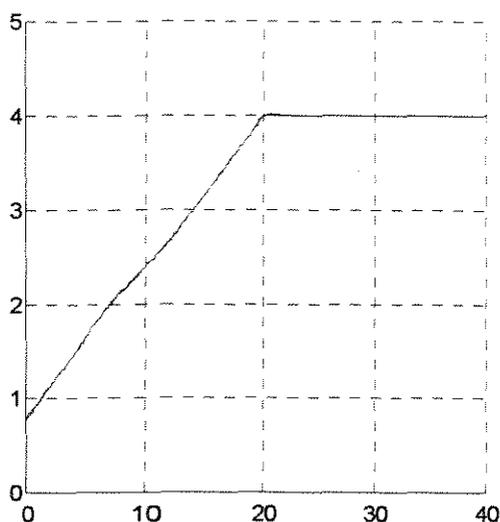
$$S_4 = \begin{cases} 0.16t + 0.8, & \text{se } t \leq 20 \text{ h} \\ 4, & \text{se } 20 \text{ h} < t < 40 \text{ h} \end{cases}, \text{ onde a variável } t \text{ representa o tempo.}$$

Como pode ser visto nesta figura, o algoritmo de otimização foi capaz de ajustar as constantes do controlador de tal modo que a resposta em malha fechada coincide perfeitamente com a saída desejada. Além do mais, a variável manipulada não sofre atuações bruscas (esforço de controle baixo).

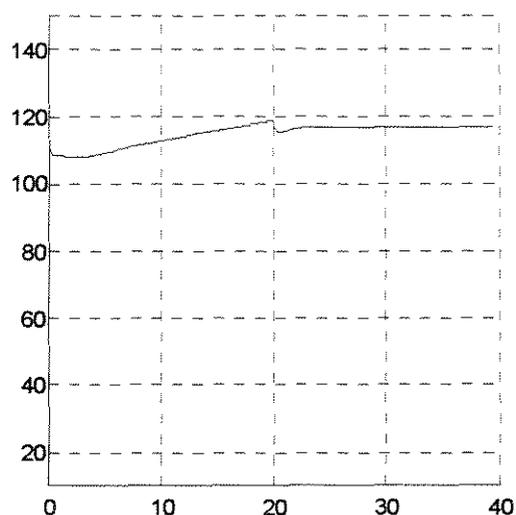
Objetivando testar a capacidade destas constantes do controlador em levar o sistema ao *set point* desejado mesmo na presença de fortes perturbações, a concentração de ART no mosto foi assumida como sendo 162 g/l (-10 % em relação ao estado estacionário) e a temperatura do fluido refrigerante como sendo 31°C (+ 10,7 % em relação ao estado estacionário). A Figura 5.29 mostra que apesar de uma pequena oscilação no início, o controlador foi capaz de conduzir com sucesso o sistema ao novo estado desejado.

A Figura 5.31 mostra a saída quando os parâmetros do modelo E e Ks foram assumidos como sendo 2,67 % menor e 25 % maior, respectivamente e o controlador utilizando o mesmo conjunto de constantes ajustadas anteriormente. Apesar de um pequeno desvio em relação ao caminho desejado, a resposta do sistema continua sendo satisfatória, mesmo quando parâmetros do modelo modificam-se.

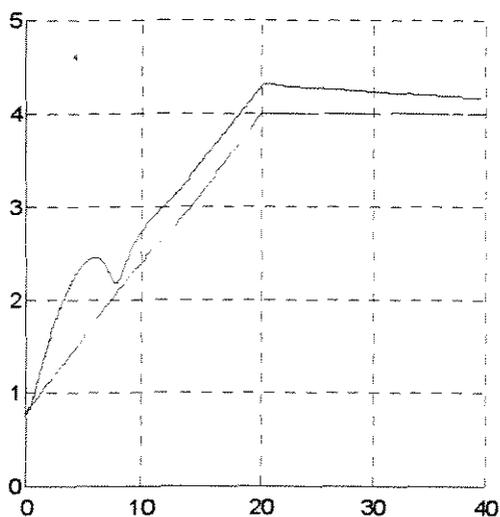
Finalmente, o caminho desejado para a variável controlada foi assumido como sendo uma função serra, ou seja, um caminho mais complexo. Até o tempo igual a 20 h o caminho é idêntico ao do problema anterior, porém entre 20 h e 40 h é simétrico em relação ao intervalo anterior (descrito pela equação:  $S_4 = -0,16t + 7,2$ ). As constantes do controlador foram novamente ajustadas e a resposta em malha fechada é mostrada na Figura 5.31 na qual se vê a perfeita concordância entre a trajetória requerida e a resultante do sistema em malha fechada.



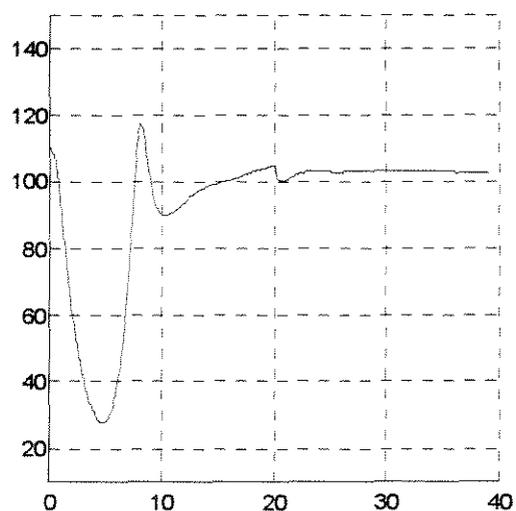
**Figura 5.27** - Concentração de ART (g/l - Eixo Y) no 4º reator versus tempo (h - Eixo X). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada).



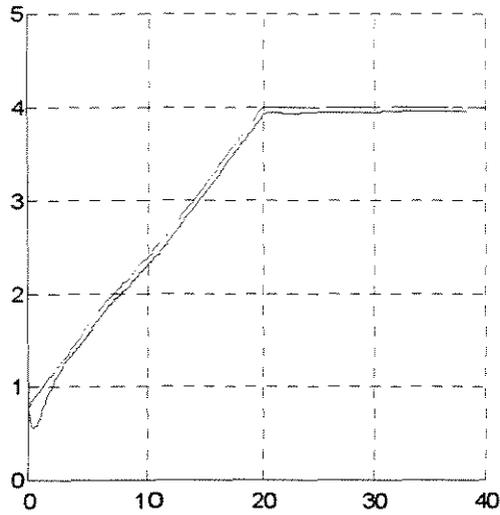
**Figura 5.28** - Vazão de mosto ( $m^3/h$  - variável manipulada) versus tempo (h). Resposta do sistema a uma trajetória requerida.



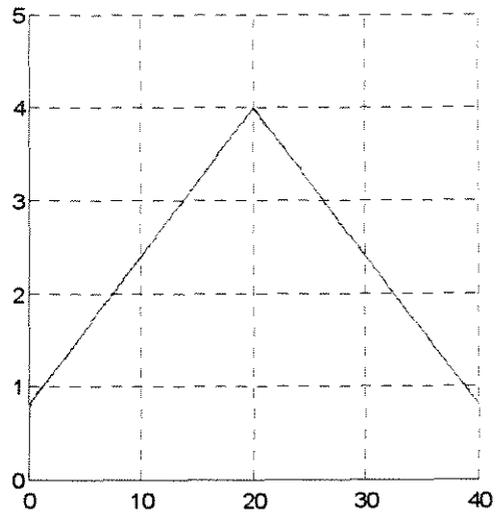
**Figura 5.29** - Concentração de ART (g/l) no 4º reator versus tempo (h). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada) sob perturbação em  $S_0 = 198$  g/l,  $T_0 = T_{je} = 31$  °C.



**Figura 5.30** - Vazão de mosto ( $m^3/h$  - variável manipulada) versus tempo (h). Resposta do sistema a uma trajetória requerida sob perturbação em  $S_0 = 198$  g/l,  $T_0 = T_{je} = 31$  °C.



**Figura 5.31** - Concentração de ART (g/l) no 4<sup>o</sup> reator versus tempo (h). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada) sob perturbação em  $K_s = \text{g/l}$  e .



**Figura 5.32** - Concentração de ART (g/l) no 4<sup>o</sup> reator versus tempo (h). Resposta do sistema (linha cheia) a uma trajetória requerida (linha tracejada).

A tabela que se segue resume as vantagens e desvantagens de cada um dos controladores examinados anteriormente.

Tabela 5.8 - Vantagens e desvantagens dos controladores implementados.

CONTROLADOR	VANTAGENS	DESVANTAGENS
<b>PID</b>	<ul style="list-style-type: none"> <li>• facilmente implementado;</li> <li>• quando bem sintonizado, geralmente produz bons resultados para sistemas de controle regulatórios;</li> </ul>	<ul style="list-style-type: none"> <li>• restrito a sistemas com uma entrada e uma saída;</li> <li>• difícil de ser sintonizado na prática;</li> <li>• o uso de constantes mal sintonizadas tornam o sistema facilmente instável;</li> <li>• toma ações de controle bruscas;</li> <li>• possui quatro parâmetros a serem ajustados (tempo de amostragem, <math>K_c</math>, <math>\tau_i</math> e <math>\tau_D</math>);</li> <li>• em geral não produz bons resultados para sistemas de controle supervisórios;</li> </ul>
<b>Adaptativo LQG</b>	<ul style="list-style-type: none"> <li>• aplicável a sistemas com entradas e saídas múltipla;</li> <li>• permite pesar mais um estado em relação a outro no cálculo da ação de controle;</li> <li>• grande suporte teórico no que se refere à robustez, estabilidade e convergência;</li> <li>• permite a utilização de "softsensors" para a predição de estados não-mensuráveis ou de difícil acessibilidade;</li> </ul>	<ul style="list-style-type: none"> <li>• maior dificuldade de implementação;</li> <li>• envolve a solução em tempo real da Equação de Riccati;</li> <li>• quando aplicável a sistemas não-lineares pode divergir;</li> <li>• necessita de um estimador em linha dos parâmetros do modelo;</li> <li>• necessita do conhecimento de todos os estados do sistema;</li> </ul>
<b>Adaptativo baseado em modelo não-linear</b>	<ul style="list-style-type: none"> <li>• menos sensível a uma sintonia inadequada dos parâmetros;</li> <li>• possui somente dois parâmetros que devem ser ajustados: tempo de amostragem e <math>q</math>;</li> <li>• relativamente simples de ser implementado;</li> </ul>	<ul style="list-style-type: none"> <li>• restrito a processos com uma entrada embora suporte múltiplas saídas;</li> <li>• necessita de um estimador em linha dos parâmetros do modelo;</li> <li>• necessita do conhecimento dos estados do sistema;</li> </ul>
<b>Estados retroalimentados projetado utilizando técnicas de otimização</b>	<ul style="list-style-type: none"> <li>• conduz com grande precisão o sistema ao "set point" desejado;</li> <li>• permite um monitoramento acurado da variável controlada;</li> <li>• pode empregar modelos que não são derivados das equações de balanço, como por exemplo, redes neurais;</li> </ul>	<ul style="list-style-type: none"> <li>• necessita de um modelo fiel ao processo;</li> <li>• tempo computacional é longo, dificultando o seu emprego em tempo real;</li> </ul>

## 5.6 - Conclusões

Os resultados apresentados neste trabalho mostram que as estratégias de controle adaptativas utilizadas (controlador adaptativo baseado em modelo não linear e controlador adaptativo LQG) possuem um desempenho superior quando comparados com o controlador clássico PID digital na forma do algoritmo da velocidade no controle da concentração de ART efluente de um sistema contínuo de fermentação alcoólica em escala industrial, com malha de controle de uma entrada e uma saída. Os controladores adaptativos necessitam de um modelo interno de controle que é identificado em linha utilizando um algoritmo recursivo, sendo a ação de controle tomada baseada nesse modelo interno. A atuação dos controladores avançados sobre a variável manipulada é mais suave quando comparada com o PID, sendo que na etapa de projeto pode-se projetar um controlador que atue mais vigorosa ou lentamente, através da manipulação dos fatores de amortecimento, dependendo da dinâmica do processo em estudo. Outro parâmetro que deve ser convenientemente ajustado é o tempo de amostragem.

Do mesmo modo mostrou-se que um controlador que utiliza realimentação total dos estados com constantes sintonizadas utilizando um algoritmo de otimização conveniente é capaz de conduzir com sucesso a saída do sistema a um caminho desejado. Este tipo de controlador se aplica facilmente a processos com múltiplas entradas e múltiplas saídas e é adequado em aplicações onde se quer ter um monitoramento acurado da variável manipulada.

Deste modo, as estratégias de controle apresentadas neste capítulo revelam grande potencial de aplicação no controle de sistemas fermentativos e também em outros sistemas complexos presentes na Engenharia Química. No próximo capítulo será dado um breve tratamento dos problemas a serem considerados no desenvolvimento de algoritmos de controle avançado do tipo adaptativo para colunas de destilação em batelada.

## CAPÍTULO VI

### CONTROLE DE UMA COLUNA DE DESTILAÇÃO EM BATELADA

#### 6.1 - Introdução

O interesse industrial pela destilação em batelada tem crescido consideravelmente nos últimos anos devido principalmente à utilização deste processo na separação de pequenas quantidades de misturas contendo produtos de alto valor agregado. Muitos estudos têm-se concentrado na determinação de uma política ótima de operação que consiste em se determinar uma trajetória ótima para a taxa de refluxo e pressão durante a batelada bem como o tempo dos cortes entre a retirada de dois produtos de interesse contidos na mistura a ser separada (*slops cuts*) (Diwekar et al., 1987; Robinson, 1969 e 1970). No entanto, pouca atenção tem sido dada ao problema do controle da destilação em batelada.

Se houvesse a disponibilidade de analisadores de concentração perfeitos, o controle da destilação em batelada seria facilmente implementado uma vez que se conhece uma política ótima de operação. A transição entre as fases de operação a refluxo constante, retirada de produto e *slops cuts* é realizada em função do valor da composição do produto desejado no produto retirado. No entanto, na maioria das aplicações industriais da destilação em batelada, não se dispõe de medidas perfeitas de composição. Isto significa que um controle inferencial necessita ser utilizado de modo que a partir de dados de temperatura e pressão se determine a concentração correspondente. Este tipo de estratégia permite que se evite a utilização de instrumentos de difícil operação, alto custo fixo e operacional e atrasos devido ao tempo de análise gasto, como em geral são os analisadores em linha de concentração.

Este capítulo apresenta a implementação de um sistema de controle aplicado a uma coluna de destilação em batelada utilizando o controlador PID digital e um controlador adaptativo auto-ajustável. Mostra-se que a malha de controle necessita estar subordinada a uma outra malha hierarquicamente superior que realize a reconciliação dos dados medidos e utilize esses dados em um otimizador em linha que irá informar ao controlador a trajetória que o sistema deve percorrer (política de operação) de modo a maximizar a quantidade de destilado ou minimizar o tempo de batelada.

## 6.2 - Descrição do Processo Simulado

O sistema a ser controlado consiste em uma coluna de destilação em batelada, com um condensador e um refeedor (*reboiler*), como mostrado esquematicamente na Figura 6.1.

A destilação em batelada é usada quando a demanda pelo produto é limitada, bem como em sistemas químicos específicos, principalmente em química fina. Uma só coluna pode ser usada para separar uma mistura multicomponente ao invés de se usar  $NC - 1$  colunas contínuas, onde  $NC$  é o

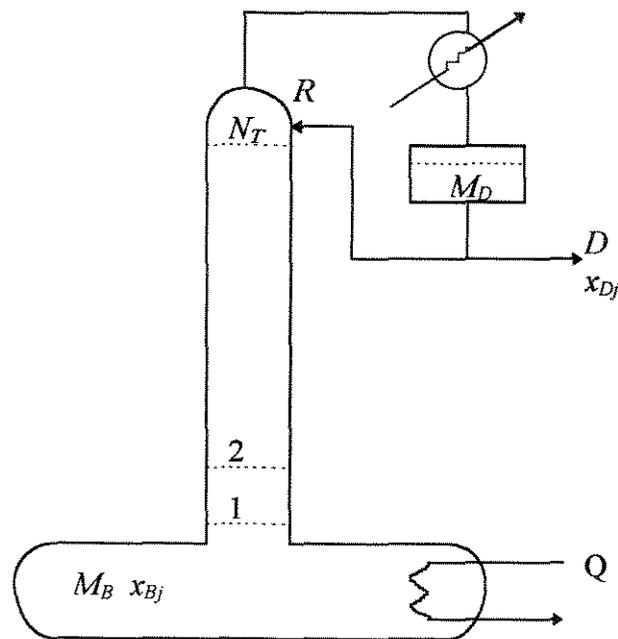


Figura 6.1 - Esquema geral de uma coluna de destilação batelada.

número de componentes a serem separados na mistura. A energia gasta na destilação batelada é geralmente maior do que a requerida na destilação contínua, mas como as quantidades destiladas são pequenas e os produtos de alto valor agregado, o gasto energético é compensado pelo valor dos produtos.

Esta operação unitária não atinge o estado estacionário na etapa de retirada dos produtos porque

a mistura é alimentada somente no início e o produto purificado é continuamente retirado, conseqüentemente mudando a composição da mistura remanescente na coluna em um dado tempo e reduzindo a quantidade a ser destilada. O controle de uma coluna de destilação em batelada objetiva obter um produto (destilado) tão puro quanto possível, através da manipulação da composição e temperatura da coluna. Em geral, a operação controlada leva a menores tempos de processamento.

Na base da coluna tem-se um refeedor, o qual fornece o calor de vaporização para a mistura a ser separada. Inicialmente, quando a mistura contém uma quantidade significativa do componente mais volátil (baixo ponto de bolha), a composição da fase vapor é rica neste componente, e, conseqüentemente, a temperatura do vapor que deixa o *reboiler* é também baixa. Um condensador localizado no topo da coluna remove o calor latente de vaporização do vapor, condensando-o. Uma parte deste condensado é retornado à coluna como refluxo, enquanto que o restante é retirado na forma de produto destilado. O refluxo líquido que entra no topo da coluna flui descendente e entra em contato com o vapor ascendente que sai do refeedor. Este contato é feito em todos os pratos da coluna e dependendo da natureza dos componentes, suas quantidades relativas e da temperatura em cada estágio, ocorre uma troca mássica entre as duas fases. Isto possibilita que o vapor ascendente torne-se cada vez mais rico no componente mais volátil e que o líquido descendente se torne mais rico no componente mais pesado, proporcionando assim a separação dos produtos.

A coluna opera a refluxo total, isto é, nenhum produto é retirado, até que a concentração do produto desejado no destilado  $x_{DI}$ , o componente mais volátil, atinja a pureza especificada (ou o estado estacionário). Então um produto destilado, o qual é o componente mais leve, é retirado a uma determinada taxa que pode ser um valor constante (*Lang et al., 1994*) ou variável quando se quer manter a concentração do destilado em um valor fixo .

Assim que a mistura remanescente no refeedor vai se tornando mais pobre no componente mais volátil, a temperatura do ponto de bolha da mistura começa a subir. O perfil de temperatura na coluna continua mudando, ocasionando uma conseqüente mudança na composição do vapor que deixa o topo da coluna e é condensado no condensador. Isto resulta em uma contínua mudança na composição do destilado, e em conseqüência, em sua pureza. Inicialmente tinha-se um destilado rico no componente

mais volátil e no decorrer do tempo sua composição vai se alterando de modo que os componentes mais pesados começam a predominar. Isto pode ser corrigido aumentando-se continuamente a quantidade de condensado refluxado ao invés de mantê-la constante. Esta operação não é fácil de ser efetivada e resulta em uma contínua diminuição da quantidade de produto retirado como destilado. A maneira mais prática de se realizar a mudança na razão de refluxo, é esta ser feita a tempos definidos (após uma análise preliminar do sistema) de tal modo a possibilitar que no final da operação tenha-se um produto de composição média de valor desejado. A outra alternativa é a utilização de um sistema de controle. Esta alternativa é interessante do ponto de vista de que não necessita de um prévio conhecimento do comportamento da mistura a ser separada, pois o próprio controlador irá mudar a taxa de destilado retirado, baseado na medida da concentração do destilado.

À medida que a destilação se processa a quantidade do componente 1 no retervedor diminui até atingir um valor tal que a pureza do destilado não atende mais às especificações ou a taxa de produto retirada é muito pequena. Neste instante há duas alternativas possíveis: se o segundo componente mais volátil é também um produto de interesse, após um período de retirada de produtos fora de especificação, chamado de corte (*slop cut*), no qual a concentração do segundo componente mais volátil atinge a pureza desejada, começa-se a retirada do segundo produto; caso contrário, encerra-se a batelada e nova carga é adicionada ao retervedor, que pode juntar-se à carga anterior remanescente ao corte, ou inicializar-se com uma carga totalmente nova.

### **6.3 - Modelagem, Parâmetros e Condições Iniciais do Processo Simulado**

O projeto e operação otimizados de uma coluna de destilação em batelada é um dos problemas mais interessantes da Engenharia Química. O processo pode ser operado a várias pressões e razões de refluxo tanto na etapa da retirada de um produto, quanto no período de cortes. O projeto ótimo da coluna (diâmetro, número de pratos ou comprimento de recheio) e uma operação otimizada podem ser importantes na redução do tempo de batelada, os quais resultam em maior capacidade e/ou melhora na qualidade do produto (menos tempo a altas temperaturas reduz a degradação térmica).

Neste trabalho, adotaram-se as seguintes simplificações na modelagem matemática da coluna:

- pratos teóricos;

- fluxos molares constantes (vapor e líquido);
- acúmulo de vapor nos pratos desprezível;
- condensador total;

A quantidade total de carga adicionada na coluna é  $M_{bo}$  (moles). Este material pode ser uma carga fresca com composição  $z_j$  ou uma mistura de carga fresca e cortes, como mencionado anteriormente. A composição no refeedor no início da batelada é  $x_{Boj}$ . A composição no refeedor em um tempo qualquer é  $x_{Bj}$ . O “holdup” instantâneo no refeedor é  $M_B$ . Os “holdups” nos pratos e no balão de refluxo são assumidos como sendo constantes. A taxa de vapor  $V$  é considerada constante (moles por hora). O refeedor, pratos e balão de refluxo são inicialmente preenchidos com material à composição inicial  $x_{Boj}$ .

Um modelo simplificado que descreve a destilação multicomponente em batelada é mostrado abaixo (Luyben, 1989):

- Balanço de Massa no Refeedor:

$$\frac{dM_B}{dt} = -D \quad (6.3.1)$$

$$\frac{d[M_B x_{Bj}]}{dt} = R x_{1j} - V y_{Bj} \quad (6.3.2)$$

- Balanço de massa no Prato  $n$ :

$$M_n \frac{dx_{nj}}{dt} = R[x_{n+1,j} - x_{nj}] + V[y_{n-1,j} - y_{nj}] \quad (6.3.3)$$

- Balanço de massa no Prato  $N_T$  (prato do topo):

$$M_{NT} \frac{dx_{NT,j}}{dt} = R[x_{Dj} - x_{NT,j}] + V[y_{NT-1,j} - y_{NT,j}] \quad (6.3.4)$$

- Balanço de massa no Balão de refluxo:

$$M_D \frac{dx_{Dj}}{dt} = Vy_{NT,j} - [R + D]x_{Dj} \quad (6.3.5)$$

$$R = V - D \quad (6.3.6)$$

- Quantidade de destilado acumulada:

$$\frac{dH_D}{dt} = D \quad (6.3.7)$$

- Quantidade destilada do componente 1:

$$\frac{dHX_1}{dt} = Dx_{D1} \quad (6.3.8)$$

A composição  $y_j$  e a temperatura da fase gasosa são determinados termodinamicamente a partir da condição de existência do equilíbrio de fases líquido-vapor. Dependendo do grau de precisão requerido na simulação de colunas de destilação, pode-se:

- 1 - considerar a volatilidade relativa ( $\alpha_i$ ) como sendo constante; a composição da fase gasosa se relaciona com a composição da fase líquida segundo a expressão:

$$y_j = \frac{\alpha_j x_j}{\sum_{k=1}^{NC} \alpha_k x_k} \quad (6.3.9)$$

A escolha desta alternativa não permite o cálculo da temperatura de equilíbrio, e portanto só é recomendada como etapa inicial no estudo das estratégias de controle. Esta alternativa é apresentada devido ao fato do tempo computacional ser muito menor quando comparado com o tempo gasto quando se considera cálculos termodinâmicos mais complexos.

2 - considerar ambas as fases (líquida e vapor) como sendo fases ideais; a temperatura de equilíbrio é a temperatura que satisfaz a equação abaixo, derivada a partir da lei de Raoult:

$$\sum_{j=1}^{NC} x_j P_j^{sat} - P = 0 \quad (6.3.10)$$

O cálculo da temperatura é feito iterativamente a partir de uma estimativa inicial, sendo que se utiliza o método de Newton-Raphson na busca da raiz que satisfaz a equação. Calculada a temperatura que satisfaz a equação acima, a composição da fase gasosa é dada por:

$$y_j = \frac{x_j P_j^{sat}}{P} \quad (6.3.11)$$

sujeita às restrições:

$$\begin{aligned} \sum_j x_j &= 1 \\ \sum_j y_j &= 1 \end{aligned} \quad (6.3.12)$$

3 - considerar as não-idealidades das fases líquidas e vapor através do modelo de equilíbrio  $\gamma$ - $\phi$ , ou seja, modelar a fase líquida através de coeficientes de atividade ( $\gamma$ ) e a fase vapor através de uma relação PVT. Termodinamicamente o equilíbrio de fases líquido-vapor ocorre quando a fugacidade destas fases se igualam:

$$f_j^L = f_j^V \quad (6.3.13)$$

as fugacidades são dadas por:

$$f_j^V = \phi_j^V y_j P \quad (6.3.14)$$

$$f_j^L = \gamma_j x_j f_j^\circ \quad (6.3.15)$$

sendo  $f_j^\circ$  aproximado por  $P_j^{sat}$  e portanto:

$$f_j^L = \gamma_j x_j P_j^{sat} \quad (6.3.16)$$

Este modelo é capaz de prever com relativa precisão mesmo o equilíbrio líquido-vapor de misturas não ideais, como as formadas por substâncias polares. Os coeficientes de atividade podem ser preditos utilizando o método UNIQUAC quando não se dispõe de dados experimentais e o coeficiente de fugacidade de cada componente na mistura gasosa, previstos utilizando uma equação de estado, que pode ser por exemplo, a equação do virial truncada no segundo termo quando a pressão for baixa ou moderada.

## 6.4 - Projeto do Sistema de Controle

### 6.4.1 - Introdução

Vários trabalhos publicados na literatura reportam à utilização do controle adaptativo no controle de **colunas de destilação contínuas**. *Sastry et al.*, (1977) utilizaram um controlador adaptativo STR no controle da composição de topo em uma coluna binária, apresentando resultados de simulação e de uma planta piloto e comparação de desempenho com o controlador clássico PI; o STR foi formulado na forma polinomial e testado para a condição regulatória e supervisória; *Morris et al.*, (1982) e

*Dahlqvist (1981)* utilizaram um controlador adaptativo STR no controle simultâneo da composição de fundo e de topo em uma coluna binária em escala piloto; *Tham et al., (1991)* utilizaram um procedimento semelhante, porém com um cromatógrafo em linha para medidas de concentração; o STR foi projetado pelo critério da variância mínima e os resultados comparados com o desempenho de um PI e de um PID com múltiplas malhas; *Chien et al., (1987)* utilizaram um controlador STR para o controle da composição de topo e de fundo, porém utilizando duas malhas desacopladas; *Woinet et al., (1991)* também implementaram um controlador adaptativo STR na regulação da composição de topo de uma coluna binária; o controlador foi projetado utilizando o critério da localização dos pólos.

Para colunas de destilação em batelada *Fileti (1995)* utilizou o controlador adaptativo STR com representação do processo na forma de transformada-Z com coeficientes ajustados através de análise regressiva e leis de controle na forma PI e derivada do algoritmo de Dahlin.

#### 6.4.2 - Objetivos do Controle

Fica evidente da discussão acima que o controle de colunas de destilação em batelada precisa ser formulado levando-se em conta:

1.) o calor fornecido ao refeedor para controlar a taxa de vaporização. Isto é necessário para prover um tempo suficiente de contato entre as fases líquida e vapor na coluna, e permitir assim que se estabeleça o equilíbrio das mesmas, necessário à transferência de massa inter-fases. A queda de pressão ao longo da coluna é pequena, porém tem uma grande influência no seu desempenho. Se a queda de pressão da fase vapor tornar-se insuficiente, pode ocorrer inundamento da coluna. A quantidade de vapor que entra na coluna pode ser controlada manipulando a pressão do vapor de aquecimento utilizada no refeedor ou a corrente elétrica no caso de aquecimento por resistência elétrica.

**Variável controlada:** taxa de vaporização;

**Variável manipulada:** vazão de vapor que entra no refeedor;

**Variável medida:** queda de pressão ao longo da coluna.

2.) o calor retirado no condensador. Isto irá afetar a temperatura do líquido que retorna à coluna

na forma de refluxo, e portanto, a separação nos estágios. A manipulação do calor retirado pode ser feita controlando-se a vazão da água de resfriamento, deixando, se possível, a temperatura do condensado o mais próxima do ponto de bolha da mistura.

**Variável controlada:** temperatura do condensado;

**Variável manipulada:** vazão de resfriamento;

**Variável medida:** temperatura do condensado.

3.) a razão de refluxo, isto é, a razão entre a quantidade de líquido que retorna à coluna para a quantidade de líquido retirado como produto ou, ainda, a vazão de destilado. Isto pode ser feito pelo ajuste da válvula localizada na linha do refluxado que retorna ao topo da coluna.

**Variável controlada:** composição de destilado;

**Variável manipulada:** razão de refluxo ou vazão de destilado;

**Variável medida:** composição do vapor no prato NT (topo).

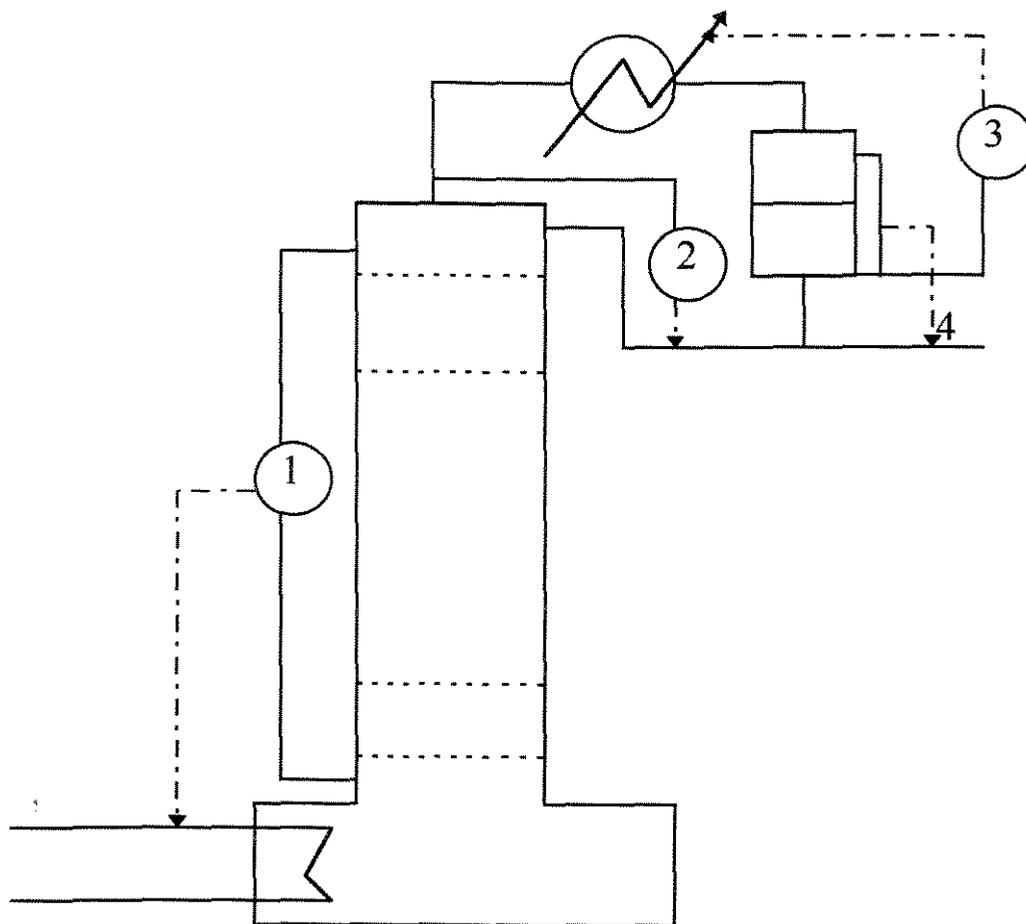
### 6.4.3 - Configuração do Sistema de Controle

Um esquema geral do sistema de controle da coluna de destilação em batelada pode ser visto na Figura 6.2.

A composição do vapor no topo da coluna pode ser calculada através de:

- medida direta (por exemplo, cromatografia em fase gasosa). A desvantagem desta técnica é o alto custo dos equipamentos envolvidos em medidas em tempo real e em linha e dificuldade de operação dos mesmos, em condições industriais;
- medida indireta através de medidas de temperatura e pressão e dados de equilíbrio líquido-vapor. A desvantagem desta técnica é que se supõe que há o equilíbrio termodinâmico entre as fases líquida e vapor (*Quintero, 1992*). O instrumento de medida de temperatura necessita ser o mais preciso possível e ser selecionado convenientemente para detectar pequenas mudanças de temperatura. Em geral, termômetros de resistência de platina são utilizados por

proporcionarem alta precisão (em média  $0,1\text{ }^{\circ}\text{C}$  em condições industriais). Termopares, apesar de possuírem menor precisão, também podem ser utilizados (Robinson, 1985);



**Figura 6.2** - Configuração mínima de controle de uma coluna de destilação em batelada. (1 - malha de controle da vazão de vapor; 2 - malha de controle da composição instantânea de destilado; 3 - malha de controle da temperatura da água de resfriamento; 4 - malha de controle do nível do condensador).

- medida indireta utilizando uma rede neural artificial que relacione temperatura, pressão e composição da fase vapor. Se a rede for treinada utilizando dados de equilíbrio de fases, esta técnica tem a mesma vantagem da anterior, porém o esforço computacional (e conseqüentemente o tempo de cálculo) é bem menor (Willis, 1992).

- medidas indiretas utilizando temperatura e pressão e correlação empírica tirada de dados de operação em malha aberta (*Buckley et al., 1985*);

O desempenho do sistema de controle depende fortemente do conhecimento preciso das variáveis envolvidas. Porém, independentemente do método de medida empregado (medida direta ou inferência) essa medida possui um certo grau de incerteza e necessita-se portanto realizar uma filtragem dos dados de modo a eliminar os ruídos presentes. Um conhecimento preciso dos estados e parâmetros do processo pode ser obtido, por exemplo, através do uso de técnicas de reconciliação de dados (*Ramamurthi et al., 1993*).

#### 6.4.4 - Controle Adaptativo Utilizando Modelo na Forma Equações Diferenças

A proposta inicial no controle da composição de destilado é a utilização do STR de *Åström e Wittenmark (1973)* modificado por *Clarke et al., (1975)*. Para tanto, supõe-se que existe uma relação linear entre a composição de destilado ( $x_T$ ) e a vazão de destilado retirada ( $D$ ), representado por:

$$x_T(t) + a_1 x_T(t-1) + a_2 x_T(t-2) = b_0 D(t-1) + b_1 D(t-2) + b_2 D(t-3) + \varepsilon(t) \quad (6.4.1)$$

ou:

$$A(q^{-1})x_T(t) = B(q^{-1})D(t-1) + \varepsilon(t) \quad (6.4.2)$$

A lei de controle que minimiza a variância do erro entre o valor predito para um intervalo de amostragem a frente e o valor real da variável controlada é dada pela Equação 4.3.8 (Capítulo 4).

Utilizando-se:

$$P(q^{-1}) = \frac{P_N(q^{-1})}{P_d(q^{-1})} \quad (6.4.3)$$

e

$$\hat{C} \cdot \hat{\phi}_y^*(t+k) = \hat{F}y_f(t) + \hat{G}u(t) \quad (6.4.4)$$

e adotando-se:  $P = R = 1$  e  $Q = \lambda(1-q^{-1})$ . Como  $P = 1$ , então  $y_f = y$ , e

$$C = AE + z^{-k}F \quad (6.4.5)$$

Os graus dos polinômios F e E são dados por:

$$\text{grau de F : 1} \quad F = f_o + f_1 q^{-1}$$

$$\text{grau de E : 0} \quad E = 1 \quad \text{com } C(q^{-1}) = 1$$

Chega-se a seguinte lei de controle:

$$D(t) = \frac{1}{\lambda} \left[ x_{TSP} + a_1 x_T(t) + a_2 x_T(t-1) - (b_o - \lambda) D(t-1) - b_1 D(t-2) - b_2 D(t-3) \right] \quad (6.4.6)$$

onde os coeficientes  $a_1$ ,  $a_2$ ,  $b_o$ ,  $b_1$ ,  $b_2$  são estimados em linha por um estimador de parâmetros (Equações 3.3.25 a 3.3.27 do Capítulo 3).

Uma outra alternativa para se derivar a lei de controle adaptativa é definir uma função auxiliar  $\phi$ , na forma:

$$\phi(t) = x_{TSP} - x_T(t+1) + qD(t) - qD(t-1) \quad (6.4.7)$$

que é análoga à Equação 5.4.18 (Capítulo 5). Fazendo  $\phi(t) = 0$  (ver item 5.4.4, do Capítulo 5), tem-se a seguinte lei de controle:

$$D(t) = \frac{1}{q} \left[ x_T(t+1) - x_{TSP} + qD(t-1) \right] \quad (6.4.8)$$

Na lei de controle acima percebe-se que se a composição predita para o próximo intervalo de amostragem  $[x_T(t+1)]$  for maior que o valor desejado  $[x_{TSP}]$ , a vazão de destilado retirado aumenta; se  $x_T(t+1)$  for menor que o valor desejado  $[x_{TSP}]$ , a vazão de destilado retirado diminui, o que é coerente com o sistema físico.

O valor da vazão de destilado máxima e mínima estão relacionados com a razão de refluxo máxima e mínima permitidas. Adotou-se os seguintes valores para esta variável:

- razão de refluxo máxima: 5;
- razão de refluxo mínima: 0,5;

que correspondem aos valores que na prática são passíveis de serem utilizados.

### 6.5 - Resultados e Discussão

A coluna simulada possui as características apresentadas na Tabela 6.1.

Tabela 6.1 - Parâmetros da coluna de destilação em batelada simulada.

Vazão de vapor	100 moles/h
Número de componentes	3
Número de pratos	20
<i>Holdup</i> dos pratos	1 mol
<i>Holdup</i> do condensador	10 moles
Carga inicial alimentada	400 moles
Pressão de operação	1 atm
Composição inicial da carga	Componente 1: 0,3 Componente 2: 0,3 Componente 3: 0,4
Volatilidade relativa	9, 3, 1

O intervalo de amostragem utilizado foi de 5 min em todas as simulações apresentadas. O controlador PID digital com algoritmo na forma da velocidade empregado foi sintonizado por tentativa e erro devido ao fato da grande dificuldade da utilização das técnicas convencionais de sintonia (Ziegler-Nichols e Cohen-Coon) para o caso da destilação em batelada. As constantes utilizadas foram:  $K_c = 150$ ;  $\tau_D = 10$ ;  $\tau_I = 5$ ; O *set point* adotado foi a composição do componente 1 no destilado. A

coluna é operada a refluxo constante até que a composição deste componente atinja 0,9 e então começa-se a retirar o destilado a uma vazão dada pelo sistema de controle.

As Figuras 6.3 a 6.8 mostram o desempenho do controlador PID digital (Anexo II).

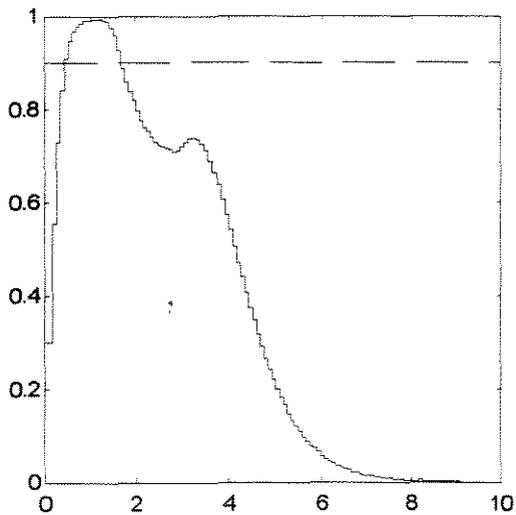


Figura 6.3 - Fração molar instantânea do componente 1 no destilado  $x$  tempo de batelada (h). Controle PID

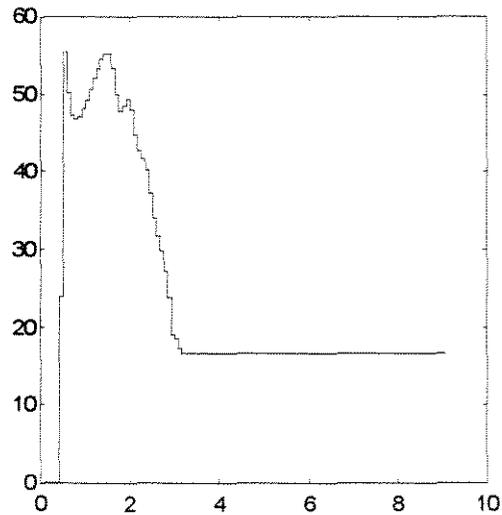


Figura 6.4 - Vazão de destilado (mol/h)  $x$  tempo de batelada (h). Controle PID

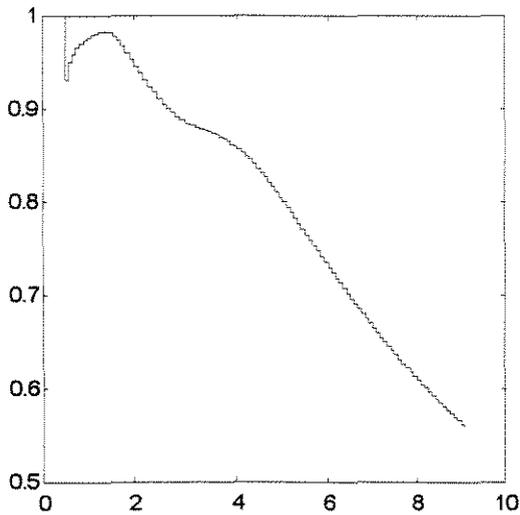


Figura 6.5 - Composição acumulada do componente 1 no destilado x tempo de batelada (h). Controle PID

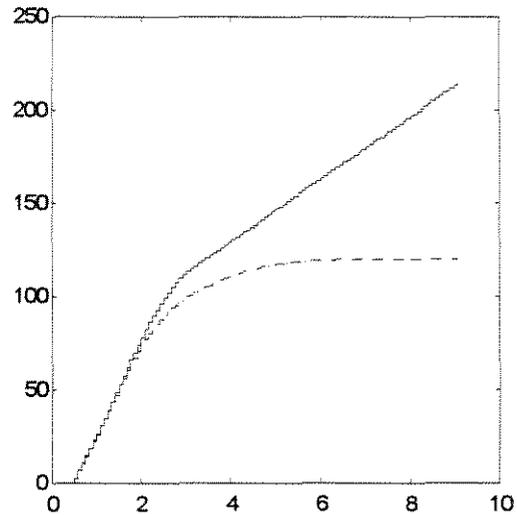


Figura 6.6 - Quantidade total de destilado (—) e componente 1 recuperado (---) (mol) x tempo de batelada (h). Controle PID

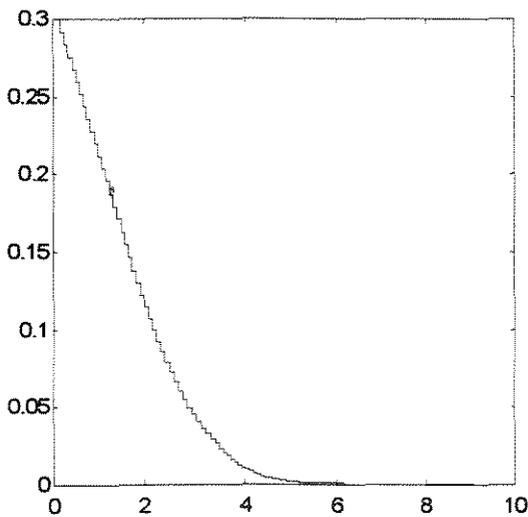


Figura 6.7 - Fração molar do componente 1 no refeedor x tempo de batelada (h). Controle PID

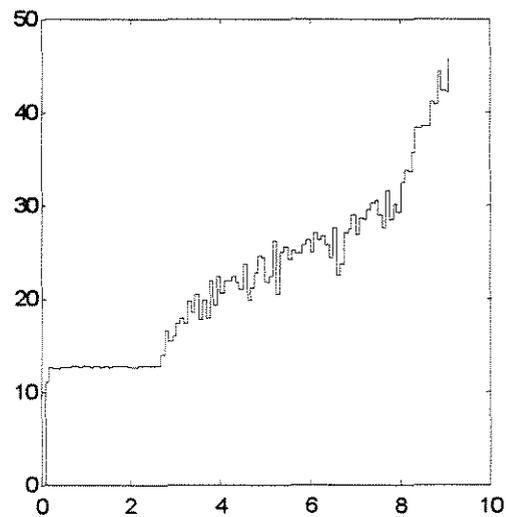


Figura 6.8 - Tempo de CPU gasto em cada intervalo de amostragem (s) x tempo de batelada (h). PC 486, 66 Mz. Volatilidade relativa constante. Controle PID.

As Figuras 6.9 a 6.13 mostram o desempenho do controlador adaptativo SRT implementado utilizando a lei de controle descrita pela Equação 6.4.8. O fator de esquecimento do estimador de parâmetros utilizado foi 0,97; a matriz covariância inicial  $P_0 = \text{diag} \{100 \ 100 \ 100 \ 100 \ 100 \ 100\}$ ;  $q = 0,05$ ; As Figuras 6.14 a 6.17 mostram o desempenho do controlador adaptativo SRT implementado

utilizando a lei de controle dada pela Equação 6.4.6. Os parâmetros são os mesmos do caso anterior, com  $\lambda = 0,05$ .

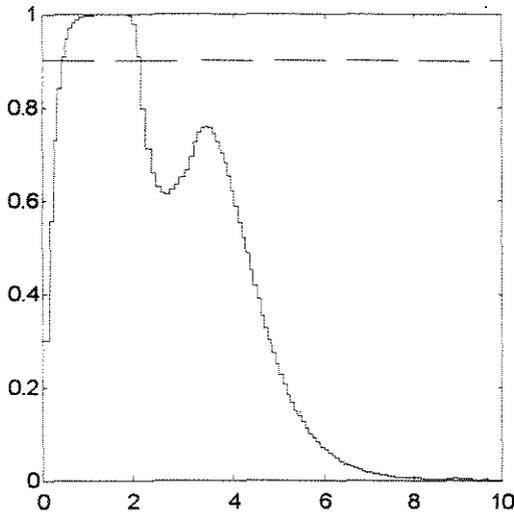


Figura 6.9 - Fração molar instantânea do componente 1 no destilado x tempo de batelada (h). Controle STR

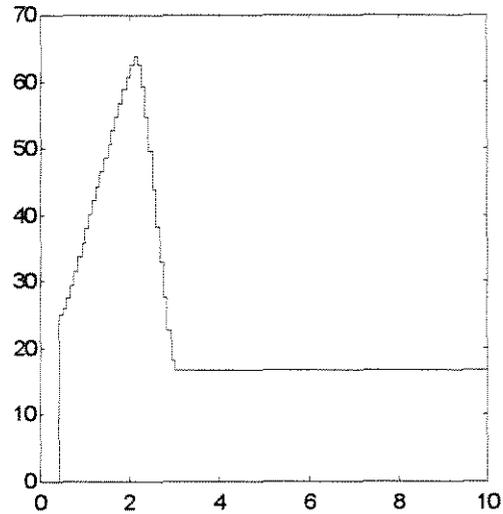


Figura 6.10 - Vazão de destilado (mol/h) x tempo de batelada (h). Controle STR

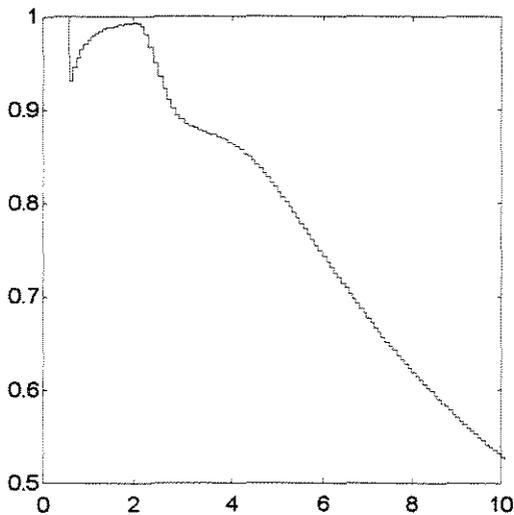


Figura 6.11 - Composição acumulada do componente 1 no destilado x tempo de batelada (h). Controle STR

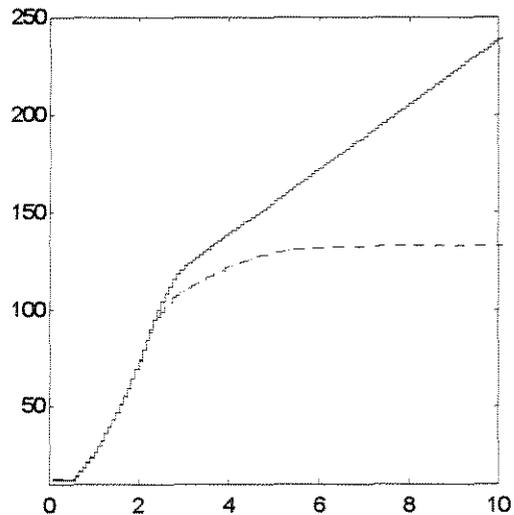


Figura 6.12 - Quantidade total de destilado (—) e de benzeno destilado (----) (mol) x tempo de batelada (h). Controle STR

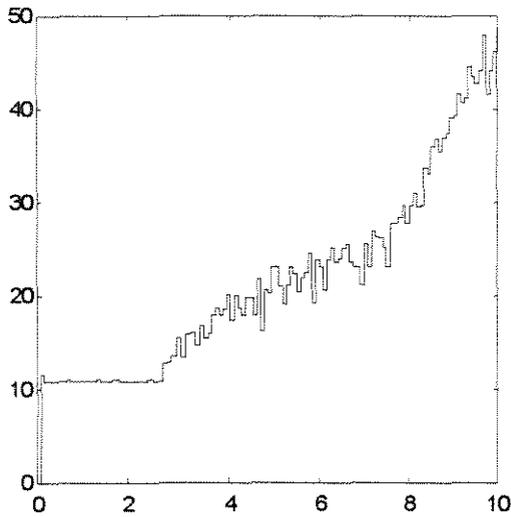


Figura 6.13 - Tempo de CPU gasto em cada intervalo de amostragem (s) x tempo de batelada (h). PC 486, 66 Mz. Volatilidade relativa constante. Controle STR.

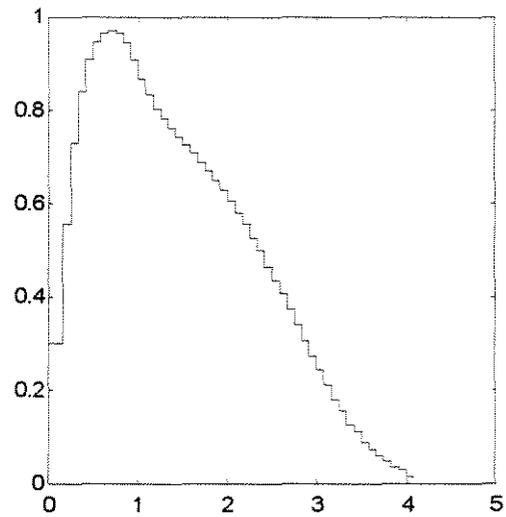


Figura 6.14 - Composição instantânea do componente 1 no destilado x tempo de batelada (h). Controle STR

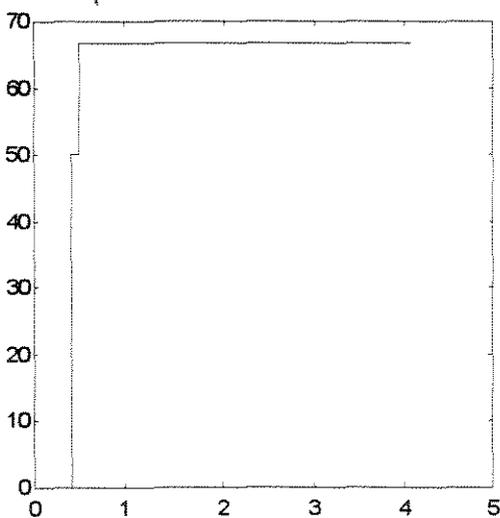


Figura 6.15 - Vazão de destilado (mol/h) x tempo de batelada (h). Controle STR

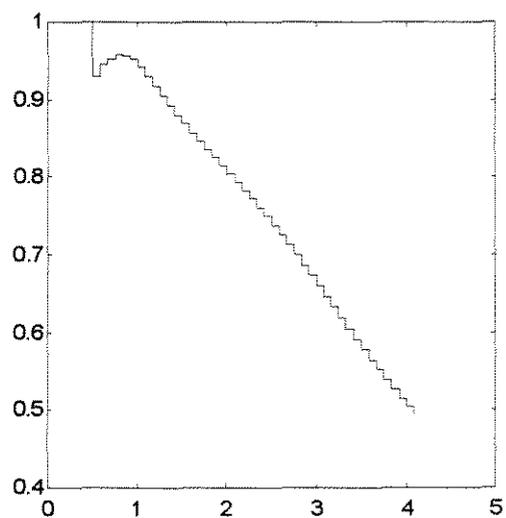


Figura 6.16 - Composição acumulada do componente 1 no destilado x tempo de batelada (h). Controle STR

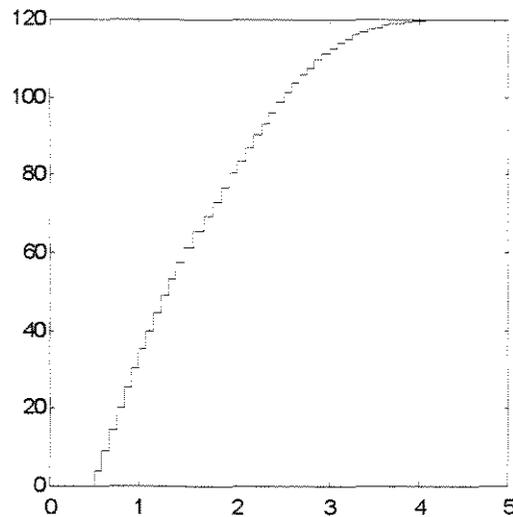


Figura 6.17 - Quantidade de componente 1 recuperada (mol) x tempo de batelada (h). Controle STR.

Uma medida quantitativa do desempenho dos controladores pode ser feita avaliando a quantidade de componente 1 recuperada como destilado a uma composição média de 0,9. A Tabela 6.3 mostra os resultados obtidos pelas simulações. Observa-se que o controlador STR dado pela Equação 6.4.8 é o que apresenta os melhores resultados pois consegue a maior quantidade de componente 1 recuperado seguido de perto pelo PID. Uma análise mais conclusiva necessita levar em consideração o tempo gasto na recuperação pois esta variável afeta o custo de produção devido aos gastos com vapor.

Tabela 6.2 - Quantidade de componente 1 recuperada como destilado a uma composição média de 90%.

Controlador	Tempo (h)	Quantidade de componente 1 recuperada com composição 0,9 (mol)
PID	2,66	95,2
STR Equação 6.4.6	1,32	54,0
STR Equação 6.4.8	2,91	104,3

Como pode ser observado na Figura 6.15, o controlador STR (Equação 6.4.6) age como se a coluna operasse a refluxo mínimo pois este permanece no valor mínimo em toda a operação, mesmo

quando a concentração do destilado cai a valores muito baixos, mostrando claramente que esta metodologia de projeto do controlador não é adequada para aplicação nesta classe de problema. O principal motivo da falha deste tipo de controlador quando aplicado à coluna de destilação em batelada é o fato de se assumir que existe uma relação linear entre a variável manipulada (vazão de destilado e a variável medida (composição do componente 1 no destilado), considerando esta longe de ser verdadeira para esta classe de processo. Isto pode ser facilmente visto analisando as equações de balanço de massa que descrevem a dinâmica da coluna.

Em geral os problemas de controle envolvem a regulação ou o supervisionamento de um processo a partir de um estado de referência que, na maioria dos casos, é o estado estacionário. O controlador parte de um valor de referência para a variável manipulada e acrescenta incrementos a este valor calculados pelo controlador a fim de manter a variável controlada no valor desejado. Para a coluna em estudo isto não acontece. Primeiro, pelo fato de que o processo não atinge o estado estacionário pois é um processo inerentemente dinâmico. Em segundo lugar, a etapa de controle geralmente é precedida de uma etapa a refluxo total na qual a concentração do produto desejado no destilado alcança o valor desejado e a partir deste momento começa a haver a retirada de produto. Esta retirada funciona como uma perturbação ao processo e acarreta alguns problemas ao sistema de controle. Se o controlador estiver programado para começar a retirar pequenas quantidades de destilado que vai aumentando com o tempo, o efeito da perturbação é minimizado, porém o tempo de batelada aumenta consideravelmente o que pode tornar a operação economicamente inviável. Por outro lado se logo no início da retirada de produto esta for realizada a uma alta taxa, a perturbação ao sistema é muito grande, dificultando a atuação do controlador.

A presença de um sistema de controle adaptativo ou PID isolado não consegue melhorar muito o desempenho de uma coluna de destilação em batelada. Necessita-se ter um nível hierarquicamente superior ao nível de controle que além da reconciliação de dados (citado anteriormente) realize uma otimização em tempo real do processo de modo a informar ao controlador o caminho que ele deve conduzir o sistema (política de operação) de modo a minimizar ou maximizar uma função objetivo requerida que, em geral, é a minimização do tempo de batelada ou a maximização do produto destilado. A otimização em tempo real de processos complexos como o em estudo não é uma tarefa trivial.

Um fator que deve ser analisado objetivando uma aplicação experimental de um sistema de controle é o tempo computacional gasto na solução do modelo. Nas simulações anteriores considerou-se volatilidade relativa constante no cálculo da composição da fase vapor a partir da suposição da existência do equilíbrio termodinâmico de fases. Esta consideração corresponde à que demanda menor tempo computacional que é função principalmente do número de pratos teóricos da coluna e do “hold up” dos pratos e condensador. Para as simulações mostradas anteriormente, o tempo computacional em cada intervalo de amostragem ficou entre 10 e 50 segundos (Figuras 6.8 e 6.13) utilizando um PC 486, 66 Mz e o *software* Matlab 4.0 e considerando um tempo de amostragem de 5 minutos.

### **6.6 - Conclusões**

Os resultados apresentados neste capítulo mostram que apesar do controlador adaptativo STR apresentar resultados mais satisfatórios quando comparado com o controlador clássico PID, a malha de controle necessita estar subordinada a um nível hierárquico superior que possui duas funções: realizar a reconciliação dos dados amostrados e prover uma política ótima de operação da coluna através do emprego de um algoritmo de otimização.

Um dos maiores obstáculos ao sucesso do controle de destilação em batelada é a dificuldade de se determinar o valor de concentração em linha e em tempo real. Várias metodologias são propostas sendo que a inferenciação desta variável a partir de dados de temperatura e pressão é uma das mais atraentes. Temperatura, pressão e concentração em uma mistura gasosa podem ser correlacionados empiricamente, termodinamicamente através da consideração da existência de equilíbrio entre as fases líquida e gasosa ou utilizando uma rede neural artificial devidamente treinada.

O controle da coluna foi implementado através de uma malha de uma entrada e uma saída na qual a variável medida é a concentração do componente mais volátil no destilado e a variável manipulada a vazão de destilado.

## CAPÍTULO VII

### CONCLUSÕES GERAIS E SUGESTÕES

#### PARA TRABALHOS FUTUROS

##### **7.1 - Conclusões**

Existe uma demanda crescente para a operação de processos químicos e correlatos com alto desempenho. Para tanto, além de um projeto adequado, a operação com controle não manual é importante. Ao projetar tais sistemas de controle, há a preocupação com o projeto de sistemas que satisfarão as especificações impostas pelos usuários sob as condições antecipadas de operação. A maioria dos sistemas de controle que exigem grande desempenho para uma grande gama de condições de operação será necessariamente adaptativa até um certo grau. Quando um alto grau de adaptabilidade é claramente requerido, a maioria das especificações atuais será obedecida por um sistema do tipo identificação-decisão-modificação com modificação sequencial ou contínua, dependendo da taxa de variação dos parâmetros envolvidos, caracterizando-se o *controle adaptativo*.

Existem basicamente três estratégias de implementação do controlador adaptativo. A primeira delas, o **controlador adaptativo com ganho programado**, que utiliza uma variável auxiliar do processo (outra que não seja a saída da planta usada na realimentação) que se correlacione bem com as mudanças dinâmicas do sistema. A segunda estratégia, o **controlador adaptativo com modelo de referência**, é um pouco mais elaborada pois as especificações do sistema de controle são dadas em termos de um modelo de referência o qual diz como a saída do processo responderia de maneira ideal ao sinal de entrada. No entanto, nenhuma das duas estratégias anteriores tem a capacidade de “aprender” novas dinâmicas não modeladas até então. Surge assim a terceira estratégia que é o **controlador adaptativo auto-ajustável**. Nessa estratégia os parâmetros do controlador são relacionados com os parâmetros da planta e quando estes não são conhecidos, podem ser estimados em tempo real utilizando um algoritmo adequado. O sistema de controle possui duas etapas fundamentais: a estimativa de parâmetros e/ou estados e o projeto do controlador, que também é realizado em tempo real.

A estimativa de parâmetros e de estados é uma etapa fundamental na formulação dos controladores adaptativos auto-ajustáveis. Além disto, o conhecimento em tempo real de todos os estados de um sistema é fundamental para o seu completo monitoramento e necessário nas estratégias de controle avançado que utilizam a técnica de realimentação desses estados. Como nem todos os estados são diretamente mensuráveis ou as medidas em tempo real são disponíveis somente com atrasos, portadoras de imprecisão, custo elevado, as técnicas de estimativa de estado constituem em uma proposta interessante na solução deste problema. Dentre as várias técnicas disponíveis para realizar essa estimativa as mais interessantes são as que utilizam um *software*, chamado de *soft sensor*. Em geral este *software* é um filtro, um observador de estado ou uma rede neural artificial.

Dentre os filtros apresentados na literatura o filtro de Kalman é o mais empregado, porém na forma original só pode ser aplicado a sistemas descritos por modelos lineares. Uma extensão deste algoritmo é o filtro de Kalman estendido que pode ser utilizado na estimativa de estados e parâmetros de modelos não lineares. O emprego desta técnica exige a definição de várias variáveis que devem ser convenientemente escolhidas para a obtenção de convergência, estabilidade, etc. No Capítulo 3 ilustrou-se com sucesso o emprego desta técnica na estimação de dois estados e parâmetros a partir da medição de dois outros estados em um processo fermentativo em batelada. Os processos fermentativos constituem-se em típicos processos nos quais a acessibilidade aos estados é difícil e portanto fortes candidatos ao emprego de técnicas de estimativa, que são úteis no controle e monitoramento destes sistemas.

Solucionado o problema da estimação/identificação a próxima etapa é o projeto do controlador que pode ser realizado obedecendo-se a vários critérios. Um dos mais comuns é a minimização da variância do erro entre a saída real e aquela predita por um modelo, o modelo de controle. Outro critério também largamente empregado e que é aplicável a modelos na forma espaço-de-estados é o controle ótimo LQG, porém restrito a sistemas lineares. Em geral, quando o sistema não é linear, faz-se uma linearização deste em torno de um ponto fixo ou móvel e então aplica-se o algoritmo LQG que envolve a solução da equação de Riccati. Existe ainda uma terceira maneira de se projetar um controlador adaptativo que é a imposição da localização dos pólos do sistema em malha fechada a uma região de estabilidade.

Objetivando testar algumas das técnicas de estimação e projeto o controle adaptativo foi aplicado a dois sistemas representativos da Engenharia Química: um processo biotecnológico com reatores em série e uma coluna de destilação em batelada. O primeiro sistema constitui-se de um processo em escala industrial com modelagem e parâmetros determinados em trabalho anterior. O segundo sistema possui uma dinâmica bem característica haja vista que o processo é inerentemente dinâmico, o que representa um enorme desafio a qualquer sistema de controle. Mostrou-se que o controle adaptativo é menos sensível a uma sintonia inadequada de seus parâmetros quando comparado com o controlador PID e que é capaz de atuar com sucesso tanto na regulação quanto no supervisionamento da variável controlada. Mostra-se que as ações de controle dos controladores adaptativos são mais suaves permitindo assim que o processo possa responder à atuação desejada. Para o segundo sistema, discute-se a necessidade da malha de controle estar subordinada a uma malha externa que realize a reconciliação dos dados amostrados e através do emprego de uma otimização em tempo real defina a política ótima de operação que permita minimizar o tempo de batelada ou maximizar a quantidade de destilado produzida, dependendo do interesse econômico.

## **7.2 - Trabalhos futuros**

Propõe-se em trabalhos futuros a investigação:

1. do desempenho de outros filtros que não sejam o filtro Kalman estendido na estimação de estados e parâmetros, principalmente os filtros adaptativos, pois são auto-sintonizáveis; a literatura apresenta uma imensa lacuna no que se refere a implementação de outros filtros a sistemas presentes na Engenharia Química;
2. da atuação do controlador adaptativo junto com algoritmos de reconciliação de dados e otimização em tempo real;
3. do desenvolvimento de um “software” para controle adaptativo aplicando os conceitos de projeto orientado a objeto;
4. do emprego de redes neurais artificiais na inferenciação de dados não mensuráveis diretamente.

# ANEXO I

## LINEARIZAÇÃO DE SISTEMAS NÃO-LINEARES UTILIZANDO SÉRIE DE TAYLOR

Suponha que um sistema não-linear seja descrito por:

$$\begin{aligned}x(t+I) &= f(x(t), u(t)) + r(x(t), u(t)).w(t) \\ y(t) &= h(x(t)) + m(x(t), u(t)).v(t)\end{aligned}\tag{I.1}$$

Definindo:

$$\begin{aligned}\Delta x(t) &= x(t) - x^*(t) \\ \Delta y(t) &= y(t) - h(x^*(t)) \\ \Delta u(t) &= u(t) - u^*(t)\end{aligned}\tag{I.2}$$

A forma linearizada do modelo descrito acima, utilizando série de Taylor truncada na primeira derivada, em torno no estado de referência  $x^*(t)$ ,  $u^*(t)$  é:

$$\begin{aligned}\Delta x(t+I) &= F(t)\Delta x(t) + G(t)\Delta u(t) + \bar{w}(t) \\ \Delta y(t) &= H(t)\Delta x(t) + \bar{v}(t)\end{aligned}\tag{I.3}$$

onde:

$$F(t) = \left. \frac{\partial}{\partial x} f(x, u) \right|_{x^*(t), u^*(t)}, \quad G(t) = \left. \frac{\partial}{\partial u} f(x, u) \right|_{x^*(t), u^*(t)}, \quad H(t) = \left. \frac{\partial}{\partial x} h(x) \right|_{x^*(t)}$$

e com  $\bar{w}(t)$ ,  $\bar{v}(t)$  ruídos brancos com covariâncias  $R_1$  e  $R_2$  respectivamente. Se os ruídos não forem independentes,  $R_{12}$  é a covariância cruzada.

O modelo linear é variante no tempo, sendo uma descrição aproximada do modelo não-linear nas proximidades da trajetória de referência.

## ANEXO II

### CONTROLADOR PID DIGITAL

Considere o processo geral mostrado na Figura II.1, com uma saída  $y$ , uma perturbação  $d$  e uma variável possível de ser manipulada  $m$ .

A ação de controle PID feedback envolve os seguintes passos:

1. Medir o valor da saída utilizando um medidor adequadamente escolhido e posicionado. Denota-se de  $y_m$  o valor indicado pelo instrumento de medida.

2. Comparar o valor medido  $y_m$  com o valor desejado  $y_{sp}$  (set point) da saída. Gera-se um erro a partir destas duas grandezas:  $\varepsilon = y_{sp} - y_m$

3. O erro é então alimentado no controlador, que por sua vez, altera o valor da variável manipulada  $m$  de tal maneira a reduzir a magnitude do valor de  $\varepsilon$ . A alteração da variável manipulada é feita através do elemento final de controle, no caso, uma válvula pneumática.

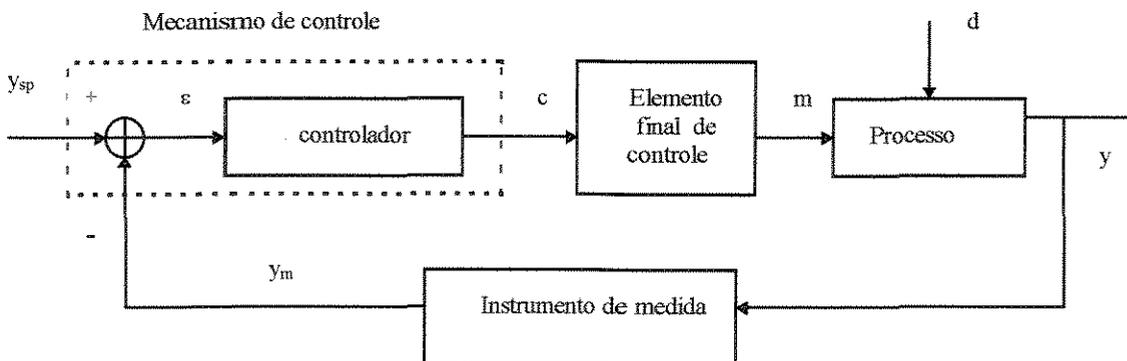


Fig. II.1 - Malha de controle feedback.

O controlador PID tem a seguinte forma:

$$u(t) = K_c \left( \varepsilon(t) + \frac{I}{\tau_i} \int_0^t \varepsilon(t) dt + \tau_D \frac{d\varepsilon}{dt} \right) \quad (\text{II.1})$$

com a atuação: a ação de controle tomada pelo controlador é proporcional ao erro, à integral do erro e à derivada do erro. Para que o controlador possa ser utilizado as constantes  $K_c$ ,  $\tau_i$  e  $\tau_D$  necessitam ser convenientemente escolhidas, isto é, o controlador necessita ser sintonizado.

A expressão anterior é a forma analógica do PID. Na forma discreta, utilizada por controladores digitais, pode ser utilizada a seguinte expressão, chamada de *forma da velocidade*:

$$\Delta u_t = u_t - u_{t-1} = K_c \left( 1 + \frac{T}{\tau_i} + \frac{\tau_D}{T} \right) \varepsilon_t - K_c \left( 1 + \frac{2\tau_D}{T} \right) \varepsilon_{t-1} + K_c \frac{\tau_D}{T} \varepsilon_{t-2} \quad (\text{II.2})$$

O algoritmo na forma da velocidade tem as seguintes vantagens, quando comparado com outras formas:

1. *não necessita de inicialização.*
2. *É protegido contra “integral windup”.*
3. *É protegido contra falhas do computador de controle.*

O controlador PID convencional tem a desvantagem, que uma vez sintonizadas suas constantes, estas ficam invariáveis podendo levar a grandes *offsets* nas variáveis de saída. No entanto, pode-se utilizar o controlador PID com constantes ajustadas em linha, sendo então um PID adaptativo.

A determinação dos valores das constantes  $K_c$ ,  $\tau_i$  e  $\tau_D$  é chamada de sintonia do controlador PID. Diversas técnicas podem ser utilizadas na determinação dessas constantes: Ziegler-Nichols, Cohen-Coon, tentativa e erro, regras heurísticas, etc. (Luyben, 1989; Stephanopoulos, 1984)

## ANEXO III

### TRABALHOS CIENTÍFICOS PUBLICADOS

#### DURANTE O PERÍODO DE TESE

##### Trabalhos Apresentados em Congressos Internacionais com Publicação em Anais

- ASSIS, A. J, MACIEL FILHO, R., “**Recursive State and Parameter Identification for Adaptive Controller Design Purpose. Application to Biotechnological Reactors**”, I International Conference on Science, Engineering and Technology of Intensive Processing, Nottingham (UK), 18th - 20th, September 1995.
- ASSIS, A. J, MACIEL FILHO, R., “**Estimativa Recursiva de Estados e Parâmetros para projeto de Controladores Adaptativos**”, XVI Congresso Ibero Latino Americano sobre Métodos Computacionais para Engenharia, Curitiba (PR), 29/11 a 01/12 de 1995.
- ASSIS, A. J, MACIEL FILHO, R., “**State Feedback Control System Design using Optimization Techniques. Application to a Continuous Fermentation Process**”, IASTED - International Conference on Modeling, Simulation and Optimization, Gold Coast, Australia, 6-9 maio/1996.

##### 6.4 - Trabalhos científicos no prelo

- ASSIS, A. J, MACIEL FILHO, R., “**Recursive State and Parameter Identification for Adaptive Controller Design Purpose. Application to Biotechnological Reactors**”, Artigo submetido à revista Inglesa *Chemical Engineering Research and Design* (em processo de revisão).
- ASSIS, A. J, MACIEL FILHO, R., “**Estratégias de Controle Adaptativo Aplicadas a um Processo Contínuo de Fermentação Alcolica**”, XI Congresso Brasileiro de Engenharia Química, Rio de Janeiro, Brasil, setembro de 1996.
- ASSIS, A. J, MACIEL FILHO, R., “**Adaptive Control of Biotechnological Reactors: On Line State and Parameter Estimation**”, International Congress of Chemical Engineering, EUA, July, 1996.

- ASSIS, A. J, DECHECHI, E. C e MACIEL FILHO, R., **“Controle Adaptativo e Preditivo (DMC) de um Processo Contínuo de Fermentação Alcólica: Comparação de Desempenho**, XI SINAFERM - Simpósio Nacional de Fermentações, 31/07 a 02/08/1996, São Carlos, SP.
- ASSIS, A. J, MACIEL FILHO, R., **“On Line Identification and Adaptive Control of Biochemical Reactors Using Kalman Filter and LQG Approach”**, CHISA’96: 12th International Congress of Chemical and Process Engineering, Praga, República Theca, 25-30 agosto de1996
- ASSIS, A. J, MACIEL FILHO, R., **”Nonlinear Model-Based Adaptive Control for Continuous Fermenters Processes with Delayed Measurements”**, CAIP’96: 3er Congreso Interamericano de Computacion Aplicada a la Industria de Procesos, Republica Argentina, Villa Maria, Cordoba, nov/1996.

## REFERÊNCIAS BIBLIOGRÁFICAS

- Allidina, A. Y e F. M. Hughes, "Self-Tuning Controller with Integral Action", *Optimal Control Applications & Methods*, vol. 3, pp. 355-362, 1982.
- Anderson, B.D.O., R.R. Bitmead, C.R. Johnson, P.V. Kokotovic, R.L. Kosut, I.M.Y. Mareels, L. Praly & B.D. Riedle, **Stability of Adaptive Systems, Passivity and Averaging Analysis**, MIT Press, Cambridge, Massachusetts, 1986. (Citado por S. Sastry e M. Bodson, 1989)
- Andrietta, S. R., *Modelagem, Simulação e Controle de Fermentação Alcoólica Contínua em Escala Industrial*, Tese de Doutorado, UNICAMP/FEA, 1994.
- Åström, K. J & B. Wittenmark, **Adaptive Control**, Addison-Wesley Publishing Company, USA, 1989.
- Åström, K. J., "Introduction", *Optimal Control Applications & Methods*, vol. 3, pp. 303-462, 1982.
- Åström, K. J. e B. Wittenmark, "On Self Tuning Regulators", *Automatica*, vol. 9, pp. 185-199, 1973.
- Åström, K. J. e B. Wittenmark, "Self-Tuning Controllers Based on Pole-Zero Placement", *IEE Proceedings*, vol. 127, D, 3, pp. 120-130, 1980.
- Åström, K. J., "Theory and Applications of Adaptive Control - A Survey", *Automatica*, vol. 19, no. 5, pp. 471-486, 1983.
- Åström, K. J., U. Borisson, L. Ljung e B. Wittenmark, "Theory and Applications of Self-Tuning Regulators", *Automatica*, vol. 13, pp. 457-476, 1977.
- Åström, K.J. & B. Wittenmark, *On Self Tuning Regulators*, *Automatica*, Vol. 9, pp. 185-199, 1973. (Citado por S. Sastry e M. Bodson, 1989)
- Åström, K. J. & B. Wittenmark, *Computer Controlled Systems*, Prentice-Hall, USA, 1984.
- Benson, R. S., "The State of Chemical Process Control: an Industrialist's View", *Chem. Eng. Res. Des.*, vol. 65, pp. 451-452, 1987.
- Boskovic, J. D. & K. Narendra, "Comparison of Linear, Nonlinear and Neural-network-based Adaptive Controllers for a Class of Fed-batch Fermentation Processes", *Automatica*, vol. 31, no. 6, pp. 817-840, 1995.
- Bowser, K. T., *Controller Design for Nonlinear Chemical Processes*", Honors Thesis, Florida State University, 1994.

- Broll, J. A. Rix e H. Gelbe, "Nonlinear Model-Based Feedforward Control of Distillation Columns", *Chem. Eng. Technol.*, vol. 18, pp. 178-182, 1995.
- Buckley, P. S., W. L. Luyben & J. P. Shunta, *Design of Distillation Column Control Systems*, Edward Arnold, USA, 1985.
- Caines, P.E., **Linear Stochastic Systems**, John Wiley, New York, 1988. (Citado por S. Sastry e M. Bodson, 1989)
- Caminal, G, J. Lafuente, J. López-Santín, M. Poch, C. Solá, "Application of Extended Kalman Filter to Identification of Enzymatic Deactivation", *Biotechnology and Bioengineering*, vol. 29, pp. 366-369, 1987.
- Cardello, R. J, K-Y. San, "The Design of Controllers for Batch Bioreactors", *Biotechnology and Bioengineering*, vol. 32, pp. 519-526, 1988.
- Carrol, T. A., W. F. Ramirez, "On-Line State and Parameter Identification of Positive Photoresist Development", *AIChE Journal*, vol. 36, no. 7, pp. 1046-1053, 1990.
- Chattaway, T. e G. Stephanopoulos, "Adaptive Estimation of Bioreactors: Monitoring Plasmid Instability", *Chemical Engineering Science*, vol. 44, no. 1, pp. 41-48, 1989.
- Chen, C-Y. e C-C. Sun, "Adaptive Inferential Control of Packed-Bed Reactors", *Chemical Engineering Science*, vol. 46, no. 4, pp. 1041-1054, 1991.
- Chen, L, G. Bastin & V. Breusegem, "A Case Study of Adaptive Nonlinear Regulation of Fed-batch Biological Reactors", *Automatica*, vol. 31, no. 1, pp. 55-65, 1995.
- Cheng, Y, T. W. Karjala, D. M. Himmelblau, "Identification of Nonlinear Dynamic Process with Unknown and Variable Dead Time Using an Internal Neural Network", *Ind. Eng. Chem. Res.*, vol. 34, pp. 1735-1742, 1995.
- Chien, I-L., D. E. Seborg, D. A. Mellichamp, "Self-Tuning Control with Decoupling", *AIChE Journal*, vol. 33, no. 7, pp. 1079-1088, 1987.
- Choi, K-Y., A. A. Khan, "Optimal State Estimation in the Transesterification Stage of a Continuous Polyethylene Terephthalate Condensation Polymerization Process", *Chemical Engineering Science*, vol. 43, no. 4, pp. 749-762, 1988.
- Chou, Y-S e W. Wu, "Robust Control Synthesis for Uncertain Nonlinear Time-Varying Systems with Time Delays", *Proceedings of the American Control Conference*, Seattle, Washington, june 1995.
- Clarke, D. W., "Model Following and Pole-Placement Self-Tuners", *Optimal Control Applications & Methods*, vol. 3, pp. 323-335, 1982.

- Clarke, D. W., D. Phil e P. J. Gawthrop, "Self-Tuning Controller", *Proceedings of the IEE*, vol. 122, no. 9, pp. 929-934, 1975.
- Dahlqvist, S. A., "Control of a Distillation Column using Self-Tuning Regulators", *The Canadian Journal of Chemical Engineering*, vol. 59, pp. 118-127, 1981.
- Defaye, G., N. Regnier, J. Chabanon, L. Caralp e C. Vidal, "Adaptive-Predictive Temperature Control of Semi-Batch Reactors", *Chemical Engineering Science*, vol. 48, no. 19, pp. 3373-3382, 1993.
- Desai, P e A. K. Mahalanabis, "A State Space Self-Tuning Controller with Integral Action", *Optimal Control Applications & Methods*, vol. 13, pp. 301-319, 1992.
- Dimitratos, J., C. Georgakis, M. El-Aasser e A. Klein, "An Experimental Study of Adaptive Kalman Filtering in Emulsion Copolymerization", *Chemical Engineering Science*, vol. 46, no. 12, pp. 3203-3218, 1991.
- Diwekar, U. M., R. K. Malik & K. P. Madhavan, "Optimal Reflux Rate Policy Determination for Multicomponent Batch Distillation Columns", *Computers Chem. Engng*, vol. 11, no. 6, pp. 629-637, 1987.
- Dochain, D., "Adaptive Control Algorithms for Nonminimum Phase Nonlinear Bioreactors", *Computers Chem. Engng*, vol. 16, no. 5, pp. 449-462, 1992.
- Egardt, B., **Stability of Adaptive Controllers**, Springer Verlag, New York, 1979. (Citado por S. Sastry e M. Bodson, 1989)
- Eliçabe, G. E., E. Ozdeger, C. Georgakis, C. Cordeiro, "On-Line Estimation of Reaction Rates in Semicontinuous Reactors", *Ind. Eng. Chem. Res*, vol. 34, pp. 1219-1227, 1995.
- Elliott, H, W. A. Wolovich e Manohar Das, "Arbitrary Adaptive Pole Placement for Linear Multivariable Systems", *IEEE Transactions on Automatic Control*, AC-29, 3, pp. 221-228, 1984.
- Engasser, J. M., I. Marc, M. Moll & B. Duteurtre, *EBC Congress*, 579-583, 1981 (citado por Ramirez, 1987).
- Eykhoff, P., **System Identification**, Wiley & Sons, New York, 1974. (Citado por S. Sastry e M. Bodson, 1989)
- Fan, L. T., P. S. Shah, N. C. Pereira & L. E. Erickson, "Dynamic Analysis and Optimal Feedback Control Synthesis Applied to Biological Waste Treatment", *Water Research*, vol. 7, pp. 1609-1641, 1973.

- Fileti, A. M. F., *Controle em Destilação Batelada: Controle Adaptativo e Controle Preditivo com Modelo Baseado em Redes Neurais Artificiais*, Tese de Doutorado, UNICAMP/FEQ, 1995.
- Fuchs, J-J. J., "Adaptive Control and Optimal Input Design: A Realistic Approach", *Optimal Control Applications & Methods*, vol. 3, pp. 415-421, 1982.
- Gallegos, J. A & J. A. Gallegos, "Estimation and Control Techniques for Continuous Culture Fermentation Processes", *Biotechnology and Bioengineering*, vol. 26, pp. 442-451, 1984.
- Gawthrop, P. J., "A Continuous-Time Approach to Discrete-Time Self-Tuning Control", *Optimal Control Applications & Methods*, vol. 3, pp. 399-414, 1982.
- Gee, D. A. & W. F. Ramirez, "Optimal Temperature Control for Batch Beer Fermentation", *Biotechnology and Bioengineering* (citado por Ramirez, 1987).
- Goodwin, G. C, B. Mcinnis e R. S. Long, "Adaptive Control Algorithms for Waste Water Treatment and pH Neutralization", *Optimal Control Applications & Methods*, vol. 3, pp. 443-459, 1982.
- Goodwin, G.C., & K. S. Sin, **Adaptive Filtering Prediction and Control**, Prentice-Hall, Englewood Cliffs, New Jersey, 1984.
- Goodwin, G.C., & R.L. Payne, **Dynamic System Identification**, Academic Press, New York, 1977. (Citado por S. Sastry e M. Bodson, 1989)
- Goodwin, G.C., P.J. Ramadge & P.E. Caines, *Discrete-Time Multivariable Adaptive Control*, **IEEE Trans. On Automatic Control**, Vol. AC-25, no. 3, pp. 449-456, 1980. (Citado por S. Sastry e M. Bodson, 1989)
- Gudi, R. D, S. L. Shah, M. R. Gray, "Multirate State and Parameter Estimation in an Antibiotic Fermentation with Delayed Measurements", *Biotechnology and Bioengineering*, 1994, 44, 1271-1278.
- Gupta, A e R. R. Rhinehart, "Experimental Comparison of Advanced Control Techniques on a Lab-Scale Distillation Column", *Proceedings of the American Control Conference*, Seattle, Washington, June 1995.
- Harris, C.J., & S.A. Billings, **Self Tuning and Adaptive Control: Theory and Applications**, Peter Peregrinus, London, 1981. (Citado por S. Sastry e M. Bodson, 1989)
- Henson, M. A. e D. E. Seborg, "Nonlinear Control Strategies for Continuous Fermenters" *Chemical Engineering Science*, vol. 47, no. 4, pp. 821-835, 1992.
- Henson, M. A., D. E. Seborg, "Input-Output Linearization of General Nonlinear Processes", *AIChE Journal*, vol. 36, no. 11, pp. 1753-1757, 1990.

- Hinde Jr, R. F. e D. J. Cooper, "A Pattern-Based Approach to Excitation Diagnostics for Adaptive Process Control", *Chemical Engineering Science*, vol. 49, no. 9, 1403-1415, 1994.
- Ioannou, P.A. & P.V. Kokotovic, **Adaptive Systems with Reduced Models**, Springer Verlag, New York, 1983. (Citado por S. Sastry e M. Bodson, 1989)
- Isermann, R., *Digital Control Systems*, volume 2, 2a. Ed., Springer-Verlag, Berlin, 1989.
- Isermann, R., "Parameter Adaptive Control Algorithms - A Tutorial", *Automatica*, vol. 18, no. 5, pp. 513-528, 1982.
- Isermann, R., Lachmann, K. H: Parameter adaptive control with configuration aids and supervision functions. *Automatica*, vol. 21, pp. 625-638, 1985.
- Johnson, A., "LQG Applications in the Process Industries", *Chemical Engineering Science*, vol. 48, no. 16, pp. 2829-2836, 1993.
- Jonsson, G., O. P. Palsson, "An Application of Extended Kalman Filtering to Heat Exchanger Models", *Journal of Dynamic Systems, Measurement, and Control, Transactions of the ASME*, vol. 116, pp. 257-264, 1994.
- Kalman, R.E., *Design of Self-Optimizing Control Systems*, **Trans. ASME**, Vol. 80, pp. 468-478, 1958. (Citado por S. Sastry e M. Bodson, 1989)
- Kapoor, N e P. Daoutidis, "Stabilization of Unstable Systems with Input Constraints", *Proceedings of the American Control Conference*, Seattle, Washington, June 1995.
- Karjala, T. W e D. H. Himmelblau, "Dynamic Data Rectification by Recurrent Neural Networks vs. Traditional Methods", *AIChE Journal*, vol. 40, no. 11, pp. 1865-1875, 1994.
- Katende, E. e A. Jutan, "A New Constrained Self-Tuning PID Controller", *The Canadian Journal of Chemical Engineering*, vol. 71, pp. 625-633, 1993.
- Kozub, D. J, J. F. MacGregor, "State Estimation for Semi-Batch Polymerization Reactors", *Chemical Engineering Science*, vol. 47, no. 5, pp. 1047-1062, 1992.
- Kravaris, C & J. C. Kantor, "Geometric Methods for Nonlinear Process Control. 1. Background", *Ind. Eng. Chem. Res.*, vol. 29, n. 12, pp. 2295-2310, 1990.
- Kravaris, C & J. C. Kantor, "Geometric Methods for Nonlinear Process Control. 1. Controller Synthesis", *Ind. Eng. Chem. Res.*, vol. 29, n.12, pp. 2310-2323, 1990.
- Kumar, P. R., & P.P. Varaiya, **Stochastic Systems: Estimation, Identification and Adaptive Control**, Prentice Hall, Englewood Cliffs, New Jersey, 1986. (Citado por S. Sastry e M. Bodson, 1989)

- Landau, Y. D., **Adaptive Control - The Model Reference Approach**, Marcel Dekker, New York, 1979. (Citado por S. Sastry e M. Bodson, 1989)
- Lang, P., H. Yatim, P. Moszkowicz & M. Otterbein, "Batch Extractive Distillation Under Constant Reflux Ratio", *Computers Chem. Engng*, vol. 18, no. 11/12, pp. 1057-1069, 1994.
- Lee, S. C., Y. B. Hwang, H. N. Chang, Y. K. Chang, "Adaptive Control of Dissolved Oxygen Concentration in a Bioreactor", *Biotechnology and Bioengineering*, vol. 37, pp. 597-607, 1991.
- Limqueco, L., J. C. Kantor e S. Harvey, "Nonlinear Adaptive Observation of an Exothermic Stirred-Tank Reactor", *Chemical Engineering Science*, vol. 46, no. 3, pp. 797-805, 1991.
- Ljung, L., "Asymptotic Behavior of the Extended Kalman Filter as a Parameter Estimator for Linear Systems", *IEEE Transactions on Automatic Control*, AC - 24, 1, pp. 36-50, 1979.
- Ljung, L., & T. Soderstrom, **Theory and Practice of Recursive Identification**, MIT Press, Cambridge, Massachusetts, 1983.
- Ljung, L., **System Identification: Theory for the User**, Prentice-Hall, Englewood Cliffs, New Jersey, 1987.
- Lueke, R. H. Et al., "Dynamic Matrix Control of a Batch Distillation Column", *Proc. Am. Control Conf.*, Boston, 209, 1985.
- Luyben, W. L., *Process Modeling, Simulation and Control for Chemical Engineers*, 2nd. ed., McGraw-Hill, Singapore, 1990.
- Lynch, E. e W. R. Ramirez, "Real-Time Time-Optimal Control of a Stirred-Tank Reactor Using Kalman Filtering for State Estimation", *AIChE Journal*, vol. 21, no. 4, pp. 799-804, 1975.
- Maciel Filho, R., *Modelling and Control of Multitubular Fixed Bed Reactors*, Ph. D. thesis, , University of Leeds, Leeds, England, UK, 1989.
- Mäkilä, P. M., "Self-Tuning Control with Linear Input Constraints", *Optimal Control Applications & Methods*, vol. 3, pp. 337-353, 1982.
- Marchetti, J. L., D. A. Mellichamp e Dale E. Seborg, "Predictive Control Based on Discrete Convolution Models", *Ind. Eng. Chem. Process. Des. Dev.*, vol. 22, pp. 488-495, 1983.
- McDermott, P. E., D. A. Mellichamp e R. G. Rinker, "Pole-Placement Self-Tuning Control of a Fixed-Bed Autothermal Reactor. Part I: Single Variable Control", *AIChE Journal*, vol. 32, no. 6, pp. 1004-1014, 1986.

- McDermott, P. E., D. A. Mellichamp e R. G. Rinker, "Pole-Placement Self-Tuning Control of a Fixed-Bed Autothermal Reactor. Part I: Multivariable Control", *AIChE Journal*, vol. 32, no. 6, pp. 1015-1024, 1986.
- Megan, L. E D. J. Cooper, "A Neural Network Strategy for Disturbance Pattern Classification and Adaptive Multivariable Control", *Computers Chem. Engng*, vol. 19, no. 2, pp. 171-186, 1995.
- Molle, D. T. D e D. M. Himmelblau, "Fault Detection in a Single-Stage Evaporator via Parameter Estimation Using the Kalman Filter", *Ind. Eng. Chem. Res.*, vol. 26, no. 12, pp. 2482-2489, 1987,.
- Monbouquette, H. G., "Modeling High-biomass-density Cell Recycle Fermentators", *Biotechnology and Bioengineering*, vol. 39, pp. 1075-80, 1987 (Citado por *Andrietta, 1994*).
- Morari, M., "Robust Process Control", *Chem. Eng. Res. Des.*, vol. 65, pp. 462-479, 1987.
- Morris, A. J., Y. Nazer e R. K. Wood, "Multivariate Self-Tuning Process Control", *Optimal Control Applications & Methods*, vol. 3, pp. 363-387, 1982.
- Morse, A.S., *Global Stability of Parameter-Adaptive Control Systems*, **IEEE Trans. On Automatic Control**, Vol. AC-25, no. 3, pp. 433-439, 1980. (Citado por *S. Sastry e M. Bodson, 1989*)
- Najim, K., M. Najim e H. Youlal, "Self-Tuning Control of an Industrial Phosphate Dry Process", *Optimal Control Applications & Methods*, vol. 3, pp. 435-442, 1982.
- Narendra, K. S., & R.V. Monopoli (Eds.), **Applications of Adaptive Control**, Academic Press, New York, 1980. (Citado por *S. Sastry e M. Bodson, 1989*)
- Narendra, K.S., Y.-H. Lin, & L.S. Valavani, *Stable Adaptive Controller Design*, **IEEE Trans. On Automatic Control**, Vol. AC-25, no. 3, pp. 440-448, 1980. (Citado por *S. Sastry e M. Bodson, 1989*)
- Ogata, Katsuhiko, *Engenharia de Controle Moderno*, 2a. Ed, Prentice/Hall do Brasil, Rio de Janeiro, 1993.
- Paolini, E., J. A. Romagnoli, A. C. Desages e A. Palazoglu, "Approximate Models for Control of Nonlinear Systems", *Chemical Engineering Science*, vol. 47, no. 5, pp. 1161-1171, 1992
- Parks, P.C., *Lyapunov Redesign of Model Reference Adaptive Control Systems*, , **IEEE Trans. On Automatic Control**, Vol. AC-11, no. 3, pp. 362-367, 1966. (Citado por *S. Sastry e M. Bodson, 1989*)

- Pérez-Correa, J. R. e L. S. Kershenbaum, "State-Space Formulation of Multivariable Self-Tuning Controllers", *Chem. Eng. Res. Des.*, vol. 67, pp. 578-588, 1989.
- Polderman, J. W., **Adaptive Control & Identification: Conflict or Conflux?**, Ph.D. dissertation, University of Groningen, Groningen, The Netherlands, 1988. (Citado por S. Sastry e M. Bodson, 1989)
- Polihronakis, M, L. Petrou, A. Deligiannis, "Parameter Adaptive Control Techniques for Anaerobic Digesters - Real-Life Experiments", *Computers Chem. Engng*, vol. 17, no. 12, pp. 1167-1179, 1993.
- Pons, M. N., A. Rajab, J. M. Flaus, J. M. Engasser, A. Cheruy, "Comparison of Estimation Methods for Biotechnological Processes", *Chemical Engineering Science*, vol. 43, no. 8, pp. 1909-1914, 1988.
- Quintero-Marmol, E & William L. Luyben, "Inferential Model-Based Control of Multicomponent Batch Distillation", *Chemical Engineering Science*, vol. 47, no. 4, pp. 887-898, 1992.
- Ramamurthi, Y., P. B. Sistu e W. Bequette, "Control-Relevant Dynamic Data Reconciliation and Parameter Estimation", *Computers Chem. Engng*, vol. 17, no. 1, pp. 41-59, 1993.
- Ramirez, W. F e D. A. Gee, "Optimal Temperature Control of Jacket-Cooled Fermentation Reactors", *Optimal Control Applications & Methods*, vol. 12, pp. 49-62, 1991.
- Ramirez, W. F., "Optimal State and Parameter Identification. An Application to Batch Fermentation", *Chemical Engineering Science*, vol. 42, no. 11, pp. 2749-2756, 1987.
- Reuter, E., G. Wozny & L. Jeromin, "Modeling of Multicomponent Batch Distillation Process with Chemical Reaction and their Control Systems", *Computers Chem. Engng*, vol. 13, no. 4/5, pp. 499-510, 1989.
- Robinson, E. R., "The Optimisation of Batch Distillation Operations", *Chemical Engineering Science*, vol. 24, pp. 1661-1668, 1969.
- Robinson, E. R., "The Optimal Control of an Industrial Batch Distillation Column", *Chemical Engineering Science*, vol. 25, pp. 921-928, 1970.
- Robinson, E. R., *Microcomputers in the Process Industry*, Halsted Press, England, 1985.
- Rodrigues, M. I., Andrietta, S. R & Maugeri, F., "Simulação da Produtividade e Rendimento em Fermentação Alcoólica Contínua, para Reatores Operando em Condições Ideais e não Ideais de Mistura", *Stab. Açúcar e Alcool e Subprodutos*, vol. 10, no. 5, pp. 35-41, 1992 (Citado por Andrietta, 1994).

- Rohani, S., J. R. Bourne, "Self-Tuning Control of Crystal Size Distribution in a Cooling Batch Crystallizer", *Chemical Engineering Science*, vol. 45, no. 12, pp. 3457-3466, 1990.
- Rohrs, C.E., L. Valavani, M. Athans & G. Stein, *Robustness of Continuous-Time Adaptive Control Algorithms in the Presence of Unmodeled Dynamics*, Proc. Of the 21st IEEE Conference on Decision and Control, Florida, pp. 3-11, 1982. (Citado por S. Sastry e M. Bodson, 1989)
- Roux, G, B. Dahhou, K. Najim, I. Queinnec, "Adaptive Linear Quadratic Gaussian (LQG) Control of a Bioreactor", *J. Chem. Tech. Biotechnol.*, vol. 53, pp. 133-141, 1992.
- Russel, L. W. e J. D. Perkins, "Towards a Method for Diagnosis of Controllability and Operability Problems in Chemical Plants", *Chem. Eng. Res. Des.*, vol. 65, pp. 453-461, 1987.
- Sakai, H., "Generalized Predictive Self-Tuning Control for Tracking a Periodic Reference Signal", *Optimal Control Applications & Methods*, vol. 13, pp. 321-333, 1992.
- Samson, C., "Discrete Model Reference Adaptive Control of Non-Minimum Phase Systems", *Optimal Control Applications & Methods*, vol. 3, pp. 389-397, 1982.
- San, K. Y. e Stephanopoulos, G., "A Note on the Optimality Criteria for Maximum Biomass Production in a Fed-Batch Fermentor", *Biotechnology and Bioengineering*, vol. 26, pp. 1261-1264, 1984.
- Sargantanis, J. G e M. N. Karim, "Multivariable Iterative Extended Kalman Filter Based Adaptive Control: Case Study of Solid Substrate Fermentation", *Ind. Eng. Chem. Res.*, vol. 33, pp. 878-888, 1994.
- Sastry, S. E., Bodson, M; "Adaptive Control - Stability, Convergence, and Robustness", Prentice-Hall, New Jersey, USA, 1989.
- Sastry, V. A., D. E. Seborg & R. K. Wood, "Self-Tuning Regulator Applied to a Binary Distillation Column", *Automatica*, vol. 13, pp. 417-424, 1977.
- Schuler, H., C-U. Schmidt, "Calorimetric-State Estimators for Chemical Reactor Diagnosis and Control: Review of Methods and Applications", *Chemical Engineering Science*, vol. 47, no. 4, pp. 899-915, 1992.
- Schuman, R., Lachmann, K. H.; Isermann, R., "Towards Applicability of parameter adaptive control algorithms", *Proc. 8th IFAC-Congress*, Kyoto 1981, Oxford: Pergamon Press.
- Seborg, D. E., T. F. Edgar, S. L. Shah, "Adaptive Control Strategies for Process Control: A Survey", *AIChE Journal*, vol. 32, no. 6, pp. 881-913, 1986.

- Shah, S. L. E W. R. Cluett, "Recursive Least Squares Based Estimation Schemes for Self-Tuning Control", *The Canadian Journal of Chemical Engineering*, vol. 69, pp. 89-96, 1991.
- Shen, S-H. e C-C. Yu, "Use of Relay-Feedback Test for Automatic Tuning of Multivariable Systems", *AIChE Journal*, vol. 40, no. 4, pp. 627-646, 1994.
- Shi, Y, W-K. Yuan, "Application of Adaptive Estimation in Microbial Fermentation Processes", *Chemical Engineering Science*, vol. 43, no. 8, pp. 1915-1920, 1988.
- Shimizu, K., "An Overview on the Control System Design of Bioreactors", *Advances in Biochemical Engineering/Biotechnology*, vol. 50, pp. 65-84, 1993.
- Solbrand, G, A. Ahlén & L. Ljung, "Recursive Methods for Off-line Identification", *Int. J. Control*, vol. 41, no. 1, pp. 177-191, 1985.
- Sorensen, J. P., S. B. Jorgensen e K. Clement, "Fixed-Bed Reactor Kalman Filtering and Optimal Control - I. Computational Comparison of Discrete vs. Continuous Time Formulation", *Chemical Engineering Science*, vol. 35, pp. 1223-1230, 1980.
- Sorensen, J. P., S. B. Jorgensen e K. Clement, "Fixed-Bed Reactor Kalman Filtering and Optimal Control - II. Experimental Investigation of Discrete Time Case with Stochastic Disturbances", *Chemical Engineering Science*, vol. 35, pp. 1231-1236, 1980.
- Stephanopoulos, G., *Chemical Process Control*, Prentice-Hall, USA, 1984.
- Stephanopoulos, G. e Ka-Yiu San, "Studies on On-Line Bioreactor Identification. I. Theory", *Biotechnology and Bioengineering*, vol. 26, pp. 1176-1188, 1984.
- Stephanopoulos, G. e Ka-Yiu San, "Studies on On-Line Bioreactor Identification. II. Numerical and Experimental Results", *Biotechnology and Bioengineering*, vol. 26, pp. 1189-1197, 1984.
- Stephanopoulos, G. e Ka-Yiu San, "Studies on On-Line Bioreactor Identification. III. Sensitivity Problems with Respiratory and Heat Evolution Measurements", *Biotechnology and Bioengineering*, vol. 26, pp. 1198-1208, 1984.
- Stephanopoulos, G. e Ka-Yiu San, "Studies on On-Line Bioreactor Identification. IV. Utilization of pH Measurements for Product Estimation", *Biotechnology and Bioengineering*, vol. 26, pp. 1209-1218, 1984.
- Strmcnik, S & F. Bremsak, "An Efficient Algorithm for the Transformation of the Input-Output Model into the State-Space Model", *Int. J. Control*, vol. 41, no. 1, pp. 145-154, 1985.
- Teixeira, E. P., *Controle de Sistemas Não Lineares Através de Redes Neurais*, Tese de Doutorado, UNICAMP/FEE, 1991.

- Terwiesch, P. e M. Agarwal, "A Discretized Nonlinear State Estimator for Batch Processes", *Computers Chem. Engng*, vol. 19, no. 2, pp. 155-169, 1995.
- Tham, M. T., F. Vagi, A. J. Morris e R. K. Wood, "On-Line Multivariable Adaptive Control of a Binary Distillation Column", *The Canadian Journal of Chemical Engineering*, vol. 69, pp. 997-1009, 1991.
- Tham, M. T., A. J. Morris e G. A. Montague, "Soft-Sensing: A Solution to the Problem of Measurement Delays", *Chem. Eng. Res. Des.*, vol. 67, pp. 547-554, 1989.
- Tuffs, P. S., "Software Aspects of Self-Tuning Control", *in Implementation of Self-Tuning Controllers*, Editado por Kevin Warwick, Peter Peregrinus, Londres, UK, 1988.
- Tzouanas, V. K. e S. L. Shah, "Adaptive Pole-Assignment Control of a Batch Polymerization Reactor", *Chemical Engineering Science*, vol. 44, no. 5, pp. 1183-1193, 1989.
- Unbehauen, H. (Ed.), *Methods and Applications in Adaptive Control*, Springer Verlag, Berlin, 1980. (Citado por S. Sastry e M. Bodson, 1989)
- Villermaux, J., "Future Challenges for Basic Research in Chemical Engineering", *Chemical Engineering Science*, vol. 48, no. 14, pp. 2525-2535, 1993.
- Vu, K. M., "Optimal Setting for Discrete PID Controllers", *IEE Proceedings-D*, vol. 139, no. 1, pp. 31-40, 1992.
- Wieniewichs I., *Análise da Performance de Controladores IMC-PID*, Tese de Mestrado, UNICAMP/FEQ, 1993.
- Willigenburg, L. G. van, "Computation of the Digital LQG Regulator and Tracker for Time-Varying Systems", *Optimal Control Applications & Methods*, vol. 13, pp. 289-299, 1992.
- Willis, M. J., G. A. Montague, C. Di Massimo, M. T. Tham & A. J. Morris, "Artificial Neural Networks in Process Estimation and Control", *Automatica*, vol. 28, p. 1181, 1992.
- Wittenmark, B & K. J. Åström, "Practical Issues in the Implementation of Self-tuning Control", *Automatica*, vol. 20, no. 5, pp. 595-605, 1984.
- Woinet, R., G. Thomas e J. Bordet, "Adaptive Control Based on Pole Placement: an Experimental Test on a Binary Distillation Column", *Chemical Engineering Science*, vol. 46, no. 4, pp. 949-957, 1991.
- Ydstie, B. E., "Adaptive Process Control", *Chem. Eng. Res. Des.*, vol. 65, pp. 480-489, 1987.
- Zanker, P. e P. E. Wellstead, "Techniques of Self-Tuning", *Optimal Control Applications & Methods*, vol. 3, pp. 305-322, 1982.

Zhou, J. e R. H. Luecke, "Estimation of the Covariances of the Process Noise and Measurement Noise for a Linear Discrete Dynamic System", *Computers Chem. Engng*, vol. 19, no. 2, pp. 187-195, 1995.

-, *Optimization Toolbox User's Guide*, The Mathworks Inc., USA, 1992.

## ABSTRACT

ASSIS, A. J., *Projeto de Controladores Adaptativos Auto-Ajustáveis*, dissertação de mestrado, DPQ - FEQ - UNICAMP Campinas, SP, 1996

With today's requirement of stringent process specification, it is becoming increasingly important to design better controllers for chemical processes. This can be achieved using advanced control strategies, for instance, *adaptive control*. This thesis presents a general review of adaptive control, state estimation and process identification as well as applications of these techniques to relevant chemical and biotechnological processes.

It is presented a systematic and comprehensive treatment of both discrete Kalman Filter and Extended Kalman Filter (EKF), when applied to on-line recursive state and parameter identification for nonlinear stochastic systems using state-space approach. A specific system, taken as a case study, that requires the simultaneous identification of process states and model parameters, is the batch beer fermentation. The influence of sample time, presence of noisy measurements, and convergence conditions of the algorithm were investigated and the results are presented and discussed.

This work also presents a general methodology for the design of adaptive controllers for biological reactors with the aid of an illustrative case study, namely, the regulation of the ethanol concentration in a large scale continuous yeast production single-input, single-output process. The adaptive controllers were designed using LQG and minimum variance approach in a state-space formulation. A simplified process model is adopted for the specific control purposes. This model is on-line identified employing a suitable recursive Kalman filter based algorithm. Simulation studies show that the adaptive control laws can give superior controller performance compared with other conventional control algorithms.

Finally, it is briefly discussed the difficulties that have to be taken into account in applications of advanced controllers, such as adaptive controllers, in the control of batch distillation columns.