

**CLAUDIO OSVALDO AYALA BRAVO**

**UMA PROPOSTA DE CONTROLE  
PREDITIVO NÃO LINEAR BASEADO EM MODELOS LOCAIS**

Tese de Doutorado submetido ao Programa de Pós-graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina para a obtenção do Grau de Doutor em Engenharia Elétrica.

**Orientador:**

Prof. Dr. Julio Elias Normey Rico.

**Florianópolis/SC  
2010**

Catálogo na fonte pela Biblioteca Universitária  
da  
Universidade Federal de Santa Catarina

B826p Bravo, Claudio Osvaldo Ayala

Uma proposta de controle preditivo não linear baseado em modelos locais [tese] / Claudio Osvaldo Ayala Bravo ; orientador, Júlio Elías Normey Rico. - Florianópolis, SC, 2010.

142 p.: grafs., tabs., mapas

Tese (doutorado) - Universidade Federal de Santa Catarina, Centro Tecnológico. Programa de Pós-Graduação em Engenharia Elétrica.

Inclui referências

1. Engenharia de sistemas. 2. Controle preditivo. 3. Modelos locais. I. Normey-Rico, J. E. (Julio Elias). II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia Elétrica. III. Título.

CDU 621.3

# UMA PROPOSTA DE CONTROLE PREDITIVO NÃO LINEAR BASEADO EM MODELOS LOCAIS

Claudio Osvaldo Ayala Bravo

'Esta Tese foi julgada adequada para obtenção do título de Doutor em Engenharia Elétrica, Área de Concentração em Automação e Sistemas, e aprovada em sua forma final pelo Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Santa Catarina'



---

Prof. Julio Elias Normey Rico, Dr. UFSC  
Orientador

---

Prof. Roberto de Souza Salgado, Ph.D.  
Coordenador do Programa de Pós-Graduação em Engenharia Elétrica

Banca Examinadora:



---

Prof. Bismark Maure Torrico, Dr. - UFC



---

Prof. José Luis Guzmán Sánchez, Dr. - UAL - España



---

Prof. José Carlos Moreno Úbeda, Dr. - UAL - España



---

Prof. Leandro dos Santos Coelho, Dr. - PUCPR



## AGRADECIMENTOS

Meus agradecimentos, em primeiro lugar, à Universidade de Antofagasta, Chile, à Universidade Federal de Santa Catarina, Brasil, e ao Programa PEC-PG da Capes, que tornaram possível meus estudos de aperfeiçoamento.

Quero agradecer a todos os professores e funcionários do DAS que tive a sorte de conhecer durante meus estudos e que sempre mostraram boa disposição e gentileza, como os professores Augusto, Daniel, Eduardo, Eugenio, Nestor, Ubirajara, Augustinho, Alexander e também aos atendentes da Secretaria de PGEAS, Willson e Marcelo.

Um agradecimento especial ao meu professor tutor por sua ótima disposição, paciência e guia ao longo dos meus estudos.

Um reconhecimento muito especial para minha amada Senita por seu amor, carinho, seu apoio constante e colaboração durante meus estudos.

Agradeço a todos os meus companheiros e amigos que estiveram presentes durante meu aperfeiçoamento, apoiando-me de uma forma ou de outra, com sua amizade e seu carinho incondicional: Giovana, Jaime e Tais, Yasmin e Diego, Edward, Eliane, Bismark, Pilar, Rodrigo, Leo.

Também agradeço aos meus irmãos Víctor e Marcelo, por seu exemplo para seguir na busca do aperfeiçoamento acadêmico. Aos meus colegas da Universidade de Antofagasta agradeço por seu apoio às minhas tarefas no Chile durante meus estudos, principalmente ao colega Marcos Crutchik por sua participação direta na gestão da minha vinda ao Brasil.

E não podia deixar de agradecer certamente, a esta bela e mágica cidade de Florianópolis, pela de sua acolhida, e a este querido e grande país pelas oportunidades dadas.



## RESUMO

O presente trabalho aborda o desenvolvimento de uma metodologia de projeto para o controle de plantas não lineares causais com restrições e tempos mortos dominantes, que operem em zonas de equilíbrio estáveis, tendo como base o controlador preditivo baseado em modelos locais e que contemple aspectos de robustez. Este controlador deve ser simples de implementar e aplicar, com baixo custo computacional. Para alcançar estes objetivos se estuda, se implementa, se analisa e se compara com outras técnicas existentes, um gerenciador de modelo local que captura com precisão a dinâmica não linear do processo entre pontos de operação, fazendo uso do modelo não linear da planta. Esta característica, combinada com uma sintonia *on-line* da penalização do controle, outorga ao sistema uniformidade no comportamento da saída e controle da planta em toda sua faixa de operação. Como algoritmo base, se usa um controlador preditivo DTC-GPC que combina as boas características dos controladores preditivos com um compensador de tempos mortos robusto. Este novo algoritmo é aplicado em várias plantas mediante simulação e também se implementa numa planta real. Os resultados mostram que o desempenho da nova proposta é superior a outras técnicas, seja de modelos locais e outras conhecidas, cumprindo também com as algumas das características desejadas para sua aplicação industrial.

**Palavras-chave:** Controle preditivo não linear, modelos locais, tempos mortos.



## ABSTRACT

The present work concerns the development of a design methodology for control of nonlinear plants with dead time and constraints. Thus, this thesis proposes an algorithm based on local models and a predictive controller which covers issues of stability and robustness. For the local controller a dead-time compensator generalized predictive controller is used because. The algorithm is simple to implement and has low computational cost. It uses a supervisor that computes the local model to be used at each operation condition in such a way that it captures quite accurately the nonlinear dynamics of the process between operating points, using the nonlinear model of the plant. This characteristic, combined with an on-line tuning of the control weight, allows for a uniform behavior of the inputs and outputs of the plant in all the operating range. Several simulation case studies and a real implementation in a solar plant are used in this work to test the controller. The obtained results show that the new proposal is superior in performance and or simplicity to other techniques.

**Keywords:** Non Linear Predictive Control, locals models, dead-time.



## LISTA DE FIGURAS

|  |    |
|--|----|
| Figura 2.1. Estrutura do MPC. . . . .  | 38 |
| Figura 2.2. Estratégia de controle do MPC. . . . .   | 38 |
| Figura 2.3. DTC-GPC para caso sem restrições. . . . .  | 46 |
| Figura 2.4. Estrutura do MPC para o caso com restrições. . . . .                                   | 47 |
|  |    |
| Figura 3.1. Esquema geral de controle . . . . .  | 50 |
| Figura 3.2. Esquema detalhado do algoritmo MPAA. . . . .   | 53 |
| Figura 3.3. Curva CEI e tratamento das perturbações. . . . .                                       | 55 |
| Figura 3.4. Entrada e saída em malha aberta do sistema<br>representado pela eq. (3.1). . . . .     | 57 |
| Figura 3.5. Curva característica estática do sistema. . . . .                                      | 58 |
| Figura 3.6. Curva característica estática do sistema e POs. . . . .                                | 58 |
| Figura 3.7. Saída do MNL e do modelo de terceira ordem da<br>proposta. . . . .                     | 59 |
| Figura 3.8. Saída do MNL e do modelo de segunda ordem da<br>proposta . . . . .                     | 59 |
| Figura 3.9. Saída do MNL e do modelo de terceira ordem da<br>proposta. . . . .                     | 60 |
| Figura 3.10. Curva característica estática do modelo e POs. . . . .                                | 61 |
| Figura 3.11. Saída do MNL e do ML para ir de PO1 a PO2. . . . .                                    | 62 |
| Figura 3.12. Saída do MNL e do ML para ir de PO2 a PO3. . . . .                                    | 62 |
| Figura 3.13. Saída do MNL e do ML para ir de PO3 a PO4. . . . .                                    | 63 |
| Figura 3.14. Sinais do MNL e do modelo da proposta para<br>perturbações no PO(2, 3.299). . . . .   | 64 |
| Figura 3.15. Sinais do MNL e do modelo da proposta para<br>perturbações no PO(2.5, 4.021). . . . . | 64 |
| Figura 3.16. Controle e saída do MNL e modelo proposto para<br>transição de PO1 a PO2. . . . .     | 65 |
| Figura 3.17. Controle e saída do MNL e modelo da proposta<br>para transição de PO2 a PO3. . . . .  | 66 |
| Figura 3.18. Tanque reator agitado continuamente. . . . .  | 67 |
| Figura 3.19. Curva característica estática do CSTR. . . . .  | 68 |
| Figura 3.20. Curva característica estática inversa do CSTR. . . . .                                | 69 |
| Figura 3.21. Curva CEI versus curva MEI do CSTR. . . . .   | 70 |
| Figura 3.22. Saída do MNL do CSTR e do modelo linear<br>estimado de primeira ordem. . . . .        | 71 |
| Figura 3.23. Saída do MNL do CSTR e do modelo linear   |    |

|   |    |
|---|----|
| estimado de segunda ordem. . . . .  | 71 |
| Figura 3.24. Saída do MNL do CSTR e do modelo linear de segunda ordem, $\Delta u$ nominal. . . . .              | 72 |
| Figura 3.25. Saída do MNL e do modelo da proposta para perturbações no PO(60, 0.0215). . . . .                  | 73 |
| Figura 3.26. Saída do MNL e do modelo da proposta para perturbações no PO(80, 0.00445). . . . .                 | 74 |
| Figura 3.27. Sinal típico de controle. . . . .  | 74 |
| Figura 3.28. Saída do MNL do CSTR e do modelo linear estimado de segunda ordem. . . . .                         | 75 |
| Figura 3.29. Sinal típico de controle aplicado na planta. . . . .   | 76 |
| Figura 3.30. Saída do MNL e do modelo linear de segunda ordem, entrada tipo rampa. . . . .                      | 76 |
| Figura 3.31. Curva característica estática do CSTR e POs . . . . .  | 77 |
| Figura 3.32. Saídas do sistema não linear e do modelo da proposta para diferentes $\Delta u$ . . . . .          | 78 |
| Figura 3.33. Saídas do sistema não linear, do modelo linearizado e do modelo da proposta. . . . .               | 79 |
| Figura 3.34. Controlador com matriz dinâmica baseado em modelos locais. . . . .                                 | 81 |
| Figura 3.35. Controlador com matriz dinâmica baseado em controladores locais. . . . .                           | 82 |
| Figura 3.36. Saída e controle para transferência entre PO2 e PO3. . . . .                                       | 84 |
| Figura 3.37. Ganho versus penalização de controle e curva de ajuste. . . . .                                    | 85 |
| Figura 4.1. Curva característica estática e pontos de operação definidos. . . . .                               | 88 |
| Figura 4.2. Seguimento de referência, controle e tempo de CPU com $\lambda$ variável. . . . .                   | 90 |
| Figura 4.3. Saída do MNL e do ML da primeira mudança na referência. . . . .                                     | 91 |
| Figura 4.4. Saída do sistema e do ML para o caso da terceira mudança na referência. . . . .                     | 91 |
| Figura 4.5. Seguimento de referência aplicando a proposta com $\lambda_n=1.5$ . . . . .                         | 92 |
| Figura 4.6. Seguimento de referência e controle com único modelo linear de previsão e $\lambda_n=1.5$ . . . . . | 93 |
| Figura 4.7. Saída e controle no caso de perturbação na entrada e saída da planta. . . . .                       | 94 |

|   |     |
|---|-----|
| Figura 4.8. Referência, saída e controle com perturbação no controle. . . . .                       | 95  |
| Figura 4.9. Referência, saída e controle com variações de 10% nos parâmetros do sistema. . . . .    | 95  |
| Figura 4.10. Planta de Neutralização de pH. . . . .   | 96  |
| Figura 4.11. Curva característica estática do sistema. . . . .                                      | 99  |
| Figura 4.12. CEI e curva obtida com MEI. . . . .  | 102 |
| Figura 4.13. Seguimento de referência e controle com $\lambda n=100$ e $\lambda$ constante. . . . . | 102 |
| Figura 4.14. Seguimento de referência e controle com modelo único e $\lambda n=100$ . . . . .       | 103 |
| Figura 4.15. Referência, saída, e controle com modelo da proposta e com modelo único. . . . .       | 104 |
| Figura 4.16. Seguimento de referência e controle com $\lambda n=40$ . . . . .                       | 105 |
| Figura 4.17. Resposta a um degrau de perturbação no $q_2$ com referência no pH de 7.0. . . . .      | 106 |
| Figura 4.18. Resposta a um degrau de perturbação no $q_2$ com referência no pH de 9.0. . . . .      | 107 |
| Figura 4.19. Respostas a perturbação no $q_2$ com e sem restrição. . . . .                          | 108 |
| Figura 4.20. Respostas a mudanças de referências considerando tempo morto no processo. . . . .      | 109 |
| Figura 4.21. Seguimento de referência e controle com $\lambda$ variável                             | 110 |
| Figura 5.1. Layout básico da planta AQUASOL. . . . .  | 114 |
| Figura 5.2. Uma malha do campo coletor solar. . . . .   | 115 |
| Figura 5.3. Pontos de operação da planta a controlar. . . . .                                       | 120 |
| Figura 5.4. Resposta em malha fechada e sinal de controle para os POs escolhidos. . . . .           | 122 |
| Figura 5.5. Entradas no processo real, dia parcialmente nublado. . . . .                            | 124 |
| Figura 5.6. Saída e controle no caso dia parcialmente nublado                                       | 124 |
| Figura 5.7. Entradas no processo real, dia ensolarado. . . . .                                      | 125 |
| Figura 5.8. Saída e controle no processo simulado, dia ensolarado                                   | 126 |
| Figura 5.9. Comparação do algoritmo proposto com outros algoritmos de controle. . . . .             | 127 |
| Figura 5.10. Saída, controle e perturbações do processo real da primeira experiência. . . . .       | 129 |
| Figura 5.11. Saída, controle e perturbações do processo real da segunda experiência. . . . .        | 130 |



## LISTA DE TABELAS

|   |     |
|---|-----|
| Tabela 3.1. Modelos entre pontos de operação e cálculo de SSE. . .                                | 61  |
| Tabela 3.2. Condições de operação do CSTR . . . . .   | 67  |
| Tabela 3.3. Modelos entre pontos de operação e SSE. . . . .                                       | 77  |
| Tabela 3.4. Ganho do modelo e lambda para transferências entre<br>pontos de operação. . . . .     | 84  |
|   |     |
| Tabela 4.1. Condições de operação nominal da planta de pH. . . . .                                | 97  |
| Tabela 4.2. Modelos ARX e parâmetros dinâmicos do sistema. . .                                    | 100 |
| Tabela 4.3. Parâmetros de ajuste do controlador. . . . .  | 101 |
| Tabela 4.4. Parâmetros de resposta do LM-GPC, LC-GPC e<br>método proposto. . . . .                | 106 |
| Tabela 4.5. Parâmetros dinâmicos do LM-GPC, LC-GPC e a<br>proposta com $q_2 = 0.15$ ml/s. . . . . | 107 |
|   |     |
| Tabela 5.1. Registro dos parâmetros e variáveis associadas ao<br>modelo do processo. . . . .      | 116 |
| Tabela 5.2. Valores dos parâmetros da planta. . . . .   | 118 |
| Tabela 5.3. Parâmetros dinâmicos entre pontos de operação. . . . .                                | 120 |
| Tabela 5.4. Parâmetros de Ajuste. . . . .   | 121 |
| Tabela 5.5. Parâmetros dinâmicos para cada PO . . . . .   | 121 |
| Tabela 5.6. Parâmetros dos controladores. . . . .   | 127 |



## LISTA DE ABREVIATURAS E SIGLAS

| <b>Termo</b> | <b>Denominação original</b>   |
|--------------|---|
| ARX          | Auto-regression with exogenous inputs                                     |
| CARIMA       | Controlled Auto-Regressive Integrated Moving-Average                      |
| CCE          | Curva Característica Estática   |
| CEI          | Curva Estática Inversa  |
| CML          | Cálculo do Modelo Local   |
| CPA          | Cálculo Parâmetros de Ajuste  |
| CPC          | Compound Parabolic Concentrator   |
| CPU          | Central Processing Unit   |
| CRHPC        | Constrained Receding-Horizon Predictive Control                           |
| CSTR         | Continuous Stirred Tank Reactor   |
| DEAHP        | Double Effect Absorption Heat Pump  |
| DMC          | Dynamic Matrix Control  |
| DTC          | Dead-Time Compensator   |
| DTC-GPC      | Dead Time Compensator Generalized Predictive Controller                   |
| DTC-GPC-FL   | DTC-GPC Feedback Linearization  |
| DTC-GPC-LM   | DTC-GPC Local Model   |
| DTC-NEPSAC   | Dead-Time Compensator Nonlinear Extended Prediction Self-Adaptive Control |
| EPSAC        | Extended Predictive Self Adaptive Control                                 |
| RBF          | Radial Basis Function   |
| FSP          | Filtered Smith Predictor  |
| GPC          | Generalized Predictive Control  |
| LC-DMC       | Local Controller Dynamic Matrix Control                                   |
| LC-GPC       | Local Controller Generalized Predictive Control                           |
| LLT          | Local Linearization Trajectory  |
| LM-DMC       | Local Model Dynamic Matrix Control  |
| LM-GPC       | Local Model GPC   |
| LMN          | Local Model Network   |
| LP           | Linear Programming  |
| LSE          | Least Squares Estimator   |
| MAC          | Model Algorithm Control   |
| MED          | Multi-Effect Distillation   |

|        |   |
|--------|---|
| MEI    | Modelo Estático Inverso                             |
| MIMO   | Multiple Input Múltiple Output                      |
| ML     | Modelo Linear                                       |
| MNL    | Modelo Não Linear                                   |
| MPAA   | Modelo de Predição e Ajuste Adaptativos             |
| MPC    | Model Predictive Control                            |
| NEPSAC | Nonlinear Extended Prediction Self-Adaptive Control |
| NLP    | Nonlinear Programation                              |
| NMPC   | Nonlinear Model Preditive Control                   |
| ODES   | Ordinary Differential Equations Systems             |
| OP     | Optimal Predictor                                   |
| PFC    | Predictive Functional Control                       |
| PID    | Proporcional Integral Derivativo                    |
| PNMPC  | Practical não-Linear MPC                            |
| PO     | Ponto de Operação                                   |
| QP     | Quadratic Programming                               |
| RBF    | Radial Base Function                                |
| SCGPC  | Stable Continuous Generalized Predictive Control    |
| SGPC   | Stable Generalized Predictive Control               |
| SIORHC | Stabilising I/O Receding-Horizon Control            |
| SISO   | Singled Input Singled Output                        |
| SP     | Smith Predictor                                     |
| SP-GPC | Smith Predictor Generalized Predictive Controller   |
| SQP    | Sequential Quadratic Programming                    |
| SSE    | Sum of Squares Error                                |

## SUMÁRIO

|  |           |
|--|-----------|
| <b>1 INTRODUÇÃO</b>                            | <b>21</b> |
| 1.1 MOTIVAÇÃO.....                             | 21        |
| 1.2 ESTADO DA ARTE DO NMPC.....                | 24        |
| 1.2.1 MPC LINEAR E NÃO LINEAR.....             | 25        |
| 1.2.2 FORMULAÇÕES ALTERNATIVAS DO NMPC.....    | 26        |
| 1.2.3 ESTABILIDADE E ROBUSTEZ DO MPC.....      | 29        |
| 1.2.4 O MPC PARA SISTEMAS COM TEMPO MORTO..... | 31        |
| 1.2.5 SINTONIA DE MPC'S.....                   | 31        |
| 1.3 FUNDAMENTOS DA NOVA PROPOSTA.....          | 32        |
| 1.4 OBJETIVOS.....                             | 34        |
| 1.5 ESTRUTURA DO TRABALHO.....                 | 34        |
| <br>   |           |
| <b>2 REVISÃO DE CONTROLE PREDITIVO LINEAR</b>  | <b>37</b> |
| 2.1 INTRODUÇÃO.....                            | 37        |
| 2.2 CONTROLE PREDITIVO BASEADO NO MODELO.....  | 37        |
| 2.2.1 METODOLOGIA DO MPC.....                  | 37        |
| 2.2.2 CONTROLE PREDITIVO GENERALIZADO.....     | 39        |
| 2.2.2.1 PARÂMETROS DE SINTONIA.....            | 41        |
| 2.2.2.2 RESTRIÇÕES.....                        | 43        |
| 2.3 CONTROLADOR DTC-GPC.....                   | 44        |
| 2.4 SUMÁRIO.....                               | 48        |
| <br>   |           |
| <b>3 FILOSOFIA E METODOLOGIA DE PROJETO</b>    | <b>49</b> |
| 3.1 INTRODUÇÃO.....                            | 49        |
| 3.2 ALGORITMO DE CONTROLE.....                 | 49        |
| 3.2.1 CONFIGURAÇÃO OFF-LINE.....               | 51        |
| 3.2.2 OPERAÇÃO ON-LINE DO CONTROLADOR.....     | 52        |
| 3.2.2.1 CASO DE ESTUDO 1: MODELO LAZAR.....    | 56        |
| 3.2.2.2 CASO DE ESTUDO 2: CSTR.....            | 66        |
| 3.2.2.3 COMPARAÇÕES.....                       | 79        |
| 3.2.2.4 PENALIZAÇÃO DO CONTROLE.....           | 82        |
| 3.3 COMENTÁRIOS.....                           | 85        |

|  |            |
|--|------------|
| <b>4 APLICAÇÕES E COMPARAÇÕES POR SIMULAÇÃO</b>  | <b>87</b>  |
| 4.1 INTRODUÇÃO.....                              | 87         |
| 4.2 CASO DE ESTUDO 1: MODELO LAZAR.....          | 87         |
| 4.3 CASO DE ESTUDO 2: CONTROLE DE PH.....        | 96         |
| 4.3.1 CONFIGURAÇÃO E AJUSTE DO CONTROLE.....     | 99         |
| 4.3.2 COMPARAÇÃO COM OUTRAS TÉCNICAS.....        | 104        |
| 4.3.3 ANÁLISE DO CASO COM RESTRIÇÕES.....        | 108        |
| 4.3.4 ANÁLISE DO CASO COM TEMPO MORTO.....       | 108        |
| 4.3.5 MUDANÇAS MAIORES NA REFERÊNCIA.....        | 110        |
| 4.4 CONCLUSÕES.....                              | 110        |
| <b>5 CONTROLE DE PLANTA AQUASOL</b>              | <b>113</b> |
| 5.1 INTRODUÇÃO.....                              | 113        |
| 5.2 DESCRIÇÃO DO SISTEMA.....                    | 113        |
| 5.3 MODELO SIMPLIFICADO DO CAMPO SOLAR.....      | 114        |
| 5.4 PROJETO DO CONTROLADOR.....                  | 118        |
| 5.5 SIMULAÇÕES PRÉVIAS.....                      | 122        |
| 5.5.1 DIA PARCIALMENTE NUBLADO.....              | 123        |
| 5.5.2 DIA ENSOLARADO.....                        | 125        |
| 5.5.3 COMPARAÇÕES.....                           | 126        |
| 5.6 EXPERIMENTOS.....                            | 128        |
| 5.6.1 PRIMEIRA EXPERIÊNCIA.....                  | 128        |
| 5.6.2 SEGUNDA EXPERIÊNCIA.....                   | 130        |
| 5.7 CONCLUSÕES E COMENTÁRIOS.....                | 131        |
| <b>6 CONCLUSÕES FINAIS</b>                       | <b>133</b> |
| 6.1 PRINCIPAIS CONTRIBUIÇÕES DESTE TRABALHO..... | 134        |
| 6.2 PUBLICAÇÕES.....                             | 134        |
| 6.3 PESQUISAS FUTURAS.....                       | 135        |
| <b>REFERÊNCIAS BIBLIOGRÁFICAS</b>                | <b>137</b> |

# CAPÍTULO 1

## INTRODUÇÃO

Neste capítulo apresentam-se, inicialmente, os fatores que motivaram este trabalho e o caminho abordado na procura da solução do problema de controle. Na continuação, é apresentado o estado da arte em relação às técnicas de controle preditivo para sistemas lineares e não lineares, descrevendo de forma sucinta o problema da estabilidade e as formulações estáveis existentes na atualidade. Apresenta-se também o problema das incertezas no controle preditivo em relação aos tempos mortos, e as formulações robustas do mesmo. Também se abordam aspectos relativos à sintonia dos controladores. Finalmente, descrevem-se os fundamentos e objetivos que orientaram este trabalho de tese e a estrutura do documento.

### 1.1. MOTIVAÇÃO

A forma de operar processos industriais tem experimentado avanços significativos nos últimos tempos, guiados pela necessidade de produzir de forma segura, limpa e competitiva, produtos que satisfaçam as necessidades do mercado, tanto na demanda como na qualidade e uniformidade. Duas razões justificam este fato, de um lado, a necessidade de responder a um mercado cada vez mais diversificado e exigente no controle de qualidade e segurança dos produtos, considerando seus ciclos de vida cada vez mais curtos. Por outro lado, a necessidade de promover o crescimento sustentável, minimizando o impacto ambiental e o consumo de recursos, contribui para a procura de uma produção mais eficiente para atender as exigências e limitações impostas aos produtos. Por isso, é conveniente procurar técnicas de controle que proporcionem leis que maximizem a eficiência, assegurando a satisfação dos limites sobre os produtos.

Na indústria de processos é normal a existência de um ponto de operação para a permanência do processo, a fim de maximizar a eficiência. No entanto, ao longo do seu funcionamento normal, estes processos estão sujeitos a mudanças freqüentes no seu ponto de operação, de modo que para estes não há nenhum ponto de funcionamento, mas sim uma gama de pontos de operação e em quaisquer deles o processo pode funcionar durante um período de

tempo. A escolha do ponto de operação, dentro deste intervalo, deve respeitar a diversidade dos produtos, lotes ou condições em que a planta pode estar funcionando.

Ao abordar o problema de controle, é necessário considerar dois aspectos que surgem nesta condição: O primeiro decorre da ampla gama de pontos de operação que as plantas apresentam o que ressalta a natureza não-linear de sua dinâmica (implícito nas equações constitutivas associadas a balanços de materiais, energia e momento) e do grau de incertezas (estrutural e paramétrica) associadas às suas representações. O outro aspecto é que neste tipo de plantas é comum a distribuição espacial de algumas ou todas as variáveis de estado, o que significa que suas dinâmicas devem ser descritas por sistemas acoplados de equações algébricas, diferenciais ordinárias e/ou equações diferenciais parciais.

À natureza complexa do sistema é adicionada a presença de restrições sobre o seu funcionamento. Estas restrições podem ser limites nas variáveis manipuladas e/ou limites impostos sob as variáveis de processo. Também podem resultar de limitações físicas de variáveis ou limites nas áreas de evolução da planta por razões econômicas, ambientais ou operacionais.

Outro fato relevante a considerar, em processos industriais, são os efeitos causados por tempos mortos nos sistemas de controle, os quais representam um problema importante encontrado na indústria de processos que apresentam tempos mortos dominantes.

O controle preditivo é uma das poucas estratégias que permite o controle dos sistemas com restrições com um critério ótimo, garantindo a estabilidade e convergência para o ponto de equilíbrio (Mayne, 2001). Esta técnica outorga intrinsecamente certo grau de robustez e resolve o problema dos tempos mortos. Dado o êxito alcançado pelo controle preditivo baseado no modelo (MPC, *Model Predictive Control*), em aplicações lineares e não lineares na indústria de processos, a sua aplicação obteve um forte crescimento nos últimos anos. Mais de 4600 aplicações foram relatadas num período de 5 (cinco) anos desde 1997 (Qin & Badwell, 2002), principalmente nas áreas de refino e das indústrias química, alimentar, aeronáutica e automobilística.

Um fator que tem contribuído grandemente para o desenvolvimento desta técnica avançada de controle, principalmente os MPCs lineares, é a existência de *softwares* comerciais de MPCs que

incorporam programas para apoiar projetos de controles, desenvolvimento de modelos e provas de simulação em malha fechada.

De acordo com vários autores (De Prada, 2004; Qin & Badwell, 2002), as tendências no controle avançado de processos, e o desenvolvimento tecnológico da próxima geração de MPCs, está associada a controladores não lineares baseados em modelos (NMPC, *Nonlinear Model Predictive Control*). No entanto, aspectos práticos na aplicação do MPC em plantas industriais devem considerar que estas formulações avançadas de controle são aplicadas e mantidas, principalmente, por engenheiros e técnicos de distintas especialidades. É do conhecimento de todos os que têm contato com o controle aplicado na indústria que o êxito na aplicação de qualquer nova técnica de controle dependerá de sua simplicidade em relação a sua filosofia, configuração e sintonia (Froisy, 2006). Tendo em vista também aspectos de factibilidade operacionais que podem decidir na aplicação certa, ou não, das novas propostas de controle avançado a fim de melhorar os processos.

Um aspecto crucial para o êxito na aplicação do MPC é o modelo da planta que deve representar, o mais fielmente possível, seu comportamento estático e dinâmico. Dentro do possível, o método a aplicar não deve depender do tipo de modelo disponível. Sem dúvida, muitas das formulações para lidar com as plantas não lineares não são simples de compreender e aplicar, requerendo um nível de conhecimento maior do que normalmente é encontrado entre as pessoas que operam, mantêm e supervisionam os processos industriais.

Dada a natureza não linear dos processos e suas constantes mudanças de referências nas aplicações industriais, surge a necessidade de aplicar técnicas preditivas de controle não-lineares, entretanto sua aplicação não é trivial. Na atualidade, para enfrentar o controle de processos não lineares mediante técnicas preditivas, dispõe-se de NMPC direto e de formulações alternativas. No primeiro caso, NMPC direto, que é uma extensão da técnica linear, a solução do problema de otimização requer a consideração (e ao menos a resolução parcial) de um problema não linear não convexo (NLP, *Nonlinear Programation*) dando lugar a uma série de dificuldades computacionais relacionadas com o custo e a habilidade da resolução do problema NLP *on-line* (Camacho & Bordons, 2004). Normalmente, o problema é resolvido fazendo uso da Programação Quadrática Seqüencial (SQP, *Sequential Quadratic Programming*). No segundo tratamento, as seguintes

formulações tratam de evitar, de distintas maneiras, o problema associado à otimização não convexa: MPC linear estendido (Camacho & Bordons, 2004; Hernandez & Arkun, 1991), uso de NMPC subótimo (Camacho & Bordons, 2004; Scokaert *et al.*, 1999), uso de Horizontes Curtos (Camacho & Bordons, 2004), Decomposição da Seqüência de Controle (Tamas *et al.*, 2007), Linearização por Realimentação (Camacho & Bordons, 2004; Khalil, 1996), NMPC baseado em: Modelos Volterra (Camacho & Bordons, 2004; Doyle *et al.*, 2001), Redes Neurais Artificiais (Jalili & Araabi, 2004), Modelos Locais (Camacho & Bordons, 2004; Arahal *et al.*, 1998), modelos Fuzzy (Mahfouf, 2002), modelos Neuro-Fuzzy (Liu, 2006), modelos Hammerstein e Wiener (Al-Duwaish, 2000), etc.. A maioria destas técnicas alternativas não tem simplicidade em relação a sua filosofia, configuração e sintonia (manutenção), algumas não apresentam bom desempenho, outras não são aplicáveis a todos os casos, outras podem apresentar problemas de convergência ou têm um alto custo computacional. Também adoecem de um procedimento sistemático para a sintonia de seus parâmetros.

Baseado em todos estes fatores e motivado pela procura de uma solução mais prática ao problema de controle de processos industriais não lineares, com constantes mudanças de referências e tempos mortos dominantes, o presente trabalho é orientado no desenvolvimento de procedimentos e algoritmos computacionais, no âmbito do controle preditivo baseado no modelo, que permitam controlar estes processos com bom desempenho e uniformidade no comportamento de suas variáveis, simplicidade na filosofia, configuração e sintonia, baixo custo computacional e uso de modelos de predição de qualquer natureza. Todo o anterior é considerando restrições e certo grau de robustez da solução.

Dado o caráter industrial do Brasil e a importância que tem o controle dos processos para a economia do país, esta tese se enquadra num tema de pesquisa e desenvolvimento atual de importância estratégica para o país.

## 1.2. ESTADO DA ARTE DO NMPC

Na continuação apresenta-se uma revisão bibliográfica do MPC, dividida em distintas seções, expondo diversos temas relacionados com a nova proposta do controle de processos não lineares.

### 1.2.1. MPC LINEAR E NÃO LINEAR

O controle preditivo baseado em modelo é uma técnica de controle poderosa desenvolvida e consolidada nas duas últimas décadas. É uma das poucas técnicas de controle avançado que tem causado um significativo impacto na indústria de controle de processos. Talvez a principal razão para este êxito deva-se ao fato desta técnica lidar com diversas situações: pode ser aplicada a sistemas SISO (*Singled Input Singled Output*) e MIMO (*Multiple Input Multiple Output*), permite inclusão de ações de realimentação e pré-alimentação, restrições de entrada e saída podem ser incluídas na formulação da lei de controle e pode também compensar intrinsecamente os tempos mortos do processo (Normey-Rico & Camacho, 2007).

O MPC é uma técnica consolidada na indústria para sistemas multivariáveis com restrições que podem ser representados por modelos lineares (Henson, 1998). Embora a maioria dos sistemas reais apresente características não lineares, quando o processo opera apenas numa pequena faixa, seu comportamento pode ser aproximado satisfatoriamente através de modelos lineares, o que tem motivado muitas técnicas de MPC a utilizarem estes modelos. Exemplos destes controladores são: o DMC (*Dynamic Matrix Control*) (Cutler & Ramaker, 1980); o MAC (*Model Algorithm Control*) (Richalet *et al.*, 1978); o GPC (*Generalized Predictive Control*) (Clarke *et al.*, 1987) e o EPSAC (*Extended Predictive Self Adaptive Control*) (De Keyser & Van Cuawenberghe, 1985). São muitas as aplicações de controle baseadas em *softwares* comerciais que utilizam MPC linear na indústria, principalmente nas petroquímicas e refinarias de petróleo no Brasil e no mundo (Camacho & Bordons, 2004).

Porém, quando os processos têm um grau mediano ou severo de não linearidade, ou quando a faixa de operação é variável, ou quando os processos experimentam transições contínuas em sua operação (por exemplo colunas de destilação de alta pureza), necessariamente deverá ser levado em conta o modelo não linear no projeto do controle, de forma que permita manter a estabilidade e desempenho desejados para o sistema em malha fechada (Camacho & Bordons, 2004). Do ponto de vista conceitual o NMPC não apresenta dificuldades, já que é possível considerar a mesma função objetivo do caso linear e um modelo não linear para o cálculo das predições. O objetivo consiste novamente em encontrar o controle que minimize a função objetivo sujeito a um

conjunto de restrições. Já do ponto de vista prático, são várias as dificuldades encontradas neste problema (se comparado ao caso linear): (a) a obtenção do sinal de controle requer, em geral, a solução de um problema de otimização não convexo e (b) a análise de estabilidade e robustez da solução é muito mais complexa. Por estes motivos o NMPC é atualmente um campo aberto para pesquisas (Camacho & Bordons, 2004).

### 1.2.2. FORMULAÇÕES ALTERNATIVAS DO NMPC

Várias formulações alternativas ao NPMC direto têm sido propostas na literatura (Camacho & Bordons, 2004) para evitar todos ou alguns dos inconvenientes citados. A maioria das formulações trata de evitar, de distintas maneiras, o problema associado à otimização não convexa. Algumas destas formulações serão brevemente analisadas na continuação.

No caso do MPC linear *estendido* a técnica é bastante simples. Soma-se um novo termo à predição de saída. Este termo tenta captar as não linearidades e é computado minimizando a diferença entre a predição obtida desde o modelo linear e a predição obtida desde o modelo não linear da planta. Desta forma, as não linearidades do processo, capturadas pelo modelo não linear, são incorporadas diretamente dentro da formulação do MPC linear, mantendo a estrutura de programação quadrática (QP) (Camacho & Bordons, 2004; Hernandez & Arkun, 1991).

No enfoque do NMPC *subótimo*, evita-se a necessidade de achar o mínimo da função de custo não convexa considerando a satisfação das restrições como objetiva primário. Alcançado um decrescimento na função do custo, mediante a estratégia de otimização, esta pode ser detida quando o tempo do cômputo se esgotar, garantindo assim, também, a estabilidade (Camacho & Bordons, 2004; Scokaert *et al.*, 1999).

A idéia de MPC com *horizontes curtos* é calcular exatamente, o primeiro controle que será implementado, resolvendo o NLP, e aproximar o resto da seqüência de controle utilizando um modelo linearizado da planta. Esta técnica tem que sobrelevar o fato de que se requerem normalmente horizontes longos para alcançar o comportamento de malha fechada desejado e estabilidade (Camacho & Bordons, 2004).

No enfoque da *Decomposição da Sequência de Controle*, que tem como base o algoritmo EPSAC, a otimização convexa da função custo deve ser feita mais de uma vez, no período de amostragem, para que a resposta base e a resposta ótima sejam praticamente as mesmas, evitando assim considerar o princípio de superposição que é válido só para sistemas lineares. Para o cálculo, a resposta base utiliza o modelo não linear e a resposta ótima utiliza o modelo linearizado ao redor da saída atual (Tamas *et al.*, 2007). Além do maior tempo envolvido no cálculo do controle, as condições de convergência para o algoritmo podem ser difíceis de obter (Camacho & Bordons, 2004; De Keyser & Lazar, 2003).

*Linearização por Realimentação*, onde o modelo não linear pode ser transformado num modelo linear usando uma transformação apropriada. O principal limitante deste método é que a função de transformação pode ser obtida para poucos casos (Camacho & Bordons, 2004; Khalil, 1996).

*Modelos Volterra*, utilizados especialmente para modelos de segunda ordem, exploram algumas peculiaridades que tem o problema de otimização não convexo geral. Se o modelo quadrático é combinado com a função de custo quadrática dá lugar a um problema de programação de quarta ordem, independente dos valores dos horizontes. Este tipo de problema (função objetivo de quarta ordem) é mais fácil de resolver que um NLP geral (Camacho & Bordons, 2004; Doyle *et al.*, 2001). Neste algoritmo a obtenção do modelo não é simples, requerendo um grande número de parâmetros.

No enfoque com *Redes Neurais Artificiais*, estas redes são usadas para aprender o comportamento de um controlador não linear, ou para identificar o processo não linear, e calcular o sinal de controle *on-line* com poucos cálculos. Esta técnica requer um esforço considerável no treinamento da rede, apresentando também problemas de desempenho, caso a planta opere fora da zona de operação, onde a rede foi treinada (Camacho & Bordons, 2004; Arahall *et al.*, 1998).

Outra formulação que permite a aplicação de controladores preditivos lineares, aproveitando as vantagens que estes apresentam, é aquela baseada em *modelos locais*. A forma mais simples desta técnica é o uso do ponto de operação atual para linearizar o modelo antes da execução do controlador preditivo (Bequette, 1991). Isto permite resolver *on-line* o MPC linear, a cada tempo de amostragem, mediante programação quadrática.

Uma alternativa, na linha de modelos locais, para obter maior exatidão e melhorar o controle, é implementar linearizações locais em tempos igualmente espaçados dentro do intervalo de amostragem. O uso de linearizações repetidas das ODES (*Ordinary Differential Equations Systems*) não lineares difere, significativamente, de outros métodos para controlar plantas não lineares, nas quais o modelo é linearizado uma vez e usado sobre o horizonte completo de predição.

Uma extensão desta idéia, denominada LLT (*Local Linearization Trajectory*), procura utilizar múltiplos modelos para a minimização de tal forma que a mesma ocorra utilizando modelos lineares, referentes aos pontos transitórios pelos quais o sistema vai passar, durante uma mudança de referência, caso for utilizada a seqüência de controle previamente determinada pela otimização (Trierweiler & Secchi, 2000). O efeito dos erros da linearização pode ser reduzido pelo uso apropriado da interpolação linear, compensando desta forma a perda de otimização.

Os problemas que apresentam estas técnicas de linearizações sucessivas é o gasto computacional que aumenta linearmente com o número de linearizações. Além disso, não capturam fielmente a dinâmica do modelo não linear que representa o comportamento da planta.

O conceito de linearizações locais é relativamente semelhante ao uso de uma rede de modelos locais. Esta rede de modelos locais é usada para capturar a dinâmica do processo em diferentes pontos de operação (Camacho & Bordons, 2004). Duas formulações são propostas na exploração desta idéia, ambas usando GPC (Townsend & Irwin, 2001). A primeira é uma rede de controladores LC-GPC (*Local Controller-GPC*), cada uma projetada ao redor de um dos modelos locais. A ação de controle é formada pela combinação das saídas dos controladores lineares. O segundo método, LM-GPC (*Local Model-GPC*) utiliza um único GPC com um modelo local obtido numa combinação dos modelos lineares locais. Uma função de interpolação gera pesos de ativação para cada modelo. Pesos altos são dados aos modelos que dão uma boa aproximação em regime onde o modelo está operando, enquanto que pesos próximos de zero são dados aos outros. No primeiro tratamento (LC-GPC) a sintonia dos controladores pode não ser fácil, devido ao número e efeito das funções base normalizadas da LMN (*Local Model Network*) (Shorten & Murray-Smith, 1997). A estratégia LM-GPC requer só um conjunto de parâmetros de sintonia. O modelo interno de um único controlador GPC é atualizado a cada instante de amostragem.

Este controle gera resultados conservadores, pois a ação de controle deve ser limitada para um funcionamento correto no pior caso, isto significa um fator limitante quando a saída do processo é mudada a um ponto de operação de baixo ganho, onde, talvez, o melhor controle pode não ser atingido (Townsend & Irwin, 2001).

Uma técnica recentemente desenvolvida em Plucenio *et al.* (2007), válida para sistemas lineares e não lineares denominada PNMPC (Practical Não Linear MPC), mostra uma forma de obter uma linearização que fornece uma predição com uma aproximação de Taylor de segunda ordem. A proposta calcula as predições com um modelo combinado linear e não linear e não utiliza o método iterativo para obter a matriz gradiente (denominada:  $G_{\text{PNMPC}}$ , e que é equivalente à da resposta ao degrau  $G$ ) que é utilizada na função objetivo para a otimização. Para obter a matriz  $G_{\text{PNMPC}}$  se utiliza o Jacobiano. O modelo completo das predições inclui o modelo das perturbações através de um fator que é a integral da diferença filtrada entre a variável de saída medida no instante atual e o valor predito.

Em todos os casos anteriores, onde são usadas aproximações, trata-se de compensar as perdas no desempenho com a maior velocidade de processamento e simplicidade dos algoritmos. Assim, pode-se considerar como o melhor aquele algoritmo que consiga o melhor compromisso entre desempenho, simplicidade e velocidade (Plucenio *et al.*, 2007).

### 1.2.3. ESTABILIDADE E ROBUSTEZ DO MPC

A solução eficiente do problema de controle ótimo e a estabilidade de malha fechada são aspectos importantes para qualquer aplicação em processos reais. Para sistemas lineares sem restrições, a estabilidade pode ser analisada com ferramentas convencionais de teoria de sistemas lineares, mas se aparecem restrições ou o sistema é não linear, a lei de controle se converte em não linear, devendo-se usar outras ferramentas.

Embora as indústrias façam uso do MPC desde os anos 70, os primeiros resultados sobre garantia de estabilidade aparecem nos anos 90. São diversas as abordagens deste problema.

No contexto da estabilidade de sistemas lineares com restrições destacam-se formulações do GPC que garantem estabilidade; estes incluem CRHPC (*Constrained Receding-Horizon Predictive Control*)

(Clarke & Scattolini, 1991), SIORHC (*Stabilising I/O receding-horizon control*) (Mosca *et al.*, 1990), SGPC (*Stable Generalized Predictive Control*) (Kouvaritakis *et al.*, 1992) and *infinite-horizon GPC* (Scokaert, 1997). Entre essas, CRHPC, SIORHC e SGPC têm abordagens equivalentes. No caso do SGPC o algoritmo proposto apresenta uma solução baseada no uso de controladores de estabilização numa malha interna onde a referência é subministrada pelo GPC. Uma versão com restrições do SGPC é o SCGPC (*Stable Continuous Generalized Predictive Control*) que utiliza um procedimento de minimização alternativo ao QP (Rossiter, 1993). Estes controladores estão definidos por operadores polinomiais ao invés de funções de transferência, fazendo com que a carga computacional diminua notavelmente.

O uso da penalização ou restrição terminal, funções de Lyapunov ou conjuntos invariáveis deram lugar a uma ampla família de técnicas que são capazes de garantir a estabilidade do sistema controlado. As formulações de estabilidade garantida estão recolhidas em Mayne *et al.* (2000). Nesta referência, os autores apresentam as condições suficientes para o projeto de um controlador preditivo estabilizante com restrições e demonstram que todas as formulações nomeadas anteriormente na literatura são casos particulares desta.

O principal problema destas técnicas é o custo computacional que acarreta a sua resolução, principalmente para sistemas em grande escala.

Outro problema real muito importante a considerar, em qualquer tipo de controlador, é a robustez devido às discrepâncias existentes entre o modelo de predição e o sistema real. Esta diferença pode causar violação das restrições na evolução do sistema real ou que o controlador deixe de ser factível, ou a perda da convergência do sistema em malha fechada. O fato que no MPC se aplica a estratégia deslizante faz com que a atuação se recalculasse em cada período de amostragem, provendo de realimentação e, portanto, de robustez ao sistema.

O estudo de robustez pode ser feito a partir de dois pontos de vista: da *síntese de robustez* e da *análise de robustez*. Na síntese, a incorporação das incertezas é muito cara devido ao grau de complexidade dos controladores preditivos que incorporam otimização e satisfação de restrições, portanto na maior parte das formulações propostas com estabilidade garantida, constituem soluções meramente teóricas (Limon, 2002). Na análise, uma forma de garantir robustez no MPC é impor que as condições de estabilidade sejam satisfeitas para todas as possíveis realizações das incertezas.

#### 1.2.4. O MPC PARA SISTEMAS COM TEMPO MORTO

Dois aspectos importantes associados à estabilidade e robustez que devem ser abordados no projeto dos controladores preditivos, principalmente em aplicações industriais, estão relacionados com a estimação dos tempos mortos e a sintonia dos controladores.

Diversos trabalhos (Qin & Badgwell, 1997; Takatsu *et al.*, 1998) registram que o desempenho causado pelos atrasos nos sistemas de controle representam um dos problemas importantes encontrados na indústria de processos. As dificuldades em controlar processos com atrasos significativos são bem conhecidas e devem-se ao fato de que o atraso deteriora a margem da fase do sistema. Existem diferentes configurações para lidar com o atraso que podem ser denominadas genericamente como DTC (*Dead-Time Compensator*) (Normey-Rico & Camacho, 2007), a mais popular de todas, e bastante utilizada na indústria, é o preditor de Smith. No entanto, os problemas da robustez causados por erros na estimação do tempo morto podem levar ao preditor de Smith à instabilidade (Normey-Rico & Camacho, 2007).

Os problemas de robustez causados no MPC pelos erros na estimativa do tempo morto em MPC foram tratados recentemente usando uma abordagem de DTCs (Normey-Rico & Camacho, 2007). Os autores propõem um controlador chamado DTC-GPC que tem várias vantagens quando é comparado ao tradicional GPC e quando o propósito é a robustificação do sistema de controle para processos com tempo morto (Normey-Rico & Camacho, 2000; Normey-Rico & Camacho, 2007). O DTC-GPC utiliza um Preditor de Smith filtrado (FSP, *Filtered Smith Predictor*) para computar as previsões até o tempo morto, ao invés do preditor ótimo, obtendo um controlador resultante mais robusto e fácil de sintonizar do que a solução do GPC tradicional. O filtro usado no preditor FSP também permite que o controlador seja usado em processos com tempo morto instáveis em malha aberta.

#### 1.2.5. SINTONIA DE MPCs

Outro assunto importante em relação à aplicação do MPC, e que tem merecido atenção durante o desenvolvimento dos controladores preditivos, refere-se a sua sintonia. Técnicas de sintonia para MPC têm sido propostas em muitos trabalhos. Em Iino *et al.* (1993) apresenta-se um método de sintonia de parâmetros considerando estabilidade robusta

baseada na análise da resposta de frequência. Entretanto em Rowe & Maciejowski (2000) propõe-se um método de *H-infinito loop-shaping* onde as propriedades de estabilidade e desempenho se mantêm dentro das especificações apesar das pequenas diferenças entre a planta nominal assumida no projeto e a verdadeira planta encontrada na prática. Um método de sintonia heurística baseado em regras expertas é proposto em Drogies (1999). Recentemente em Van der Lee *et al.* (2008) o método de sintonia proposto tem um enfoque numérico e combina um algoritmo genético com uma estrutura de decisão fuzzy multiobjetivo. Os métodos propostos em Iino *et al.* (1993) e Rowe & Maciejowski (2000) requerem complicados procedimentos computacionais e são difíceis de serem usados por projetistas de controladores sem experiência. Na prática, as regras expertas desenvolvidas em Drogies (1999) e Van der Lee *et al.* (2008) devem ser modificadas por problemas de objetivos, tornando complicado seu uso. Ou seja, estes métodos de sintonia são ainda difíceis para serem aplicados por projetistas e mantenedores de controladores sem experiência e, portanto, métodos de sintonia simples do MPC são avidamente requeridos na indústria (Kawai *et al.*, 2007).

Um dos parâmetros de sintonia que tem especial relevância para obter um bom desempenho do controlador preditivo é aquele associado ao esforço do controle. Este parâmetro ajuda a prevenir esforços de controle agressivos e respostas sub-amortizadas das variáveis controladas (Han *et al.*, 2006). Mas, também podem ocorrer respostas excessivamente lentas se forem escolhidos valores altos para este parâmetro; portanto  $\lambda$  tem um impacto significativo no desempenho do MPC. A penalização do esforço de controle tem ainda um maior impacto em processos altamente não lineares, onde o ganho estático varia consideravelmente de uma região de operação a outra. Em Altinten (2007), a penalização do controle foi variada para alcançar ótimo desempenho do GPC no controle de uma planta de pH. Também, em Peng *et al.* (2007), recomenda-se que o fator de penalização da matriz de peso do controle (R) seja variável no tempo, numa relação linear com o ganho estático da planta.

### 1.3. FUNDAMENTOS DA NOVA PROPOSTA

No estudo bibliográfico apresentado previamente, referente a controladores preditivos baseados em modelos, pode-se observar que

para o caso não linear existem várias propostas alternativas para evitar o problema do alto custo computacional que implica a resolução do problema de otimização não convexa. Também se observa que a maioria dos métodos apresentados não é simples de compreender, do ponto de vista da aplicação industrial, e aqueles mais simples não têm bons modelos de predição ou têm um alto custo computacional. Tampouco existem métodos de sintonia simples, para aplicações industriais, que sejam fáceis de aplicar e que permitam obter uniformidade no comportamento das variáveis do sistema de controle, em toda a faixa de operação da planta.

Assim, esta tese propõe um novo algoritmo de controle preditivo para processos não lineares que enfatiza quatro questões importantes para o êxito de qualquer técnica de aplicação industrial: simples em sua compreensão e aplicação, desempenho aceitável, sintonia simples e sistemática e baixo custo computacional. O algoritmo se baseia no uso da técnica de modelos locais a partir de uma linearização do modelo no ponto de operação, porém propõe uma nova técnica para a obtenção do modelo local a partir de um modelo linear que captura com boa exatidão a dinâmica não linear do processo. Isto permite a solução *on-line* do MPC linear já que o problema a resolver, em cada instante da amostragem, é um problema de QP. Em relação à obtenção do modelo linear, considera-se uma técnica que pode ser definida como aproximação direcionada ao movimento do controle. Contemplam-se a determinação de um modelo local no caso de mudanças de referências e outro para o caso de rejeição das perturbações. No primeiro caso, a idéia da modelagem direcionada da dinâmica da planta, a partir do modelo não linear, é determinar, em um tempo de amostragem e em cada mudança de referência, um modelo que represente a dinâmica da planta desde o ponto de operação (PO) atual até o novo PO. No segundo caso o modelo usado é um modelo linear que represente o comportamento nas vizinhanças do PO atual. Ressalta-se o fato de que os cálculos são realizados sobre o modelo não linear (MNL) da planta e se realizam em malha aberta.

Na maioria dos controladores preditivos, incluindo não lineares diretos, os parâmetros de ajuste são escolhidos para satisfazer um comportamento adequado em todo o intervalo de operação da planta. No caso da penalização do controle, escolhe-se um valor fixo para este parâmetro. Esta forma de sintonizar o controlador pode limitar o desempenho do controle em certas regiões de operação da planta. Aqui

se mostra que é possível obter uma relação quadrática entre a penalização do controle e o ganho da planta, no ponto de operação atual, que garante um comportamento mais uniforme da saída e do controle em toda a faixa de operação da planta, possibilitando desta forma alcançar tempos de acomodação mais ajustados. O ajuste do parâmetro desta relação quadrática é baseado num procedimento sistemático, *off-line*, facilmente aplicável. Uma vez o controlador operando *on-line* a penalização é determinada em cada mudança de referência através da relação quadrática obtida. Esta forma de sintonia assegura um bom comportamento e uniformidade das variáveis manipuladas e controladas do sistema controlado.

Em relação ao problema dos sistemas com atraso e dadas às boas características do controlador DTC-GPC, tem-se considerado esta técnica como controlador MPC linear básico para ser usado na proposta para enfrentar as incertezas em relação aos tempos mortos.

#### 1.4. OBJETIVOS

Contribuir para a melhoria da solução do controle de processos não lineares no âmbito do controle preditivo, considerando fundamentalmente questões como:

- Simplicidade no desenvolvimento dos algoritmos;
- Simplicidade no ajuste de parâmetros do controlador;
- Baixo custo computacional.

No desenvolvimento do controlador dar-se-á ênfase aos problemas associados ao controle de processos não lineares causais, que podem apresentar atrasos dominantes e incertos na sua dinâmica e estão sujeitos a restrições de operação e submetidos a mudanças de referências em toda sua faixa de operação, mas que operam em zonas de equilíbrio estáveis.

#### 1.5. ESTRUTURA DO TRABALHO

O restante do documento está organizado conforme segue.

No Capítulo 2 desenvolvem-se aspectos teóricos sobre o controlador preditivo baseado no modelo, descrevendo em detalhes o controlador preditivo generalizado. Apresentam-se também aspectos

relativos ao algoritmo DTC-GPC para o tratamento de tempos mortos dominantes.

Na continuação, no Capítulo 3, apresenta-se a proposta de controle, sua filosofia e procedimento do projeto, baseado no DTC-GPC e modelos locais, utilizando alguns exemplos para esclarecer aspectos de obtenção dos modelos de predição e ajuste do controlador. Os resultados da nova técnica comparam-se com outras formulações que fazem uso de modelos locais obtidos através de outras técnicas conhecidas.

No Capítulo 4, aplica-se a metodologia do projeto a dois sistemas bem conhecidos na literatura. Também, mediante simulação, analisam-se os resultados da aplicação desta proposta e se comparam com outras técnicas de modelos locais conhecidas.

No Capítulo 5, apresenta-se o projeto e a aplicação do controlador a uma planta experimental de produção de água destilada com energia solar (AQUASOL) e apresentam-se os resultados, comparando-os com outras técnicas de controle de processos não lineares.

Finalmente, no Capítulo 6, entregam-se as conclusões finais deste trabalho com as contribuições, publicações realizadas e perspectivas de pesquisas futuras.



## CAPÍTULO 2

### REVISÃO DE CONTROLE PREDITIVO LINEAR

#### 2.1. INTRODUÇÃO

Neste capítulo revisam-se os principais conceitos e propriedades do MPC, considerando aspectos e formulações matemáticas em relação às restrições, ajustes, tratamento de tempos mortos e robustez. Inicia-se com uma descrição da metodologia do controle preditivo baseado em modelo e se apresenta o algoritmo do DTC-GPC que será utilizado neste trabalho para o controle de plantas não lineares com restrições. Finalmente, apresenta-se o resumo do capítulo.

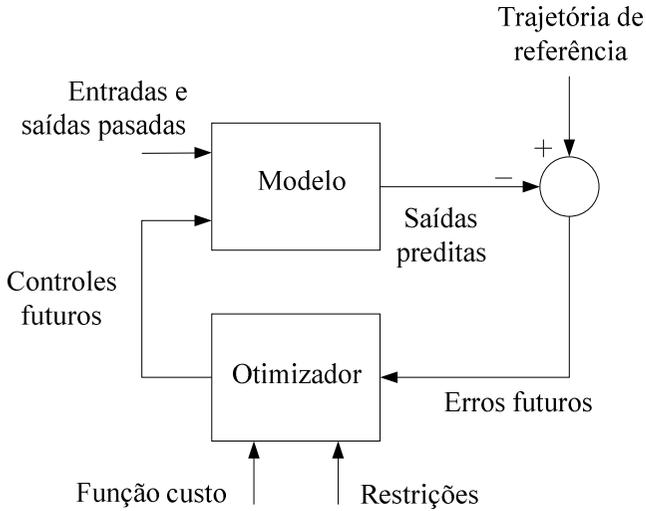
#### 2.2. CONTROLE PREDITIVO BASEADO NO MODELO

O controle preditivo baseado no modelo é uma estratégia de controle que oferece soluções atrativas implementadas com êxito na indústria para a regulação de sistemas multivariáveis lineares e não lineares com restrições. A razão para o êxito dos algoritmos MPC consiste, principalmente, na maneira natural de direcionar o problema de controle. Em comparação com o controle convencional, que utiliza uma lei de controle previamente calculada, o controle preditivo é construído com base nos seguintes princípios: uso explícito do modelo do processo para o cálculo *on-line* do comportamento futuro da planta; o cálculo de uma seqüência de controle por meio da otimização de uma função custo com restrições e a estratégia de horizonte deslizante.

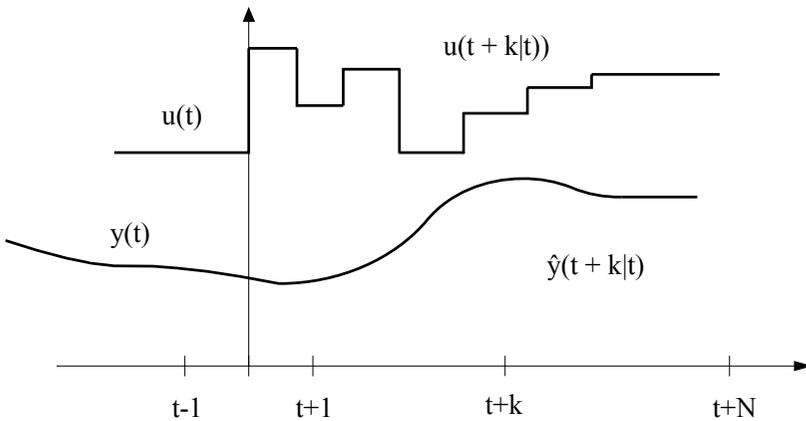
##### 2.2.1. METODOLOGIA DO MPC

A metodologia de todos os controladores pertencentes à família do MPC é caracterizada pela estrutura mostrada na Figura 2.1 e à estratégia representada na Figura 2.2. Em cada instante  $t$ , e fazendo uso do modelo do processo, se predizem as saídas futuras para um determinado horizonte  $N$ , chamado horizonte de predição. Estas saídas preditas,  $\hat{y}(t + k|t)$  (a notação indica o valor predito da variável no instante  $t+k$  calculado no instante  $t$ ), para  $k=\{1..N\}$ , dependem dos valores conhecidos até o instante  $t$  (entradas e saídas passadas) e dos sinais de controle em  $t+k$ , calculadas em  $t$ ,  $u(t + k|t)$  para  $k=\{0..N-1\}$ , que serão enviadas ao sistema e que se desejam determinar.

O critério normalmente considera uma função quadrática dos erros entre a saída predita e a trajetória de referência, incluindo, em muitos casos, o esforço de controle. Se o critério for quadrático, o modelo linear, e não existirem restrições, pode-se obter uma solução explícita; em outro caso deve-se usar um método iterativo de otimização.



**Figura 2.1:** Estrutura do MPC.



**Figura 2.2:** Estratégia de controle do MPC.

Adicionalmente, se faz alguma hipótese sobre a estrutura da lei de controle futura, como, por exemplo, que seja constante a partir de certo instante.

O sinal de controle  $u(t|t)$  é enviado ao processo enquanto os seguintes sinais de controle calculados são desprezados, posto que no seguinte instante de amostragem se conhece  $y(t+1)$  e se repete o passo anterior com este novo valor e todas as sequências atualizadas. Calcula-se, portanto,  $u(t+1|t+1)$  (que em princípio será diferente a  $u(t+1|t)$ ) fazendo uso do conceito de horizonte deslizante.

### 2.2.2. CONTROLE PREDITIVO GENERALIZADO

A técnica GPC é apoiada no uso de modelos derivados de funções de transferência (matrizes de transferência no caso multivariável). O algoritmo GPC calcula as previsões da saída da planta usando um preditor ótimo que permite encontrar o valor esperado da saída, como função dos controles futuros a partir de um modelo CARIMA (*Controlled Auto-Regressive Integrated Moving-Average*), tal como mostra a eq.(2.1).

$$A(z^{-1})y(t)=z^{-d}B(z^{-1})u(t-1)+D(z^{-1})v(t)+T(z^{-1})\frac{e(t)}{\Delta}, \quad (2.1)$$

onde  $u(t)$  e  $y(t)$  são a entrada e a saída respectivamente,  $v(t)$  é uma perturbação medida,  $d$  é o atraso em períodos de amostragem,  $e(t)$  é um ruído branco de média nula e  $\Delta=(1-z^{-1})$ .  $A$ ,  $B$ ,  $T$  e  $D$  são polinômios com operador de deslocamento para trás,  $z^{-1}$ , tal que

$$\begin{aligned} A(z^{-1}) &= 1 + a_1 z^{-1} + a_2 z^{-2} + \dots + a_n z^{-na}, \\ B(z^{-1}) &= b_0 + b_1 z^{-1} + b_2 z^{-2} + \dots + b_n z^{-nb}, \\ T(z^{-1}) &= 1 + c_1 z^{-1} + c_2 z^{-2} + \dots + c_n z^{-nc}, \\ D(z^{-1}) &= d_0 + d_1 z^{-1} + d_2 z^{-2} + \dots + d_n z^{-na}. \end{aligned} \quad (2.2)$$

Como função custo o GPC utiliza a seguinte expressão:

$$J(N_1, N_2, N_u) = \sum_{j=N_1}^{N_2} [\hat{y}(t+j|t) - w(t+j)]^2 + \lambda \sum_{j=1}^{N_u} [\Delta u(t+j-1)]^2 \quad (2.3)$$

onde  $w(t+j)$  é a referência,  $N_1$  e  $N_2$  definem a janela de previsão,  $N_u$  é o

horizonte de controle e  $\lambda$  é a ponderação do controle. Os parâmetros de ajuste do controlador são  $N_1$ ,  $N_2$ ,  $N_u$  e  $\lambda$ . Normalmente  $N_1$ ,  $N_2$  e  $N_u$  são escolhidos de acordo com as características do modelo dinâmico da planta e  $\lambda$  é usado para obter um controle mais ou menos suave.

As previsões são calculadas por meio do modelo da planta (eq.(2.1)) fazendo  $E\{e(t+j) = 0\}$ , assim se obtém:

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{f}', \quad (2.4)$$

Onde

$$\mathbf{f}' = \mathbf{H}\mathbf{v} + \mathbf{f}, \quad (2.5)$$

e  $\hat{\mathbf{y}}$  é um vetor que contém as saídas futuras do sistema, tal que

$$\hat{\mathbf{y}} = [\hat{y}(t+N_1|t) \ \hat{y}(t+N_1+1|t) \dots \hat{y}(t+N_2|t)], \quad (2.6)$$

e  $\mathbf{u}$  é um vetor que contém os incrementos de controle futuros, tal que

$$\mathbf{u} = [\Delta u(t) \ \Delta u(t+1) \dots \Delta u(t+N_u-1)], \quad (2.7)$$

onde  $\mathbf{f}$  é a resposta livre obtida fazendo zero o incremento de controle futuro,  $\mathbf{G}$  é a matriz que se pode calcular como a resposta da planta, quando se aplica um degrau unitário na variável manipulada, e  $\mathbf{H}$  é uma matriz definida como:

$$\mathbf{H} = \sum_{i=1}^j h_i z^{-i}, \quad (2.8)$$

onde  $h_i$  são os coeficientes da resposta do sistema a um degrau na perturbação medida (Camacho & Bordons, 2004).

Considerando  $\lambda$  constante, a expressão da função custo pode ser escrita como:

$$\mathbf{J} = (\mathbf{G}\mathbf{u} + \mathbf{f}' - \mathbf{w})^T (\mathbf{G}\mathbf{u} + \mathbf{f}' - \mathbf{w}) + \lambda \mathbf{u}^T \mathbf{u}, \quad (2.9)$$

e em forma quadrática:

$$\mathbf{J} = \frac{1}{2} \mathbf{u}^T \mathbf{L}\mathbf{u} + \mathbf{b}^T \mathbf{u} + f_0, \quad (2.10)$$

onde:

$$\begin{aligned}
\mathbf{L} &= 2(\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I}) \\
\mathbf{b}^T &= 2(\mathbf{f}' - \mathbf{w})^T \mathbf{G} \\
\mathbf{f}_0 &= (\mathbf{f}' - \mathbf{w})^T (\mathbf{f}' - \mathbf{w}).
\end{aligned} \tag{2.11}$$

O mínimo de  $J$  pode ser calculado, quando não há restrições, igualando a gradiente de  $J$  a zero, obtendo-se:

$$\mathbf{u} = (\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T (\mathbf{w} - \mathbf{f}'). \tag{2.12}$$

Como o algoritmo é de horizonte deslizante, unicamente o primeiro sinal será aplicado. A lei de controle fica então:

$$\Delta u(t) = \mathbf{K}(\mathbf{w} - \mathbf{f}'), \tag{2.13}$$

sendo  $\mathbf{K}$  a primeira linha da matriz  $(\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T$ .

Em relação ao polinômio  $T$  (eq.(2.1)), que possui este preditor em sua forma original, e que representa a característica estocástica dos distúrbios, tem mostrado um importante efeito na robustez de malha fechada (Camacho & Bordons, 2004). Este polinômio é usado normalmente para projetar parâmetros num segundo passo do procedimento de ajuste para melhorar a robustez do controlador.

### 2.2.2.1. PARÂMETROS DE SINTONIA

Como descrito anteriormente,  $\lambda$  e os horizontes de predição e controle são parâmetros de sintonia. Os valores de  $N_1$ ,  $N_2$  e  $N_u$  têm uma interpretação clara já que definem os instantes onde se espera que a referência siga à saída e onde é importante limitar a ação do controle. Assim, se, por exemplo,  $N_1$  é grande implica que não é importante o erro cometido nos primeiros  $N_1-1$  instantes e a resposta obtida será suave. No caso particular de sistemas com atraso de valor  $d$  é lógico escolher  $N_1 > d$  já que não haverá resposta do sistema à entrada  $u(t)$  até o tempo  $t=d$ . Uma regra para determinar  $N_2$ , o horizonte de predição, é aproximá-lo ao tempo de subida do sistema. Variando  $N_u$  é possível penalizar durante mais ou menos tempo a ação do controle. O coeficiente  $\lambda$  é a seqüência de ponderação do esforço de controle e geralmente é escolhida constante ou exponencial ao longo do horizonte. Valores grandes deste parâmetro permitem um esforço pequeno do

controle; para valores pequenos a resposta do sistema será rápida, porque o controlador tende a minimizar o erro entre a saída e a referência, aumentando o esforço do controle.

Em Bordons & Camacho (1998) apresenta-se uma formulação do GPC para uma ampla gama de processos industriais, considerando modelos de primeira ordem com tempo morto. Demonstra-se neste trabalho que os parâmetros que afetam o controlador, e então os pólos de malha fechada, dependem dos valores de  $\lambda$ . Também se conclui que se o GPC é projetado considerando que a planta tem ganho estático unitário, a penalização do controle deverá ser corrigida para manter o comportamento desejado, quando o sistema apresentar diferentes ganhos estáticos.

Se dois processos têm a mesma dinâmica e diferente ganho estático e se deseja ponderar o esforço de controle da mesma forma nos dois casos, deve-se usar uma relação quadrática entre as ponderações. Isto pode ser comprovado considerando dois sistemas, o Sistema 1 com ganho estático  $ke_1$  e o Sistema 2 com ganho estático  $ke_2$ . Suas respectivas matrizes de resposta ao degrau  $G_1$  e  $G_2$  podem ser colocadas como:

$$\mathbf{G}_1 = ke_1 \mathbf{G} \quad \text{e} \quad \mathbf{G}_2 = ke_2 \mathbf{G}, \quad (2.14)$$

onde  $\mathbf{G}$  é a matriz de resposta ao degrau do sistema com ganho estático 1. Como no cálculo de  $J$  a matriz  $\mathbf{G}$  aparece de forma quadrática ( $\mathbf{G}^T \mathbf{G}$ ) o efeito do ganho  $ke_i$  também é quadrático. Assim, para manter a relação entre  $\lambda$  e a ponderação do erro de forma uniforme nos dois sistemas, deve-se utilizar a relação dada pela equação (2.15) para  $\lambda_1$ .

$$\lambda_1 = (ke_2 / ke_1)^2 \lambda_2. \quad (2.15)$$

Esta idéia permite trabalhar com uma ponderação do esforço de controle normalizada que altera o comportamento em malha fechada do sistema de forma uniforme. Mesmo que este ajuste de  $\lambda$ , a partir do ganho estático da planta, não garanta que as respostas transitórias de malha fechada terão sempre as mesmas características, ele permite uniformizar as respostas, se comparado ao controle que não usa esta proposta. Como se verá nos exemplos apresentados nas próximas seções, os resultados são satisfatórios em todos os casos estudados.

Finalmente, em relação ao ajuste dos parâmetros do filtro  $T$  foram propostos na literatura vários métodos (Robinson & Clarke, 1991; Yoon & Clarke, 1995). No entanto, é amplamente conhecido que a

seleção dos parâmetros deste filtro não é simples, especialmente no caso de processos com tempo morto.

### 2.2.2.2. RESTRIÇÕES

Na prática todos os processos estão sujeitos a restrições. Os atuadores têm uma faixa de operação limitada e um tempo de resposta limitado, como no caso das válvulas de controle que ficam limitadas pela abertura máxima e mínima e também pelo tempo de resposta. As razões de segurança e limites nos sensores causam restrições nas variáveis dos processos como é o caso dos níveis nos tanques, vazão nas tubulações e pressão nos depósitos. Além disso, na prática, os pontos de operação das plantas estão determinados para satisfazer objetivos econômicos, conduzindo o sistema a operar perto dos limites e de violar as restrições.

O sistema de controle deve antecipar-se à violação das restrições e corrigi-las de maneira apropriada. Embora as restrições da entrada e da saída sejam tratadas basicamente da mesma forma, as implicações das restrições diferem. As restrições da saída são devidas, principalmente, a razões de segurança e devem ser controladas com antecipação, porque as variáveis de saída são afetadas pela dinâmica do processo. As variáveis da entrada, ou manipuladas, podem sempre ser mantidas no limite pelo controlador, limitando a ação do controle a valores que satisfaçam as restrições do esforço de controle.

As restrições impostas pelo processo podem ser resultado de limites na amplitude dos sinais de controle ( $U_{\min}$ ,  $U_{\max}$ ), limites nos incrementos dos sinais de controle ( $u_{\min}$ ,  $u_{\max}$ ) e limites nos sinais de saída ( $y_{\min}$ ,  $y_{\max}$ ). Para um processo de m-entradas, n-saídas e atuando em um horizonte deslizante N, essas restrições podem ser expressas como:

$$\begin{aligned} \mathbf{I}U_{\min} &\leq \mathbf{\Gamma} \mathbf{u} + \mathbf{u}(t-1)\mathbf{I} \leq \mathbf{I}U_{\max} \\ \mathbf{I}u_{\min} &\leq \mathbf{u} \leq \mathbf{I}u_{\max} \\ \mathbf{I}y_{\min} &\leq \mathbf{G}\mathbf{u} + \mathbf{f}' \leq \mathbf{I}y_{\max}, \end{aligned} \quad (2.16)$$

onde  $\mathbf{I}$  é uma matriz  $(N \times m) \times n$  formada por N matrizes identidade  $m \times m$ ,  $\mathbf{\Gamma}$  é uma matriz bloco triangular inferior cujos blocos não nulos são matrizes identidade  $m \times m$ . Essas restrições podem ser expressas de uma forma condensada como:

$$\mathbf{R}\mathbf{u} = \mathbf{c}, \quad (2.17)$$

onde  $\mathbf{R}$  e  $\mathbf{c}$  estão definidas pelas seguintes relações:

$$\mathbf{R} = \begin{bmatrix} \mathbf{I}_{N \times N} \\ -\mathbf{I}_{N \times N} \\ \mathbf{\Gamma} \\ -\mathbf{\Gamma} \\ \mathbf{G} \\ -\mathbf{G} \end{bmatrix} \quad \mathbf{c} = \begin{bmatrix} \mathbf{I}\mathbf{u}_{\max} \\ -\mathbf{I}\mathbf{u}_{\min} \\ \mathbf{I}\mathbf{U}_{\max} - \mathbf{I}\mathbf{u}(t-1) \\ -\mathbf{I}\mathbf{U}_{\min} + \mathbf{I}\mathbf{u}(t-1) \\ \mathbf{I}\mathbf{y}_{\max} - \mathbf{f}' \\ -\mathbf{I}\mathbf{y}_{\min} + \mathbf{f}' \end{bmatrix}. \quad (2.18)$$

O problema de otimização do MPC passa a ser definido como:

$$\begin{aligned} & \min \mathbf{J} \\ & \text{s.a.}^1 \\ & \mathbf{R}\mathbf{u} \leq \mathbf{c}. \end{aligned} \quad (2.19)$$

Assim, o algoritmo GPC, levando-se em conta as restrições, consiste na minimização de uma função custo quadrática sujeita ao cumprimento de restrições lineares. Isto se traduz na otimização de uma função quadrática com restrições lineares, conhecido comumente como um problema de QP e que deve ser resolvido através de métodos numéricos (Camacho & Bordons, 2004).

### 2.3. CONTROLADOR DTC-GPC

O controle preditivo MPC possui um tratamento intrínseco do tempo morto, tornando-o atrativo para lidar com este problema, além de possuir outras vantagens já citadas. No entanto os problemas de robustez causados por erros na estimativa do tempo morto não são devidamente cobertos por este tipo de controladores. Incertezas no tempo morto são uma das mais típicas dinâmicas não modeladas de alta frequência e tem uma influência perigosa na estabilidade de malha fechada.

Uma das técnicas que vem sendo estudada utilizando GPC (Normey-Rico & Camacho, 2007) é o controlador denominado DTC-

---

<sup>1</sup> s.a. : sujeito a

GPC que tem várias vantagens comparadas ao GPC tradicional: i) Tem o mesmo desempenho nominal que o GPC; ii) O projeto do filtro para melhorar a robustez no DTC-GPC é mais simples que o procedimento normal usado no GPC e permite um maior índice de robustez que o GPC baseado no preditor ótimo, com a mesma ordem do filtro; iii) O filtro não afeta o desempenho nominal para mudanças na referência; iv) O efeito do filtro sobre a resposta na rejeição das perturbações pode ser analisado de uma forma muito simples. Por exemplo, Normey-Rico & Camacho (2000) mostram que usando um preditor de Smith filtrado para computar a previsão até o tempo morto ao invés do preditor ótimo, o controlador resultante é mais robusto e fácil de sintonizar que a tradicional solução do GPC. Este controlador chamado *Smith Predictor Generalized Predictive Controller* (SP-GPC) é um caso particular do DTC-GPC, pois só se tem aplicado em plantas estáveis em malha aberta, mas tem mostrado várias vantagens em comparação com o tradicional GPC (Normey-Rico & Camacho, 2007).

Assim como a técnica de controle tradicional do GPC, o algoritmo DTC-GPC consiste em aplicar uma sequência de controle que minimiza a função custo (eq.(2.3)). Nesta equação, a previsão no tempo  $j$  do sistema, até o tempo  $t$ ,  $\hat{y}(k+j|t)$ , é calculada usando o seguinte modelo incremental da planta:

$$\Delta A(z^{-1})y(t) = z^{-d}B(z^{-1})\Delta u(t-1), \quad (2.20)$$

com uma função das previsões até  $t+d$ . As previsões da saída da planta até  $t+d$  são calculadas usando a estrutura FSP, como mostra a Figura 2.3, onde  $S(z^{-1})=G_n(z^{-1})[1-F_r(z^{-1})z^{-d}]$  é o parâmetro de sintonia e  $G_n(z^{-1})=z^{-1}B(z^{-1})/A(z^{-1})$  é o modelo do processo, livre de tempo morto. A previsão pode ser escrita numa forma compacta como:

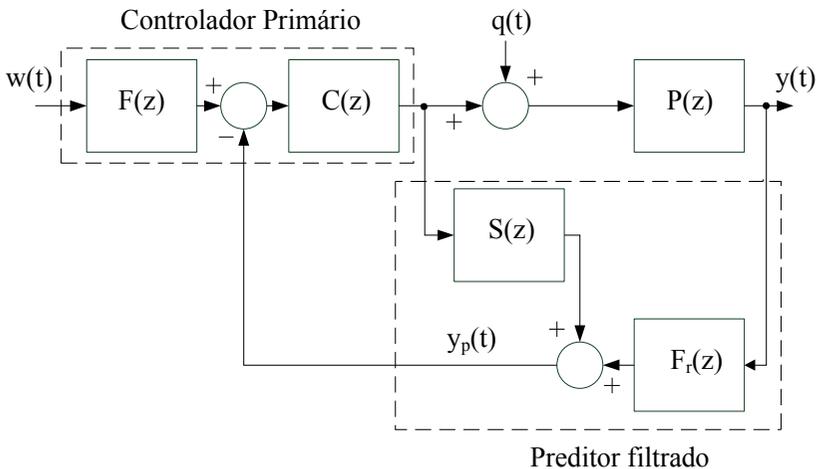
$$\hat{y}(k+d|t) = S(z^{-1})u(t) + F_r(z^{-1})y(t). \quad (2.21)$$

Assim, no caso sem restrições, este esquema é um compensador linear de tempo morto equivalente ao FSP, onde o controlador primário é sintonizado usando um procedimento de otimização. Conforme mostrado em Normey-Rico & Camacho (2007), a sintonia do filtro pode ser usada para melhorar a robustez de malha fechada e também para permitir o uso do controlador em processos com tempo morto instáveis. Observe que, quando o modelo de processo é instável,  $S(z^{-1})$  deve ser implementado com uma função de transferência estável (Normey-Rico

& Camacho, 2007). A estrutura anterior é útil para a análise e, na prática, a lei de controle pode ser calculada utilizando a resposta ao degrau e a resposta livre do sistema, como no algoritmo GPC (Clarke & Mohtadi, 1989). Neste caso, a predição é considerada como:

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{f}_r, \quad (2.22)$$

onde a resposta livre,  $\mathbf{f}_r$ , é calculada da seguinte forma. De  $t+1$  a  $t+d$ ,  $\mathbf{f}_r$  é calculada utilizando a estrutura FSP e, a partir  $t+d+1$  até  $t+N_2$  é calculada utilizando o procedimento normal do GPC.



**Figura 2.3:** DTC-GPC para caso sem restrições.

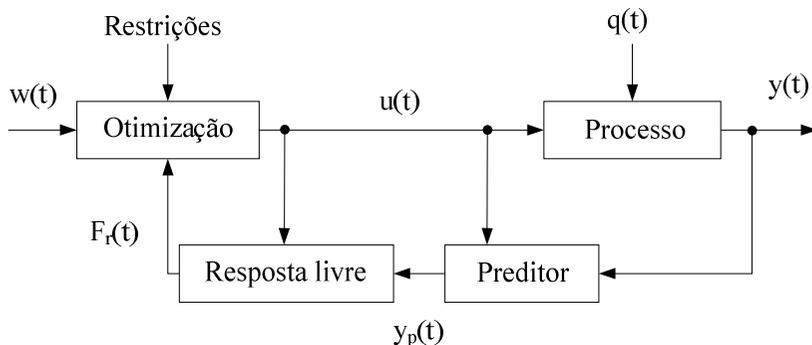
No caso sem restrições, os dois passos seguintes podem ser usados para ajustar o controlador DTC-GPC (Normey-Rico & Camacho, 2008b):

- Calcular os horizontes e os fatores de ponderação para atingir o desempenho desejado para a planta nominal, ante uma mudança no *set-point*.
- Estimar as incertezas da planta e sintonizar o filtro  $F_r(z)$  para um melhor compromisso entre robustez e desempenho, na rejeição dos distúrbios.

Para melhorar a robustez, este algoritmo oferece regras de ajuste mais simples em relação a métodos tradicionalmente utilizados de ajuste do T-polinomial do GPC (Normey-Rico & Camacho, 2000).

No caso com restrições, o efeito da estrutura do preditor do controlador pode ser interpretado usando o esquema na Figura 2.4. Como observado nesta figura, o preditor proposto no DTC-GPC só afeta o cálculo da resposta livre. A influência da estrutura de compensação do tempo morto no controlador é qualitativamente a mesma do caso sem restrições. Note que, se a solução do DTC-GPC não viola qualquer restrição nas proximidades do ponto de operação do processo, as propriedades do preditor e ajuste podem ser analisados usando o sistema de função de transferência de malha fechada.

Considerando a melhora na robustez que oferece esta configuração DTC-GPC para processos com tempo morto dominante, contempla-se neste trabalho o desenvolvimento do algoritmo de controle de plantas não lineares usando como base o DTC-GPC.



**Figura 2.4:** Estrutura do MPC para o caso com restrições.

## 2.4. SUMÁRIO

Neste capítulo, os fundamentos conceituais do controle preditivo baseado em modelo foram apresentados. Em particular detalhou-se o procedimento matemático para dois controladores lineares: o GPC e ou DTC-GPC, apresentando seus parâmetros de sintonia e alguns critérios para sua seleção, assim como a análise do procedimento para o tratamento de restrições.

O uso do controle DTC-GPC, como base de controle preditivo linear, se justifica pela melhor robustez e facilidade de sintonia apresentada por este algoritmo para sistemas com atraso comumente encontrado em meios industriais. Já os problemas de tratamento de restrições, como se verá nos próximos capítulos, serão sempre transformados em problemas de programação quadrática com modelos lineares que podem ser resolvidos através de métodos numéricos, muito eficientes e rápidos.

## **CAPÍTULO 3**

### **FILOSOFIA E METODOLOGIA DE PROJETO**

#### **3.1. INTRODUÇÃO**

Neste capítulo, a nova estratégia de MPC que combina idéias de algoritmos NMPC baseados em modelos locais e a estratégia de compensador de tempo morto, são apresentados. O algoritmo proposto usa apenas um MPC linear, mas as predições e a sintonia são atualizadas quando detectada alguma mudança na operação do processo. O algoritmo melhora, principalmente, os resultados obtidos com estratégias prévias porque simplifica a seleção do modelo e dá mais uniformidade no desempenho em toda a faixa de operação do processo a um custo computacional baixo. A técnica empregada considera especificamente os efeitos do tempo morto no processo sobre o desempenho e robustez.

A filosofia da nova proposta é apresentada, inicialmente, explicando em detalhes como se obtêm os modelos para as predições e como é realizada a sintonia do DTC-GPC, em relação à penalização do controle. Apresentam-se alguns exemplos para esclarecer os fundamentos da proposta e compara-se com outros métodos de modelos locais existentes. Na mesma seção, propõe-se um procedimento sistemático do projeto do controlador. Finalmente apresentam-se as conclusões do capítulo.

#### **3.2. ALGORITMO DE CONTROLE**

O algoritmo de controle proposto usa um único MPC linear, mas as predições e sintonia são atualizadas quando detectadas mudanças na operação do processo. São utilizadas duas idéias principais: (i) a computação de um modelo linear dinâmico da planta para ser utilizado no DTC-GPC, na região de operação atual e (ii) a penalização de controle e o filtro de robustez são adaptados usando o ganho equivalente variável do processo e o atraso do modelo linear obtido, respectivamente. O algoritmo melhora os resultados obtidos com estratégias prévias, baseadas em modelos locais, principalmente porque simplifica a seleção do modelo e dá um desempenho mais uniforme em toda a faixa de operação do processo. Além disso, considera especificamente os efeitos do tempo morto do processo sobre o desempenho e robustez.

A Figura 3.1 representa de forma esquematizada o algoritmo proposto. O controlador é baseado em um único DTC-GPC linear mais um algoritmo de modelo de predição e ajuste adaptativos (MPAA).

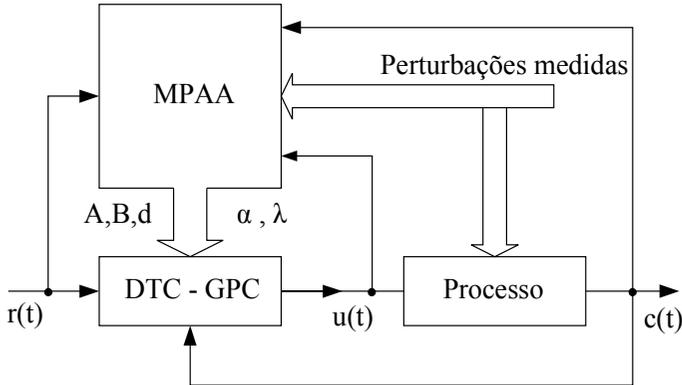


Figura 3.1: Esquema geral de controle.

A idéia principal é simples: o bloco MPAA calcula um modelo linear  $(A(z^{-1})y(t) = B(z^{-1})u(t-d)$  onde  $A$ ,  $B$  são polinômios e  $d$  é o tempo morto) e dois parâmetros de sintonia principais  $\alpha$  e  $\lambda$  para serem usados no DTC-GPC;  $\alpha$  é a o pólo do filtro de robustez  $F_r(z) = (1-\alpha)/(z-\alpha)$  e  $\lambda$  a penalização do controle. Estes parâmetros são atualizados de acordo com as condições de operação da planta. Assim como em outros controladores baseados em modelos locais, o algoritmo assume que o modelo não-linear da planta é conhecido e validado; este modelo não-linear é parte do bloco MPAA como será explicado depois. O modelo linear é computado usando esse modelo não-linear e só é atualizado quando sucede uma mudança no ponto de operação da planta ou quando a planta se estabelece num novo ponto de operação. Como será comprovado mais adiante, este enfoque é especialmente apropriado para o controle de processos não-lineares que são freqüentemente submetidos a mudanças na referência.

Como o modelo é linear, não é preciso o processo de otimização não-linear. Para completar a sintonia adaptativa, são atualizadas a penalização de controle e a constante de robustez do filtro do DTC-GPC, em concordância com o ganho e o tempo morto do modelo local calculado. Isto permite um comportamento dinâmico robusto similar em toda faixa de operação da planta.

A metodologia tem dois passos, um procedimento *off-line* usado para definir alguns parâmetros e modelos para a aplicação do algoritmo, e um segundo procedimento *on-line* que é responsável pelo cálculo do modelo do preditor e parâmetros de ajuste do DTC-GPC. Esta metodologia é uma proposta inovadora do autor deste trabalho.

### 3.2.1. CONFIGURAÇÃO OFF-LINE

O primeiro passo para configurar o controlador, é realizar o seguinte procedimento *off-line* que fornece os dados para a operação *on-line* do controlador:

Passo 1. Defina a faixa de operação da planta e restrições no controle e saída (caso existam).

Passo 2. A partir do MNL da planta, obtenha a curva característica estática (CCE) do processo na sua faixa de operação. Compute também um modelo estático inverso (MEI) da planta; este modelo pode ser obtido analiticamente (se for possível) a partir do MNL, ou por aproximação polinomial dos dados obtidos da curva característica estática, ou simplesmente por tabela no caso de conhecer previamente os pontos de operação a serem atingidos.

Passo 3. Defina um conjunto de pontos de operação na faixa de operação do processo, escolhendo-os na faixa onde a curva característica estática tem mudanças apreciáveis de inclinação.

Passo 4. Simulando o MNL, realize a prova do degrau em cada ponto de operação, definido no passo três, para levar à saída desde este PO ao próximo e determine o tempo de acomodação, o tempo morto e o ganho estático. Use o tempo de acomodação menor para calcular o tempo de amostragem e o tempo de acomodação maior para determinar um horizonte de predição. No caso do sistema não linear apresentar tempo morto variável, realize novas medições deste parâmetro em toda a faixa de operação da planta de tal forma a determinar um valor médio das medidas feitas e se calculem, caso seja possível, os valores máximos de erro da estimativa do tempo morto.

Passo 5. Usando os dados obtidos no passo prévio, determine o tempo morto e os polinômios A e B dos modelos lineares a serem utilizados no ajuste do controlador preditivo no passo seguinte (os coeficientes A e B são obtidos usando o método de mínimos quadrados). Vários testes de simulação realizados com diferentes modelos não lineares têm mostrado que é possível obter uma aproximação aceitável usando um modelo de

quarta ordem (Ljung, 1987) ainda que o processo exiba altas não linearidades e dinâmicas complexas. Em geral é possível usar modelos de primeira ordem com bons resultados.

Passo 6. Ajuste o DTC-GPC em cada PO de tal forma que o comportamento em cada um deles ao atingir o próximo PO seja o desejado, mantendo um mesmo critério e satisfazendo um compromisso entre a robustez e o desempenho. Este ajuste é feito usando as recomendações em Camacho & Bordons (2004) e simulações com o MNL. Anote os parâmetros de sintonia (horizontes  $N$  e  $N_u$ , ponderação  $\lambda$ , e ajuste do filtro  $\alpha$ ) do DTC-GPC para cada PO.

Passo 7. Ajuste uma relação quadrática entre os ganhos estáticos dos modelos ( $K_e$ ) obtidos no passo 4 e as penalizações de controle obtidas no passo 6 ( $\lambda$ ) para cada PO. Esta relação, que tem uma expressão geral  $\lambda = \lambda_n K_i^2$  será utilizada num procedimento de adaptação *on-line* para definir  $\lambda$  em cada situação de operação, com o objetivo de manter um comportamento transitório de malha fechada, que é aproximadamente definida pelo peso normalizado  $\lambda_n$  (Normey-Rico & Camacho, 2007).

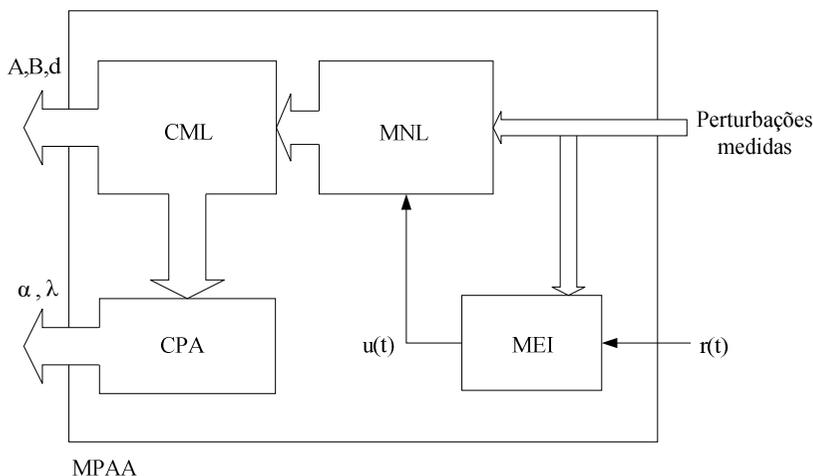
Os dados obtidos nestes 7 (sete) passos são usados como ponto de partida para a inicialização da operação do controlador adaptativo *on-line*.

### 3.2.2. OPERAÇÃO ON-LINE DO CONTROLADOR

A operação *on-line* do controlador, como já foi exposta anteriormente, é baseada em dois aspectos: (i) a computação de um modelo linear dinâmico da planta para ser utilizado no DTC-GPC na região de operação atual e (ii) o uso do ganho e tempo morto do modelo linear obtido para sintonizar o DTC-GPC. O esquema detalhado do algoritmo MPAA é mostrado na Figura 3.2.

O MPAA inclui quatro blocos: o bloco do modelo não linear (MNL) da planta, usado para simular o comportamento do processo real; o bloco do modelo estático inverso (MEI), usado para calcular a ação do controle do ponto de operação a ser atingido, um bloco para o cálculo do modelo local (CML), usado para obter o modelo do preditor linear e um bloco de cálculo dos parâmetros de ajuste (CPA) que calcula a penalização de controle e determina o filtro do DTC-GPC. Observe que o bloco MNL utiliza todas as perturbações medíveis para o cálculo das predições da saída da planta.

A técnica de cálculo do modelo é aplicada em dois casos, um modelo local obtido para o caso de rejeição das perturbações e outro



**Figura 3.2:** Esquema detalhado do algoritmo MPAA.

modelo calculado para o caso de mudanças na referência. No primeiro caso, quando o processo está operando perto de um PO dado, o modelo local é obtido com um procedimento típico usado na teoria de identificação: um sinal adequado de teste é aplicado na entrada do MNL e logo são calculados os coeficientes de um modelo linear com o algoritmo de estimação nomeado de mínimos quadrados (LSE, *Least Squares Estimator*). Este tipo de aproximação é usado normalmente no MPC quando a saída é mantida na banda pré definida, perto do PO (Camacho & Bordons, 2004). Não obstante, este modelo não pode ser utilizado para apreciáveis mudanças na referência. Neste segundo caso, a idéia é obter um modelo linear melhor que capture o comportamento em malha aberta do MNL ( $Y$ ) quando um degrau é aplicado na entrada do processo ( $U$ ) para guiá-lo do PO atual  $OP_i$  ( $[U_i, Y_i]$ ) ao PO desejado  $OP_f$  ( $[U_f, Y_f]$ ). Este modelo é computado em um tempo de amostragem e para qualquer mudança na referência realizada pelo operador ou pelo sistema supervisor.

Os fundamentos deste procedimento de modelagem são dois: (i) mesmo usando um modelo de baixa ordem, o modelo linear obtido por este procedimento aproxima melhor o comportamento não-linear do processo do que qualquer modelo local calculado usando apenas informação no  $OP_i$ ; (ii) os resultados obtidos são tão bons e com menos esforço computacional comparados aos métodos que usam

procedimentos iterativos ou linearizações ao longo da trajetória para obter o modelo linear.

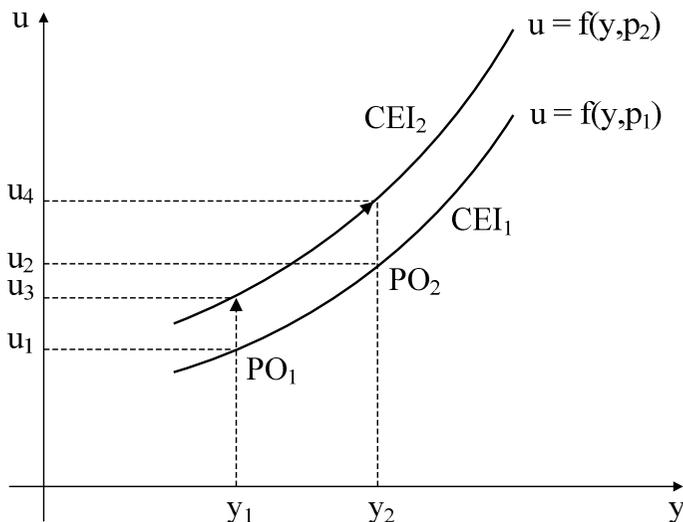
O procedimento completo para obter o modelo é como segue: Primeiro, a amplitude da ação de controle ( $U_f$ ) requerida para guiar o MNL (que representa o processo) para OPf é obtido usando o modelo estático inverso da planta e todas as perturbações medíveis. A seguir, um degrau de amplitude  $u = U_f - U_i$  é aplicado na entrada do MNL do processo para obter a evolução da saída ( $Y$ ). Dos dados obtidos, usam-se os valores incrementais da entrada  $u$  e saída  $y = Y - Y_i$ , no bloco CML, para o cálculo dos polinômios A e B, usando o método de mínimos quadrados. Esta simulação é realizada usando uma janela de tempo que atinge o tempo de acomodação mais alto obtido no passo 4 do procedimento *off-line* definido anteriormente. Desta forma, o bloco CML entrega os coeficientes dos polinômios A e B e o tempo morto  $d$  para serem utilizados na predição do DTC-GPC para o controle do processo no trajeto entre OPi e OPf.

A informação do modelo, quer seja para perturbações ou para mudanças de referências, é usada também para sintonizar o DTC-GPC:  $\lambda$  é obtida usando o ganho estático do modelo atual  $K=B(1)/A(1)$ ;  $\alpha$  é sintonizado usando o tempo morto do modelo atual e o valor de  $\alpha$  obtido no passo 6 do procedimento *off-line*.

Observe que, na inicialização do controlador, o modelo usado no DTC-GPC é obtido usando o procedimento de modelagem para a rejeição das perturbações, perto do ponto de operação atual e é assumida a operação do processo neste PO, pelo menos alguns poucos minutos antes de mudar a referência.

As perturbações, que afetam a característica estática do processo a controlar, são tratadas aplicando o seguinte procedimento sobre a curva característica estática inversa (CEI) da planta para a obtenção do modelo linear dinâmico para mudanças na referência (ver Figura 3.3; aqui  $u$  é a entrada e  $y$  é a saída da planta). Com a planta operando, no  $PO_1(y_1, u_1)$  e existindo uma perturbação desconhecida ( $p_2$ ), a saída da planta se estabelece em  $y_1$ , como conseqüência da ação do controle  $u_3$ . Este valor do controle é então conhecido e faz parte, junto com  $y_1$ , de um ponto da curva característica estática inversa CEI<sub>2</sub>. O modelo estático inverso (MEI)  $u=f(y,p)$ , obtido no projeto do controlador, e que representa matematicamente a família de curvas estáticas com  $p$  como parâmetro, pode ser utilizada para determinar  $p_2$  mediante a solução da equação  $u_3=f(y_1, p_2)$ .

Conhecido  $p_2$  é possível determinar  $u_4$  para levar a variável controlada de  $y_1$  a  $y_2$ . Para isto, basta resolver  $u_4=f(y_2, p_2)$ . Com  $u_3$  e  $u_4$  conhecidos, se determina o  $\Delta u=u_4-u_3$  para a determinação do modelo linear da predição, segundo o procedimento apresentado na seção 3.2.2. Salienta-se que este procedimento é aplicável somente quando o restante das perturbações é conhecido. A idéia é escolher uma perturbação não medida que tenha uma importante incidência na característica estática do processo.



**Figura 3.3:** Curvas CEI e tratamento das perturbações.

Esta forma de calcular a variação do controle considera um conhecimento prévio da perturbação que está afetando o sistema, o que pode não ser simples de determinar em alguns casos. Assim, outra aproximação pode ser usada, e consiste em considerar que o efeito da perturbação que modificou a condição de operação será o mesmo sobre a curva  $CEI_1$  e  $CEI_2$ , assim se pode calcular aproximadamente  $u_4-u_3=u_2-u_1$ . Desta forma,  $u_1$  determina-se da  $CEI_1$  com o conhecimento de  $y_1$ , desconsiderando perturbações. Em seguida, calcula-se  $u_2$  para atingir o valor desejado, ainda sem perturbações, calcula-se  $\Delta u=u_2-u_1$  e se aplica no modelo não linear um controle  $u_4=u_3+\Delta u$  para determinar os dados para a modelagem.

Deste procedimento, e das características do controlador proposto, pode-se estabelecer que a nova proposta é aplicável a processos não lineares, com restrições, submetidos a mudanças de

referências em toda sua faixa de operação, com atrasos dominantes e incertos que operem em zonas de equilíbrio estáveis, causais e invariantes no tempo. Deve-se considerar que muitos processos industriais operam nestas condições do ponto de vista do controle preditivo dado que os MPCs têm uma função supervisora, atuando em modo cascata sobre um conjunto de controladores PID (Proporcional Integral Derivativo) que mantêm o processo em operação estável.

Para ilustrar as propriedades desta modelagem, apresentam-se a seguir dois casos de estudo: o primeiro corresponde a um sistema não linear com características dinâmicas complexas e distintas na sua faixa de operação (Lazar, 2001); o segundo é um CSTR (*Continuous Stirred Tank Reactor*), que apresenta variações apreciáveis de inclinação na sua curva característica estática (Gao *et al.*, 2002). Ambos são utilizados na literatura para o estudo de modelagem e controle de sistemas não lineares.

### 3.2.2.1. CASO DE ESTUDO 1: MODELO LAZAR

O modelo não linear deste sistema, do tipo SISO, mostra-se na eq.(3.1), sendo que  $u$  é a entrada e  $y$  é a saída (Lazar, 2001).

$$y(k) = \frac{2.5y(k-1)y(k-2)}{1+y(k-1)^2+y(k-2)^2} + 0.3\cos(0.5(y(k-1)+y(k-2))+1.2u(k-1)). \quad (3.1)$$

A Figura 3.4 mostra a saída do sistema em malha aberta para diferentes valores da entrada. Observa-se a dinâmica particular que apresenta este sistema, com tempos de acomodação diferentes e respostas subamortecidas e sobreamortecidas.

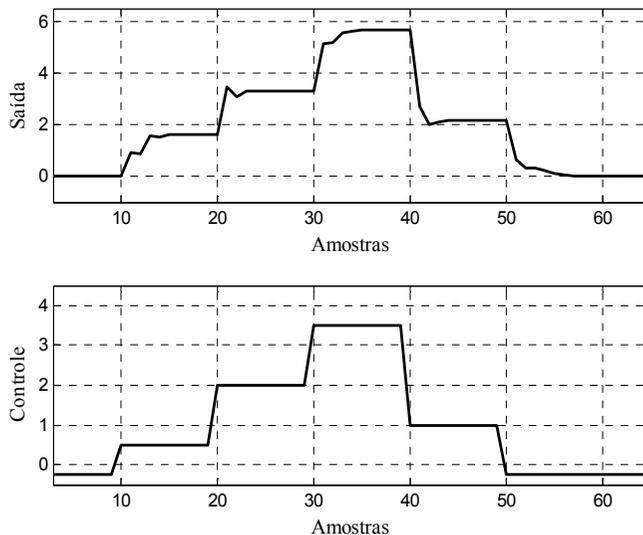
A Figura 3.5 mostra a característica estática do sistema a controlar. Observa-se nesta figura que o sistema apresenta uma não linearidade mais acentuada para valores do controle menores que 0.5.

A característica estática inversa do sistema determina-se, neste caso, diretamente da eq.(3.1). Fazendo  $y(k)=y(k-1)=y(k-2)=y_{eq}$  e  $u(k)=u_{eq}$ , se obtém a equação 3.2.

$$u_{eq} = \frac{-2.083y_{eq}^2}{1+2y_{eq}^2} + \frac{y_{eq} - 0.3\cos(y_{eq})}{1.2}. \quad (3.2)$$

Neste exemplo, deseja-se transferir a saída do sistema desde

0.000 até 1.347. Estes pontos são apresentados na Figura 3.6 e foram escolhidos pela mudança mais acentuada de inclinação da curva nesta faixa.



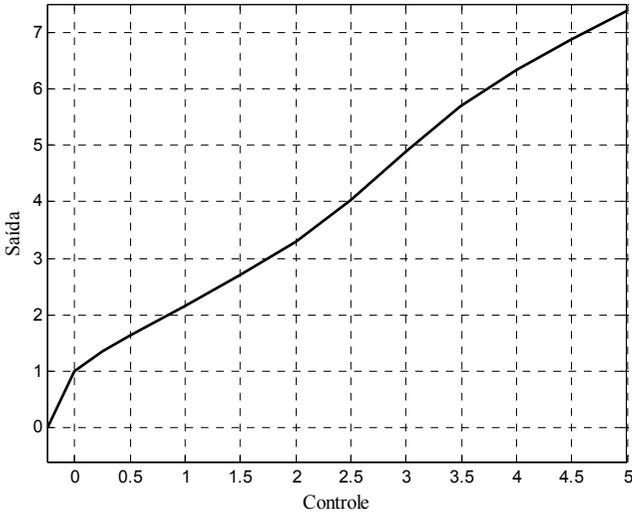
**Figura 3.4:** Entrada e saída em malha aberta do sistema representado pela eq.(3.1).

Neste exemplo, deseja-se transferir a saída do sistema desde 0.000 até 1.347. Estes pontos são apresentados na Figura 3.6 e foram escolhidos pela mudança mais acentuada de inclinação da curva nesta faixa.

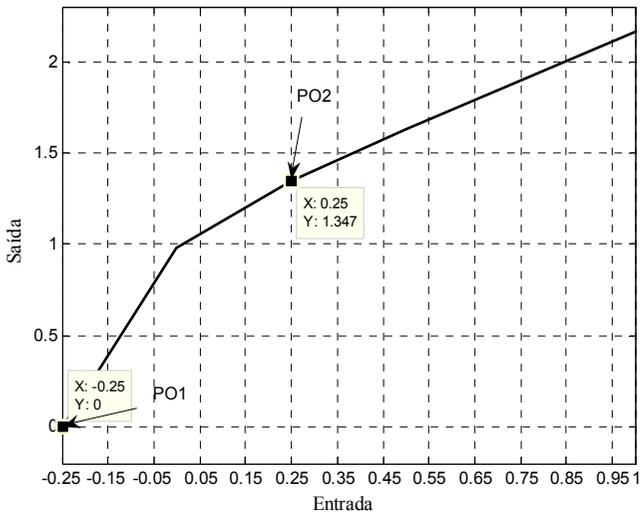
Mediante a eq.(3.2), determina-se o controle necessário para atingir a saída  $y_{eq}=1.347$ , o valor é  $u_{eq}=0.25$  e, portanto, o  $\Delta u$  para levar a planta a este novo PO é de 0.5. Deve-se entender que uma vez operando o algoritmo, o ponto de operação escolhido pode ser aleatório e o delta de controle deve ser determinado utilizando o modelo estático inverso do processo.

Aplicando o procedimento proposto de modelagem para mudanças na referência, determinam-se três modelos ARX (*Auto-regression with exogenous inputs*) de distintas ordens e comparam-se as saídas destes três modelos lineares com as saídas do MNL, utilizando como entrada o delta de controle calculado,  $\Delta u=0.5$  (ver Figuras 3.7, 3.8 e 3.9). Utiliza-se para o cálculo dos modelos uma rotina de estimação de

parâmetros do Matlab denominada *arx*, que determina modelos ARX pela técnica de mínimos quadrados. As ordens do modelo ARX são definidos como na (ordem do polinômio A), nb (ordem do polinômio B) e nk (atraso), onde um valor de nk=1 representa um sistema sem atraso.

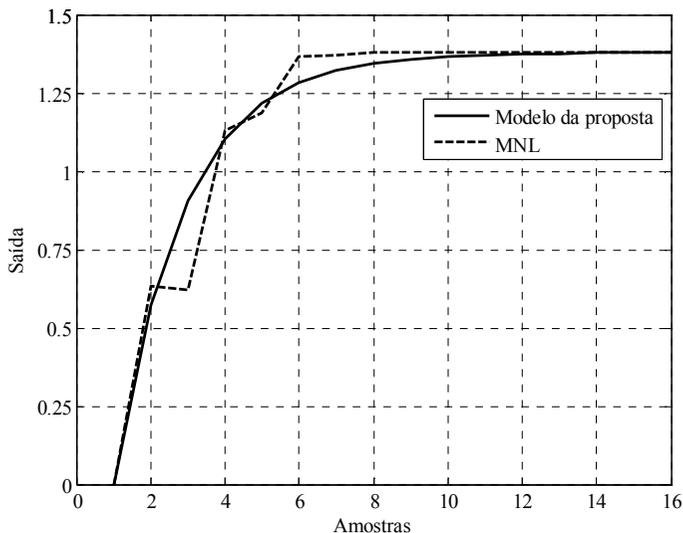


**Figura 3.5:** Curva característica estática do sistema.



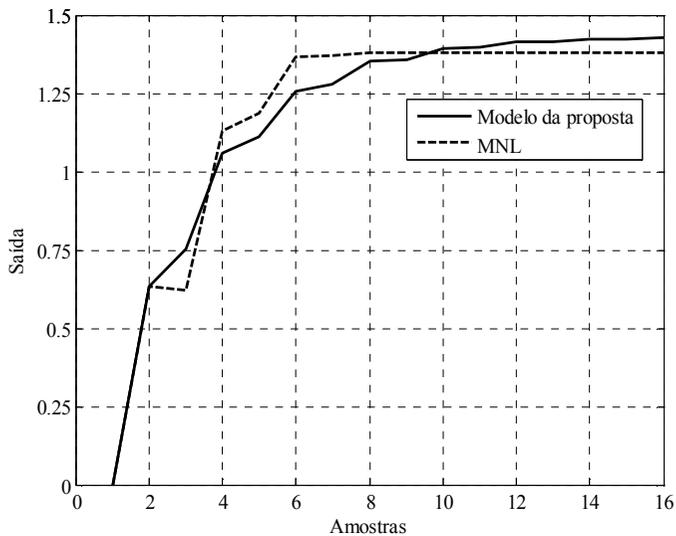
**Figura 3.6:** Curva característica estática do sistema e POs.

Modelo de 1<sup>a</sup> ordem:  $na=nb=nk=1$ ,  $A=1-0.5854z^{-1}$ ,  $B=1.0811$ .



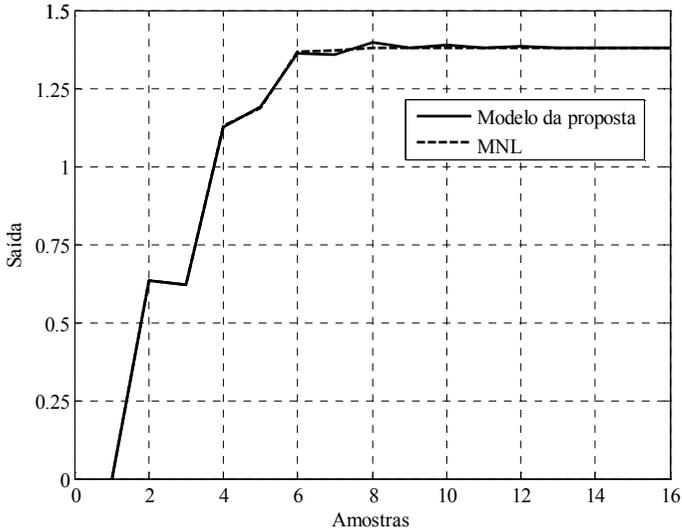
**Figura 3.7:** Saída do MNL e do modelo de primeira ordem da proposta.

Modelo de 2<sup>a</sup> ordem:  $A=1+0.0256z^{-1}-0.4880z^{-2}$ ,  $B=1.2+0.2559z^{-1}$ .



**Figura 3.8:** Saída do MNL e do modelo de segunda ordem da proposta.

Modelo de 3ª ordem:  $A=1-0.3235z^{-1}-0.2922z^{-2}+0.1530z^{-3}$ ,  $B=1.2-0.4165z^{-1}+0.6185z^{-2}$ .



**Figura 3.9:** Saída do MNL e do modelo de terceira ordem da proposta.

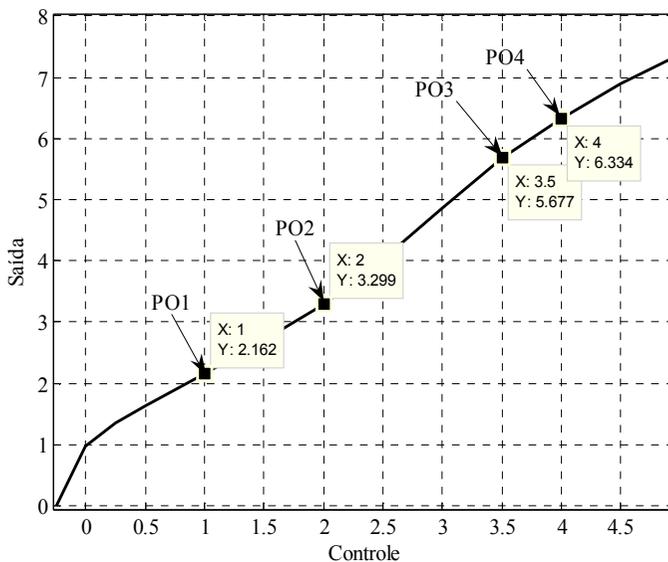
Os gráficos das Figuras 3.7, 3.8 e 3.9 mostram que, neste caso, um modelo de terceira ordem é suficiente para capturar a dinâmica do modelo não linear.

Para mostrar o bom desempenho desta proposta de modelagem, são escolhidos quatro pontos de operação na CCE, conforme mostra a Figura 3.10. A escolha destes pontos de operação é baseada, neste caso, no atingimento completo da faixa de operação do sistema. Observa-se que a curva característica estática deste sistema não apresenta variações consideráveis de inclinação, mas a idéia é mostrar como a proposta de modelagem captura o comportamento transiente do sistema.

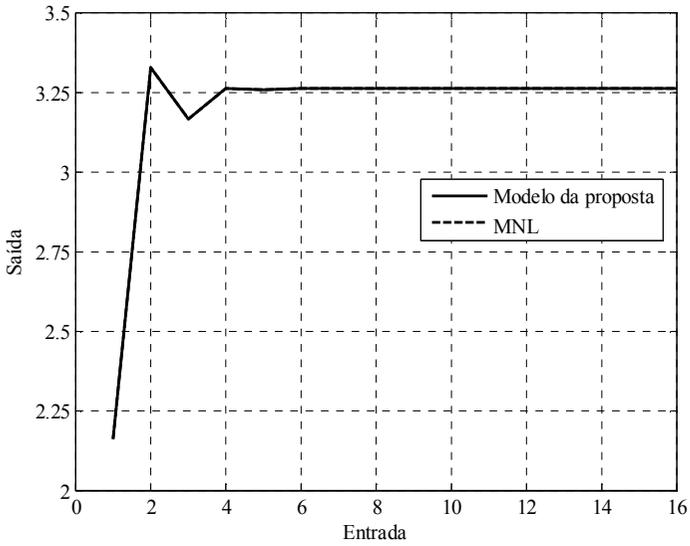
A seguir, determinam-se os modelos de transferência entre pontos de operação e calcula-se o SSE (*Sum of Squares Error*) referente ao modelo não linear. Os resultados são apresentados na Tabela 3.1, onde  $\Delta u$  representa a variação no controle para atingir o PO seguinte. Este delta de controle,  $\Delta u$ , é calculado *on-line* pela eq.(3.2). A e B representam os polinômios do modelo de terceira ordem determinados pelo algoritmo, e  $K_e$  representa o ganho do modelo entre os pontos de operação.

**Tabela 3.1:** Modelos entre pontos de operação e cálculo de SSE.

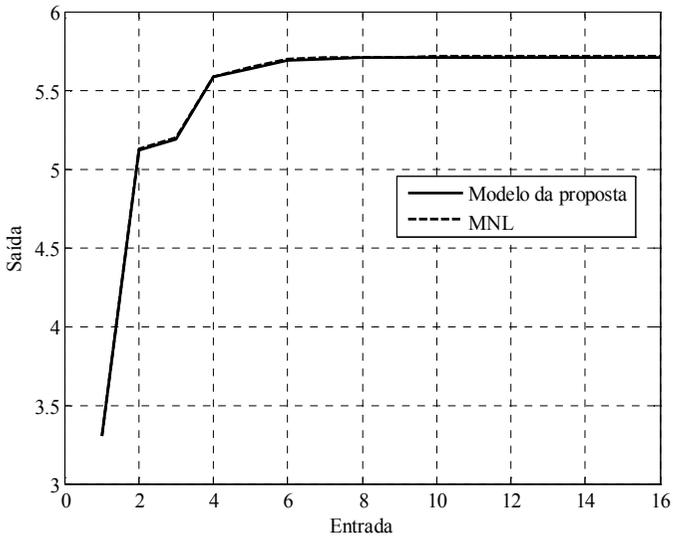
| Transfê-<br>rencia<br>entre POs | $\Delta u$ | Polinômios do Modelo<br>Linear A e B com $na=3,$<br>$nb=3, nk=1$                     | Ke   | SSE<br>$\times 10^{-9}$ |
|---------------------------------|------------|--|------|-------------------------|
| PO1 a PO2                       | 1          | $A=1-0.0659z^{-1}-0.0397z^{-2}+0.0011z^{-3}$<br>$B=1.2-0.2493z^{-1}+0.0674z^{-2}$    | 1.14 | 3.878                   |
| PO2 a PO3                       | 1.5        | $A=1-0.2368z^{-1}-0.1064z^{-2}+0.0229z^{-3}$<br>$B=1.1999-0.2404z^{-1}+0.1191z^{-2}$ | 1.59 | 641.6                   |
| PO3 a PO4                       | 0.5        | $A=1-0.0023z^{-1}-0.0042z^{-2}+0z^{-3}$<br>$B=1.2-0.0675z^{-1}+0.0482z^{-2}$         | 1.31 | $7.5816 \times 10^{-6}$ |

**Figura 3.10:** Curva característica estática do modelo e POs.

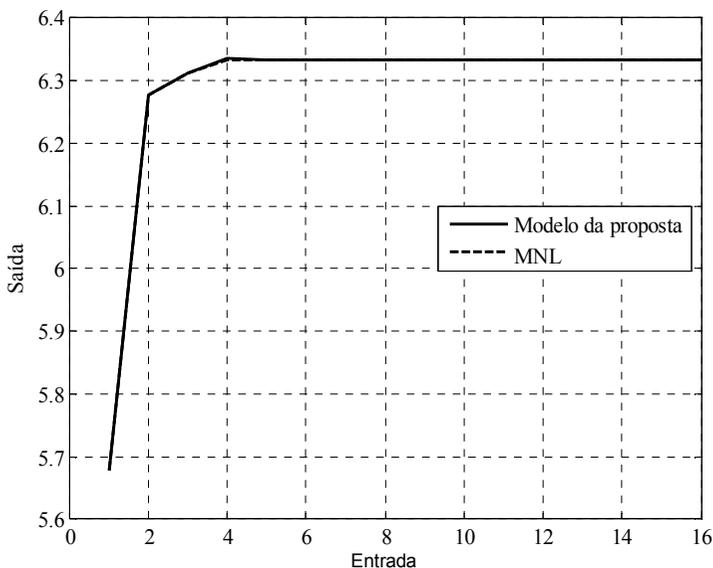
O baixo SSE calculado para cada caso confirma a validade do modelo linear referente ao MNL na zona de transição para uma entrada tipo degrau. A validade dos modelos é mostrada graficamente nas Figuras 3.11, 3.12 e 3.13.



**Figura 3.11:** Saída do MNL e do ML para ir de PO1 a PO2.



**Figura 3.12:** Saída do MNL e do ML para ir do PO2 a PO3.



**Figura 3.13:** Saída do MNL e do ML para ir de PO<sub>3</sub> a PO<sub>4</sub>.

Nas figuras seguintes, comparam-se as saídas do MNL e do modelo para perturbações, determinados pela proposta, em dois pontos de operação do sistema. Também se apresentam os polinômios A e B de ambos os modelos.

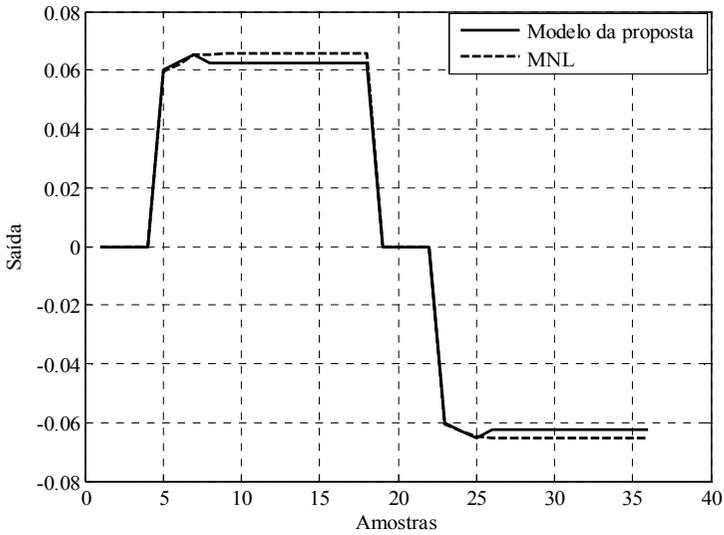
Para caso no PO(2, 3299), representado na Figura 3.14, se tem

$$\begin{aligned} A1 &= 1.0000 - 0.0302z^{-1} + 0.0137z^{-2} + 0.0471z^{-3}, \\ B1 &= 1.2016 + 0.0134z^{-1} + 0.0690z^{-2}. \end{aligned}$$

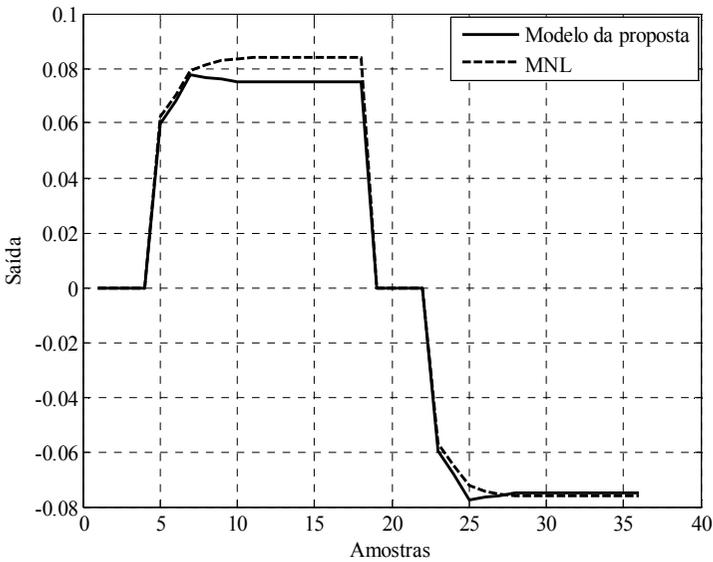
Para caso no PO(2.5, 4.021), representado na Figura 3.15, se tem

$$\begin{aligned} A2 &= 1.0000 - 0.2025z^{-1} - 0.0383z^{-2} + 0.0609z^{-3}, \\ B2 &= 1.2009 - 0.0820z^{-1} + 0.1178z^{-2}. \end{aligned}$$

Os modelos propostos apresentam um bom acompanhamento da evolução do MNL principalmente no tempo de subida. As diferenças aparecem ao final da resposta devido ao distinto ganho que apresenta o sistema baixo e sobre o ponto de operação.



**Figura 3.14:** Saída do MNL e do modelo da proposta para perturbações no PO(2, 3.299).

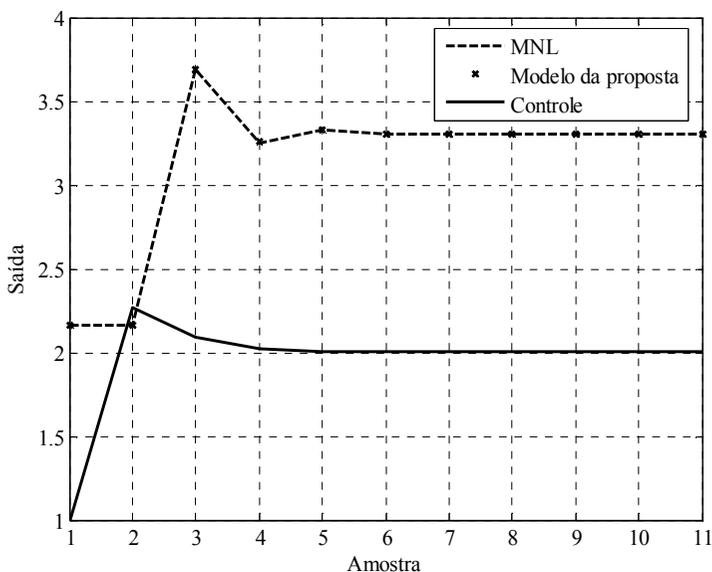


**Figura 3.15:** Saída do MNL e do modelo da proposta para perturbações no PO(2.5, 4.021).

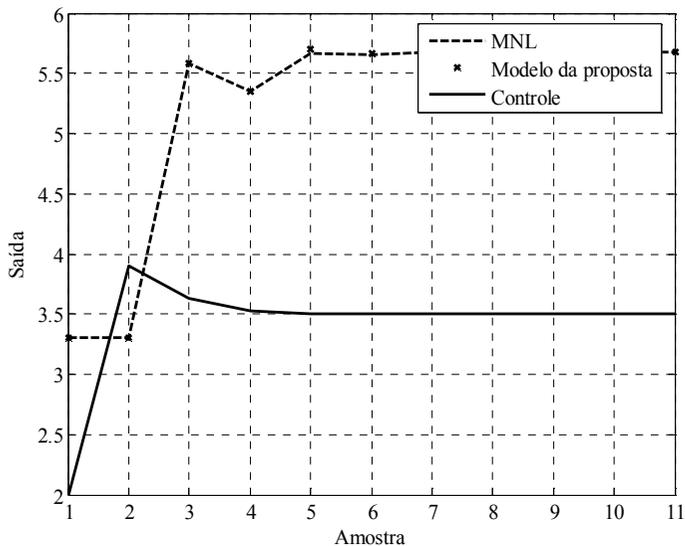
A seguir, são testados os modelos ARX obtidos escolhendo dois deles da Tabela 3.1, e aplicando a cada um, um sinal de controle do tipo apresentado comumente em malha fechada.

Nas Figuras 3.16 e 3.17 é apresentado este tipo de sinal de controle e as saídas do MNL e do modelo da proposta para transferência desde o ponto de operação PO1 ao ponto de operação PO2 e desde o ponto de operação PO2 ao ponto de operação PO3.

O sinal de controle aplicado apresenta uma ultrapassagem de 25%. Observa-se também que as saídas de ambos os modelos ficam praticamente sobrepostas.



**Figura 3.16:** Controle e saídas do MNL e do modelo da proposta para transição do PO1 a PO2.



**Figura 3.17:** Controle e saídas do MNL e do modelo da proposta para transição do PO2 a PO3.

### 3.2.2.2. CASO DE ESTUDO 2: CSTR

O esquema do sistema CSTR é mostrado na Figura 3.18. Assume-se que no interior do reator acontece uma reação irreversível exotérmica (Gao *et al.*, 2002).

No esquema do CSTR,  $q_c(t)$  é a vazão do refrigerante,  $T(t)$  é a temperatura da solução e  $C(t)$  é a concentração da saída. O objetivo é controlar  $C(t)$  manipulando  $q_c(t)$ .

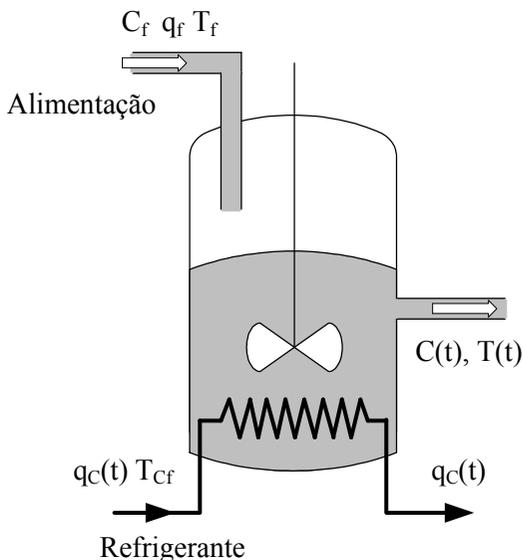
O modelo do processo consiste de duas equações diferenciais ordinárias apresentadas na continuação:

$$\frac{dT}{dt} = \frac{q_f}{V} (T_f - T(t)) + K_1 C(t) \exp\left(-\frac{E}{RT(t)}\right) + K_2 q_c(t) \left[1 - \exp\left(-\frac{K_3}{q_c(t)}\right)\right] (T_{cf} - T(t)) \quad (3.3)$$

e

$$\frac{dC(t)}{dt} = \frac{q_f}{V} (C_f - C(t)) - K_o C(t) \exp\left(-\frac{E}{RT(t)}\right). \quad (3.4)$$

Os parâmetros do modelo e as condições de operação nominal registram-se na Tabela 3.2.



**Figura 3.18:** Tanque reator agitado continuamente.

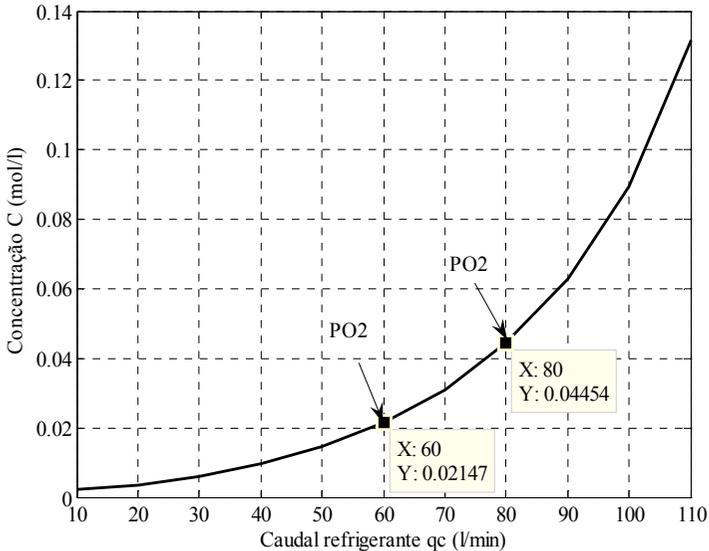
**Tabela 3.2:** Condições de operação do CSTR.

|  |  |
|--|--|
| $q_f = 100$ l/min,<br>vazão do produto               | $C_f = 1$ mol/l,<br>concentração de entrada                |
| $T_f = 350$ °K,<br>temperatura de entrada            | $T_{cf} = 350$ °K,<br>temperatura do refrigerante          |
| $K_1 = 1.44 \cdot 10^{13}$ °Kl/min/mol,<br>constante | $V = 1001$ ,<br>volume do recipiente                       |
| $E/R = 104$ °K,<br>energia de ativação               | $K_2 = 0.01/1$ ,<br>constante                              |
| $K_3 = 700$ l/min,<br>constante                      | $K_o = 7.2 \cdot 10^{10}$ min <sup>-1</sup> ,<br>constante |

A análise dos autovalores do sistema linearizado equivalente demonstra que o regime de equilíbrio estável do CSTR para a saída e entrada da planta esta no intervalo dado por:  $C(t) \in (0, 0.13566)$  e  $q_c(t) \in (0, 110.8)$ .

A Figura 3.19 mostra a curva característica estática do reator para as condições nominais, com a entrada ao processo variando de 10 a 110 (l/min). Observam-se nesta curva dois pontos de operação, PO1 e PO2, os quais foram escolhidos aleatoriamente. Suponha-se que, operando a

planta no PO1(60, 0.02147), se queira transferir ao PO2(80, 0.04454), o delta de controle para atingir o novo PO seria  $\Delta u=20$  (l/min).



**Figura 3.19:** Curva característica estática do CSTR.

Pretende-se determinar um modelo linear, para as predições, que represente a dinâmica do processo desde PO1 e PO2. Para isto, determina-se um modelo matemático que se ajuste à CCE inversa, representada na Figura 3.20. Utiliza-se para o ajuste dos dados uma ferramenta de ajuste, nominada *cftool* do *Toolbox* de identificação do Matlab.

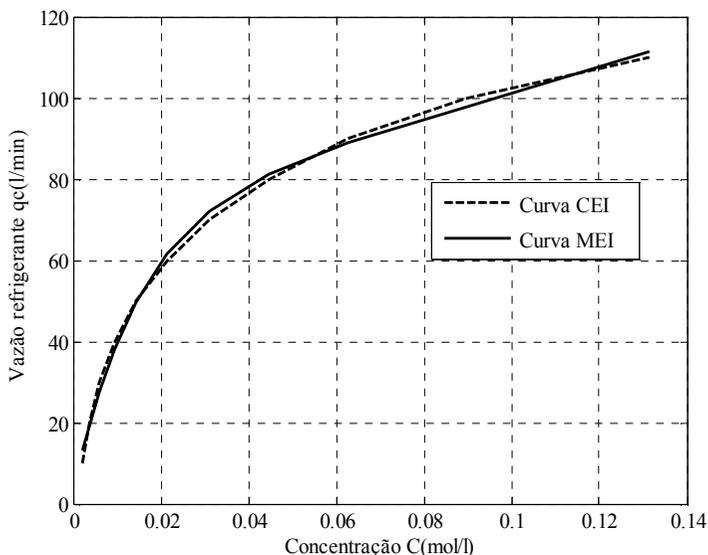
Cabe ressaltar que é possível obter também o modelo estático inverso a partir das equações 3.3 e 3.4, mas optou-se por este procedimento de ajuste de dados como uma forma de ilustrar um procedimento alternativo para obter o MEI.

O modelo determinado com este procedimento é:

$$Q_c = a_{11} \exp(b_{11} C_{ee}) + c_{11} \exp(d_{11} C_{ee}), \quad (3.5)$$

onde os coeficientes do modelo estático inverso são:

$$a_{11} = 74.28; \quad b_{11} = 3.075; \quad c_{11} = -70.49; \quad d_{11} = -63.9,$$



**Figura 3.20:** Curva característica estática inversa do CSTR.

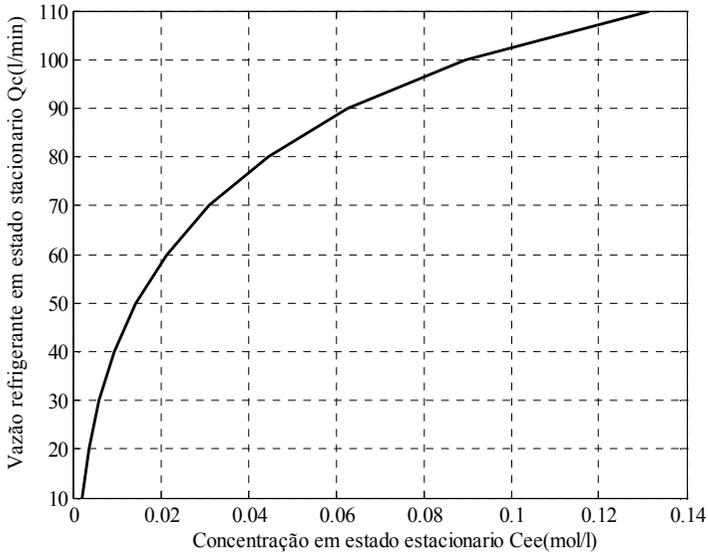
e

$Q_c$  é a Vazão de refrigerante em estado estacionário, (l/min) e  $C_{ee}$  é a Concentração da saída em estado estacionário, (mol/l).

A Figura 3.21 mostra a CCE inversa (CEI), obtida supostamente da planta (neste caso usa-se o MNL), e a curva obtida por ajuste dos dados (MEI).

Obtido o modelo, é possível determinar o controle necessário para levar o processo a qualquer outro ponto de operação desejado. Para o exemplo, e supondo o desconhecimento do controle para estabelecer o processo em  $C_{ee}=0.04454$  (ver Figura 3.19), determina-se o controle necessário mediante a eq.(3.5). O valor obtido é  $Q_c=81.08$  (l/min), quantidade que comparada com o valor real de 80 l/min, apresenta um erro próximo a 1%. Este erro pode ser menor utilizando um modelo estático inverso a partir das equações fundamentais do processo.

Assim, segundo o procedimento de modelagem estabelecido em 3.2.2, para o caso de mudança na referência, determina-se o delta de controle para aplicar no modelo não linear da planta e gerar os dados necessários para determinar o modelo ARX das previsões. Neste exemplo, o delta de controle foi  $\Delta u= 21.08$  (l/min).



**Figura 3.21:** Curva CEI versus curva MEI do CSTR.

Apresentam-se a seguir os polinômios A e B de dois modelos ARX, de ordem distinta, determinados pela proposta. Para que a comparação seja correta, testam-se os modelos, não para o  $\Delta u$  calculado, mas sim para o  $\Delta u$  nominal de 20 (l/min).

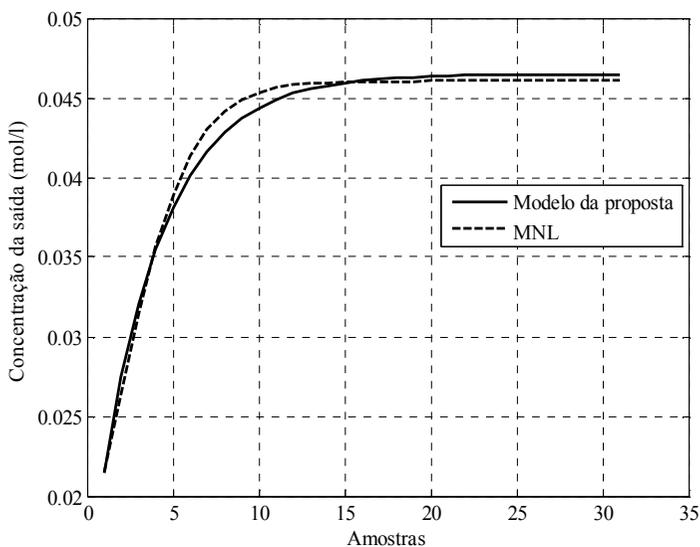
Mostram-se nas Figuras 3.22 e 3.23, uma comparação entre a evolução da saída do modelo não linear do CSTR e a saída destes modelos.

Para caso polinômios do modelo de 1<sup>a</sup> ordem:

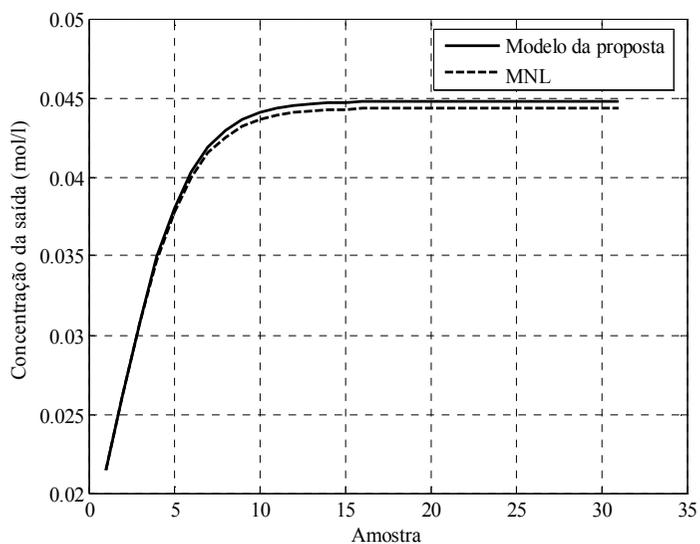
$$A1=1-0.7604z^{-1}, \quad B1=0.0002845.$$

Para caso polinômios do modelo de 2<sup>a</sup> ordem:

$$A2=1-1.2052z^{-1}+0.3698z^{-2}, \quad B2=(0.2308-0.0389z^{-1}) \times 10^{-3}.$$



**Figura 3.22:** Saída do MNL do CSTR e do modelo linear estimado de primeira ordem.

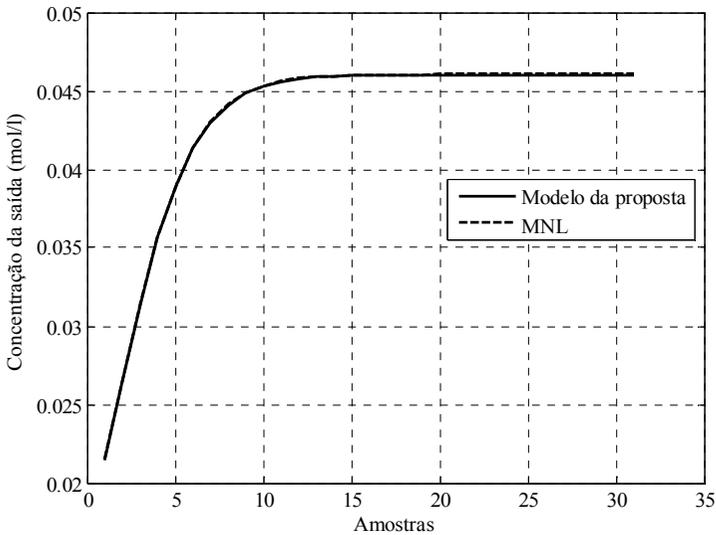


**Figura 3.23:** Saída do MNL do CSTR e do modelo linear estimado de segunda ordem.

Na Figura 3.23, observa-se que o modelo de segunda ordem segue em melhor forma a dinâmica do MNL até aproximadamente a amostra 5 e logo gera um erro em estado estacionário. Esta diferença ocorre, como veremos na continuação, porque o modelo linear foi obtido com um  $\Delta u$  diferente do nominal. Na Figura 3.24, observam-se as saídas do MNL e de um modelo de segunda ordem obtido com  $\Delta u$  nominal. A3 e B3 são os polinômios deste modelo.

Modelo de segunda ordem,  $n_a=2$ ,  $n_b=2$ ,  $n_k=1$  e  $\Delta u=20$  na entrada:

$$A3=1-1.1894z^{-1}+0.3573z^{-2}, \quad B3=(0.2298-0.0378z^{-1}) \times 10^{-3}.$$

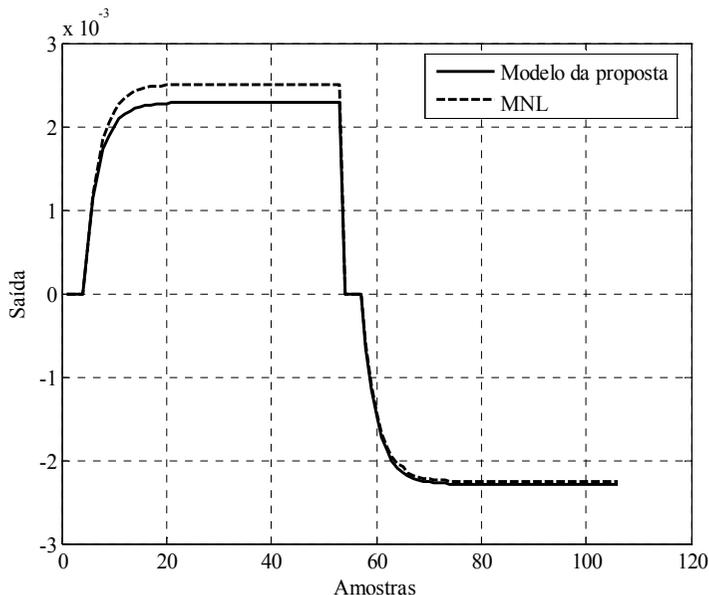


**Figura 3.24:** Saída do MNL do CSTR e do modelo linear de segunda ordem,  $\Delta u$  nominal.

Observa-se nos gráficos das Figuras 3.23 e 3.24 que, neste caso, um modelo de segunda ordem é suficiente para capturar a dinâmica do modelo não linear do CSTR para esta mudança de ponto de operação.

Nas Figuras 3.25 e 3.26, comparam-se as saídas do MNL e do modelo para perturbações, determinado pela proposta, em dois pontos de operação do sistema. Apresentam-se também os polinômios A e B de ambos os modelos. Nestes casos foi suficiente um modelo de ordem  $n_a=2$  e  $n_b=1$  para obter uma boa aproximação da resposta do MNL a entradas degrau utilizadas para determinar os modelos.

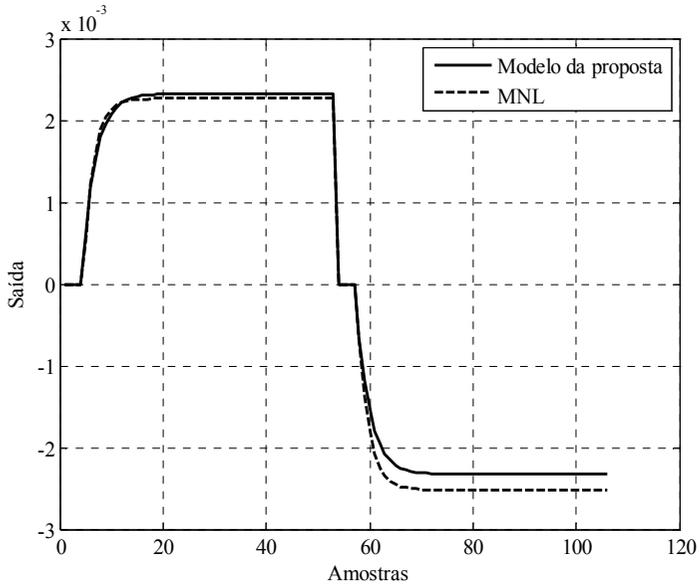
PO(60, 0.00215) :  $A1 = 1 - 0.7316z^{-1} + 0.0203z^{-2}$ ,  $B1 = 0.2269 \times 10^{-3}$ .



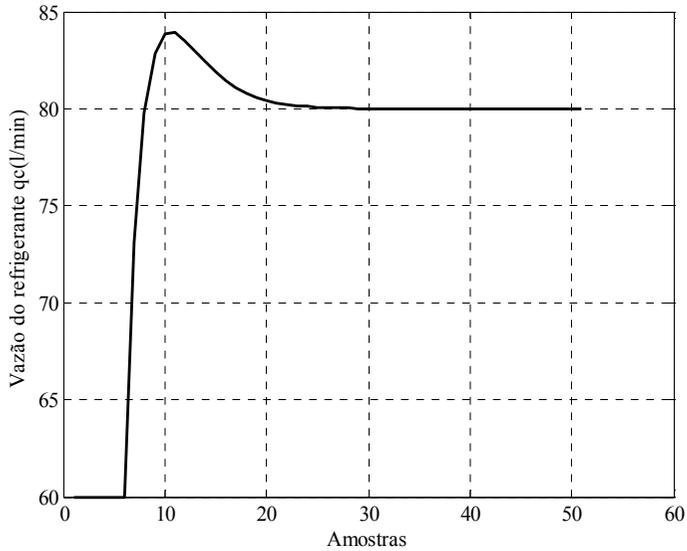
**Figura 3.25:** Saída do MNL e do modelo da proposta para perturbações no PO(60, 0.00215).

A seguir, testa-se o modelo da proposta de segunda ordem (polinômios A2 e B2), em diferentes situações que podem ser apresentadas na prática. Por exemplo, mesmo no caso de estudo 1 (3.2.2.1), quando a planta é submetida a uma mudança de referência do tipo degrau em malha fechada, normalmente o sinal de controle tem valores transitórios maiores que o valor final no início da resposta, apresentando uma forma similar à mostrada na Figura 3.27. A Figura 3.28 apresenta a resposta do MNL e do modelo da proposta ante a este tipo de entrada.

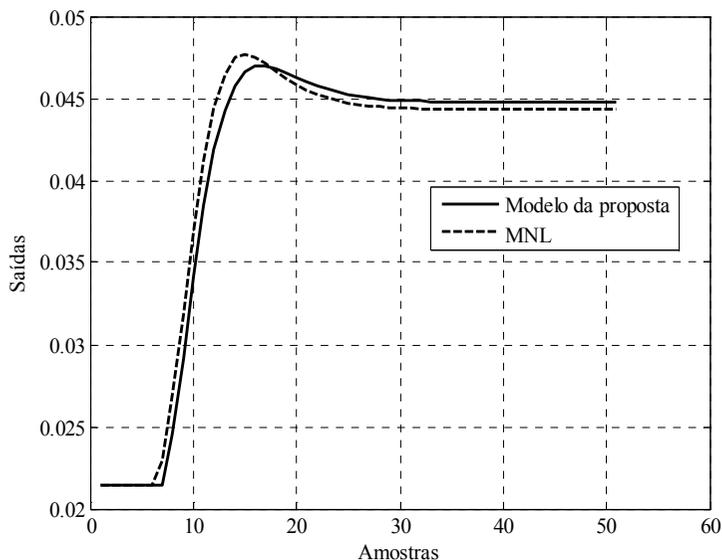
PO(80, 0.00445):  $A2 = 1.0000 - 0.7928z^{-1} + 0.0761z^{-2}$ ,  $B2 = 0.4275 \times 10^{-3}$ .



**Figura 3.26:** Saída do MNL e do modelo da proposta para perturbações no PO(80, 0.00445).



**Figura 3.27:** Sinal típico de controle.

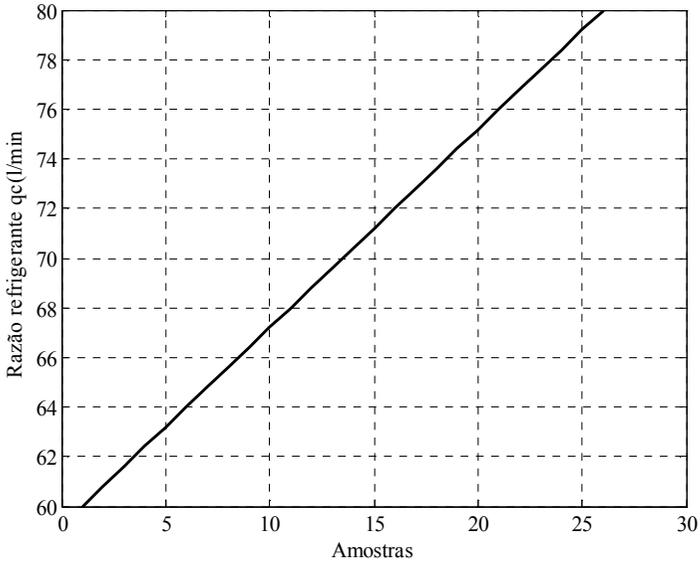


**Figura 3.28:** Saída do MNL do CSTR e do modelo linear estimado de segunda ordem.

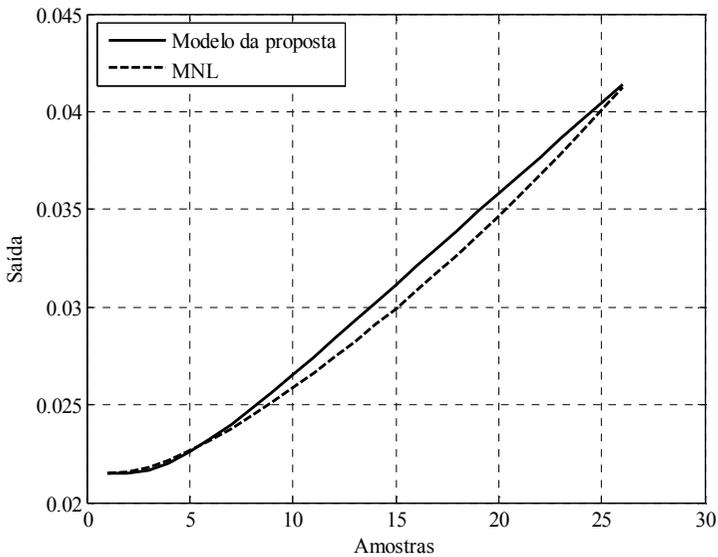
Observa-se que a saída do modelo proposto segue próximo à evolução da saída da planta não linear. Esta diferença pode ser menor caso se use o  $\Delta u$  nominal para o cálculo do modelo linear.

Outro tipo de sinais de controle, freqüentemente encontrados em plantas industriais, são rampas utilizadas para transferir os processos a uma velocidade controlada entre dois pontos de operação. Para o mesmo exemplo do reator e modelo de segunda ordem obtido pela proposta, aplica-se uma rampa, como aquela mostrada na Figura 3.29, a partir da amostra 1. A Figura 3.30 mostra a resposta do modelo proposto e a saída do modelo não linear. Observa-se que a saída do modelo proposto segue de perto a evolução da saída da planta não linear. Nota-se que o delta de controle aplicado,  $\Delta u$ , é novamente de 20 l/min.

Analogamente ao caso de estudo 1, para mostrar a aplicação geral desta proposta de modelagem, escolhem-se quatro pontos de operação na CCE do reator como é apresentado na Figura 3.31. A seguir determinam-se os modelos de transferência entre os pontos de operação e calcula-se o SSE referente ao modelo não linear. Os resultados registram-se na Tabela 3.3. Novamente, como no caso anterior, A e B

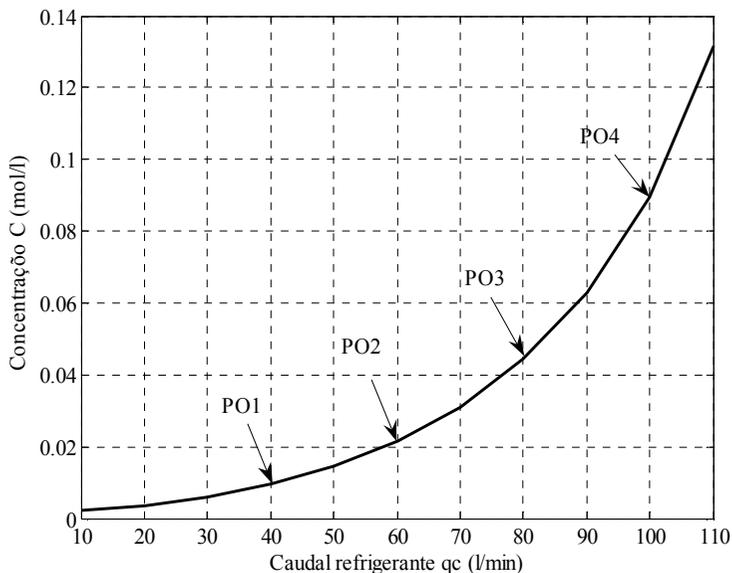


**Figura 3.29:** Sinal típico de controle aplicado na planta.



**Figura 3.30:** Saída do MNL e do modelo linear de segunda ordem, entrada tipo rampa.

representam os polinômios do modelo de segunda ordem determinados pelo algoritmo e  $K_e$  representa o ganho do modelo entre os pontos de operação.



**Figura 3.31:** Curva característica estática do CSTR e POs.

**Tabela 3.3:** Modelos entre pontos de operação e SSE.

| Transfe-<br>rência<br>entre POs | $\Delta u$ (l/<br>min) | Polinômios do Modelo<br>Linear A e B<br>com $n_a=2$ , $n_b=2$ , $n_k=1$    | $K_e$<br>(mol/<br>min)<br>$\times 10^{-4}$ | SSE<br>$\times 10^{-7}$ |
|---------------------------------|------------------------|--|--|-------------------------|
| PO1 a PO2                       | 21.5                   | $A=1-1.3229z^{-1}-0.4384z^{-2}$<br>$B=(0.1099-0.0389z^{-1})\times 10^{-3}$ | 6.15                                       | 1.0779                  |
| PO2 a PO3                       | 21.1                   | $A=1-1.2031z^{-1}-0.3683z^{-2}$<br>$B=(0.2302-0.0377z^{-1})\times 10^{-3}$ | 12   | 1.9055                  |
| PO3 a PO4                       | 17.5                   | $A=1-1.2005z^{-1}-0.4203z^{-2}$<br>$B=(0.4220-0.0497z^{-1})\times 10^{-3}$ | 21   | 4.1287                  |

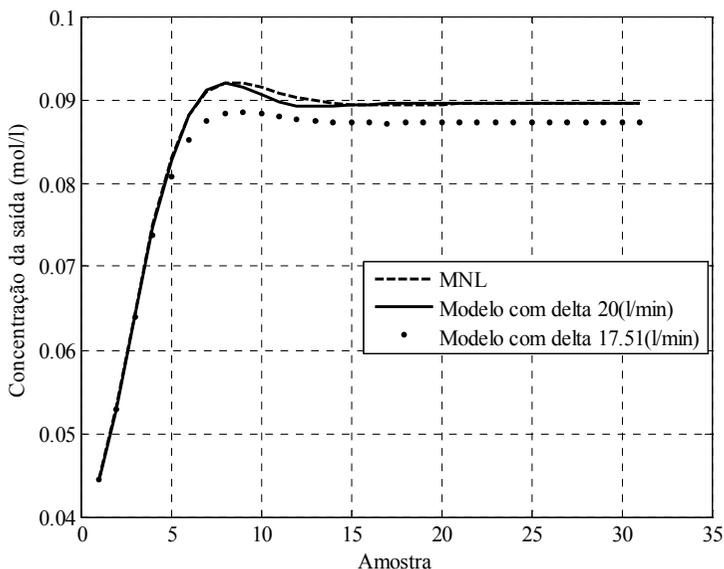
A Tabela 3.3 mostra que o delta de controle calculado pela eq.(3.5), na transição de PO3 a PO4 tem um erro maior que nos outros casos, referente ao valor nominal de 20 (l/min). No caso de utilizar o valor nominal de 20 (l/min), para obter o modelo entre estes pontos de operação, a melhora é substancial. Neste caso o algoritmo entrega os seguintes polinômios para o modelo:

$$A1=1-1.2802z^{-1}+0.4822z^{-2}, \quad B1=0.4233+0.0325z^{-1}.$$

Para este modelo o SSE é 5.5916e-008, quantidade que é bem menor ao SSE de 4.1287e-004 correspondente da Tabela 3.3.

A Figura 3.32 mostra e compara as saídas do MNL e dos dois modelos calculados para a transição PO3 a PO4. Observa-se que este último modelo linear formado pelos polinômios A1 e B1 a saída representa quase perfeitamente a dinâmica do modelo do processo.

Conclui-se, desta análise, que os modelos obtidos com o algoritmo proposto, capturam de boa forma a dinâmica da planta entre pontos de operação para diferentes perfis dos sinais de controle.



**Figura 3.32:** Saídas do sistema não linear, e do modelo da proposta para diferentes  $\Delta u$ .

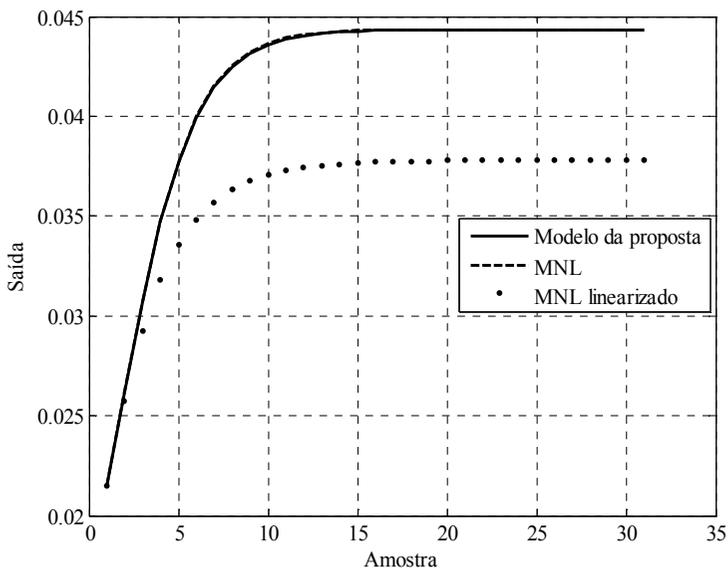
### 3.2.2.3. COMPARAÇÕES

Uma revisão e comparação da proposta de modelagem com outras técnicas de obtenção de modelos locais são apresentadas nesta seção. Por exemplo, para o caso do CSTR analisado no caso de estudo 2, os polinômios A e B do modelo linear obtido por linearização do MNL no PO1 e pela proposta, entre PO1 e PO2, calculado com  $\Delta u$  nominal, são respectivamente os seguintes:

$$A1=1-0.7058z^{-1}+0.0004z^{-2}, \quad B1=(0.2126+0.0279z^{-1}) \times 10^{-3},$$

$$A2=1-1.1871z^{-1}+0.3557z^{-2}, \quad B2=(0.2292+0.0365z^{-1}) \times 10^{-3}.$$

Para obter os polinômios por linearização utilizou-se a rotina *Linmod* do Matlab. A Figura 3.33 mostra a evolução das saídas do MNL, do modelo da proposta e do modelo obtido por linearização. Aplicou-se como entrada uma mesma variação no controle,  $\Delta u=20$  (l/min).



**Figura 3.33:** Saídas do sistema não linear, do modelo linearizado e do modelo da proposta.

Observa-se na Figura 3.33 que o modelo linearizado no PO não é capaz de capturar a dinâmica do MNL na transição de um PO a outro. É preciso acrescentar que, ainda com uma aproximação da série de Taylor de ordem maior, o modelo assim obtido representa só a dinâmica da planta ao redor do PO atual e não a dinâmica até o novo PO.

Assim, conforme exposto na seção 1.2.2, existem técnicas para melhorar a exatidão de modelos locais obtidos por linearização simples. Uma delas utiliza linearizações sucessivas dos sistemas de equações diferenciais ordinárias em intervalos igualmente espaçados, dentro do intervalo de amostragem. Outra, LLT, procura utilizar múltiplos modelos para a minimização da função custo  $J$ , de tal forma que a mesma ocorra utilizando modelos lineares, referentes aos pontos transitórios pelos quais o sistema vai passar durante uma mudança de referência, caso seja utilizada a seqüência de controle previamente determinada pela otimização (Trierweiler & Secchi, 2000). Estes procedimentos têm dois inconvenientes, o primeiro é o tempo computacional requerido para realizar estas linearizações sucessivas, o segundo é sua aplicação limitada só a sistemas representados mediante modelos com equações diferenciáveis. No caso da proposta, o modelo não linear do processo pode ter qualquer procedência e o tempo computacional é baixo, somente a magnitude necessária para obter um modelo simples.

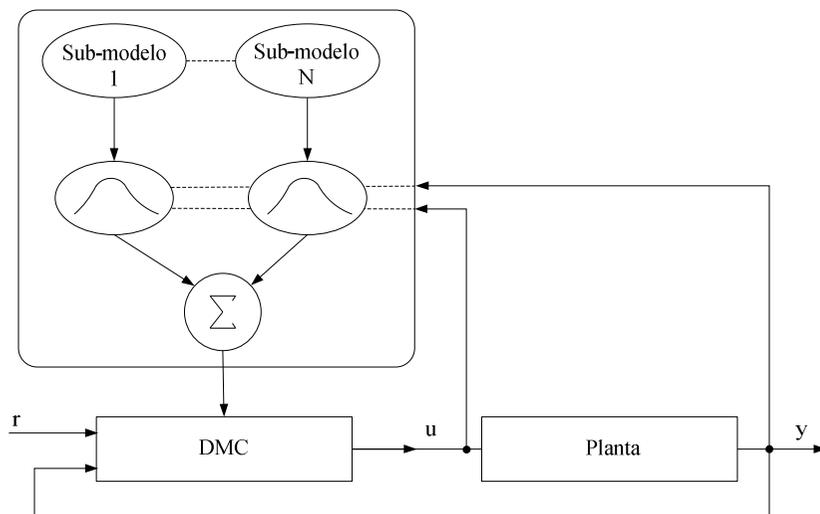
Outra técnica, já apresentada, é o uso de uma rede de modelos locais. Esta é usada para capturar a dinâmica do processo em diferentes pontos de operação. A LMN forma um modelo global da planta desde um conjunto de sub-modelos que podem ser, por si só, redes neurais, tal como RBF (*Radial Basis Function*). As saídas de cada sub-modelo são passadas através de uma função de processamento local, que efetivamente atua para gerar uma janela de validade para esse modelo dentro do espaço de operação da planta. As saídas locais resultantes são então combinadas como uma soma de pesos para formar a saída do modelo. No caso onde são usadas funções Gaussianas normalizadas, o LMN pode ser visto como uma forma generalizada de rede neural RBF.

Duas formulações são propostas na linha de redes de modelos locais, ambas usando DMC (Irwin & Townsend, 1999). A primeira utiliza um único DMC (LM-DMC) com um modelo local obtido numa combinação dos modelos lineares locais (ver Figura 3.34). Uma função de interpolação gera pesos de ativação para cada modelo. Pesos altos são dados aos modelos que dão uma boa aproximação em regime onde o

modelo está operando, enquanto que pesos próximos de zero são dados aos outros.

O segundo método é uma rede de DMCs (LC-DMC), cada uma projetada ao redor dos modelos locais (ver Figura 3.35). A ação de controle é formada pela combinação das saídas dos controladores lineares.

A estratégia LM-DMC necessita um conjunto de parâmetros de sintonia. O modelo interno de um único controlador DMC é atualizado a cada instante de amostragem. Este controle gera resultados conservadores, pois a ação de controle deve ser limitada para um funcionamento correto no pior caso, isto significa um fator limitante quando a saída do processo é mudada a um ponto de operação de baixo ganho, onde, talvez, o melhor controle não seja atingido (Irwin & Townsend, 1999). No segundo tratamento (LC-DMC), a sintonia dos controladores pode não ser fácil, devido ao número e efeito das funções base normalizadas da LMN (Shorten & Murray-Smith, 1997).

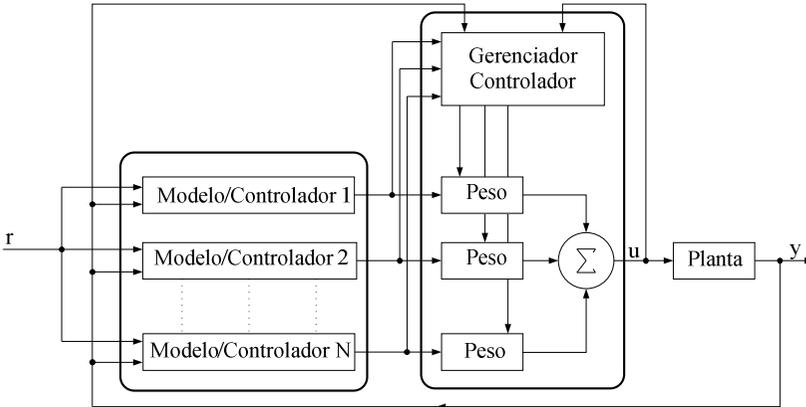


**Figura 3.34:** Controlador com matriz dinâmica baseado em modelos locais.

Do ponto de vista dos modelos locais, comparando-os com a proposta deste trabalho, observa-se que estas técnicas apresentadas de LMN são bem mais complexas, já que requerem a utilização de múltiplos modelos para cada configuração. No caso do LC-DMC o tempo de processamento computacional está associado ao número de

Modelo/Controlador utilizados, cada um destes controladores requerem um processo de otimização.

Em relação a estas duas últimas técnicas de LMN, demonstra-se no Capítulo 4, caso planta de pH, que a proposta apresenta resultados superiores em todos os casos analisados.



**Figura 3.35:** Controlador com matriz dinâmica baseado em controladores locais.

#### 3.2.2.4. PENALIZAÇÃO DO CONTROLE

Neste algoritmo, a penalização do controle fica dependente do ganho do modelo da planta no ponto de operação atual. Este procedimento fornece uma resposta mais uniforme do sinal controlado em todo o intervalo de operação da planta, possibilitando desta forma alcançar tempos de estabelecimento uniformes e mais ajustados. Uma aplicação que avalia este procedimento encontra-se em Altinten (2007), onde a penalização do controle foi variada para alcançar ótimo desempenho do GPC no controle de uma planta de pH.

Conforme demonstrado no Capítulo 2, para ponderar o esforço de controle da mesma forma no caso de dois sistemas com diferentes ganhos estáticos ( $Ke_1$  e  $Ke_2$ ), é preciso utilizar uma relação quadrática entre os esforços de controle. Assim, as ponderações do controle devem ser dadas por:

$$\lambda_2 = (Ke_1/Ke_2)^2 \lambda_1. \quad (3.6)$$

Este resultado pode ser aplicado em plantas não lineares, as quais apresentam ganhos estáticos diferentes na faixa de operação da planta, permitindo assim mais uniformidade no esforço de controle em toda a faixa de operação da planta. Isto quer dizer, interpretando a eq.(3.7), que para um ganho estático  $Ke_1$  no PO1, da curva característica estática, com uma penalização de controle ajustada como  $\lambda_1$ , para se cumprir certo comportamento na saída da planta, a penalização de controle  $\lambda_2$ , para obter um comportamento similar na variável de saída no PO2, deve ser calculada por esta relação.

Na aplicação do algoritmo de DTC-GPC, utiliza-se uma relação para o esforço do controle dada pela eq.(3.8), onde  $Ke$  é o ganho do modelo determinado pela proposta, e  $\lambda_n$  é uma ponderação normalizada que se obtém no ajuste do controle:

$$\lambda = \lambda_n (Ke)^2 \quad (3.7)$$

Esta relação quadrática, que pode ser reajustada com testes *on-line*, fornece ao sistema de controle um comportamento uniforme das variáveis de controle e controlado.

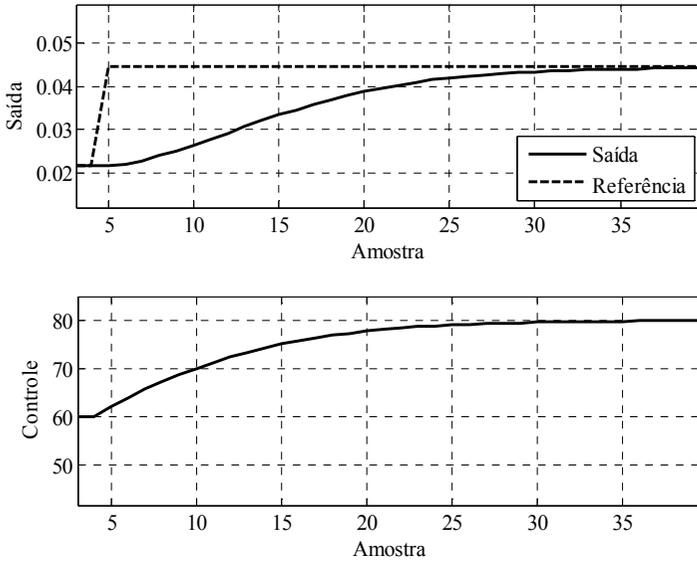
Para ilustrar este procedimento novamente utilizaremos o CSTR como exemplo. A idéia é determinar, para cada transferência de PO, a penalização de controle necessária para obter um comportamento desejado, que seja uniforme para toda a faixa de operação do processo. Então escolhendo novamente os quatro pontos de operação do caso de estudo 2, procede-se o ajuste do GPC para cada transição entre pontos de operação sucessivos. Para isto, escolhe-se um critério de comportamento para a saída do processo, neste caso o mínimo tempo de acomodação sem ultrapassagem, determina-se a penalização de controle  $\lambda$  para cada caso. A Figura 3.36 mostra o comportamento desejado para o caso da transição do PO2 a PO3.

Observa-se que o tempo de acomodação é de aproximadamente 30 amostras. Este tempo deve ser mantido para todos os ajustes. A Tabela 3.4 apresenta os valores de  $\lambda$  para cada transferência. Observam-se os valores pequenos de  $\lambda$  para este exemplo, mas estes valores estão associados ao ganho da planta que, pelas unidades utilizadas, são da ordem de  $10^{-4}$ .

A seguir, procura-se graficamente uma curva que passe pelos pares  $(Ke, \lambda)$  da Tabela 3.4. A Figura 3.37, representa com círculos estes pares e a curva contínua representa o ajuste feito para determinar à

constante  $\lambda_n$  que conforma a eq.(3.8). Assim, o valor determinado para  $\lambda_n$ , mediante este procedimento, é 65, portanto a eq.(3.8) fica:

$$\lambda = 65(Ke)^2 \quad (3.8)$$

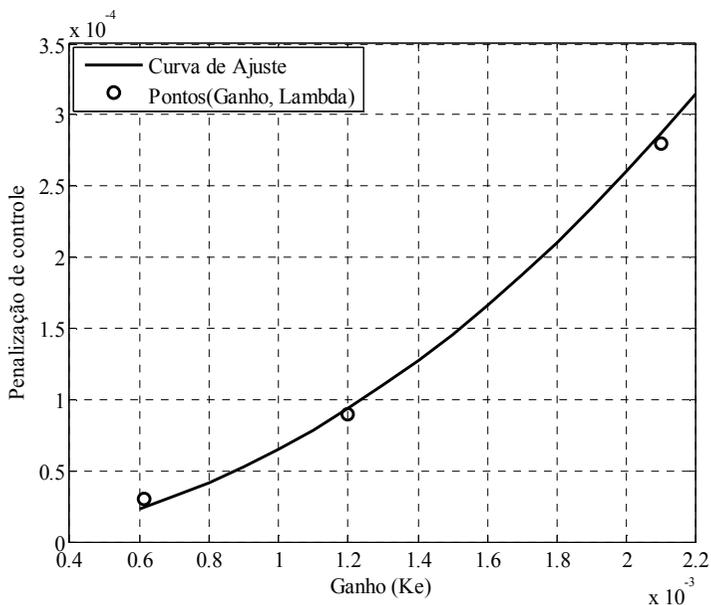


**Figura 3.36:** Saída e controle para transferência entre PO2 e PO3.

**Tabela 3.4:** Ganho do modelo e lambda para transferências entre POs.

| <b>Transferência<br/>entre POs</b> | <b>Ke (mol/min)<br/><math>\times 10^{-4}</math></b> | <b>Lambda (<math>\lambda</math>)<br/><math>\times 10^{-6}</math></b> |
|------------------------------------|---|--|
| PO1 a PO2                          | 6.15  | 30   |
| PO2 a PO3                          | 12.00   | 90   |
| PO3 a PO4                          | 21.00   | 280  |

Com esta equação, determina-se *on-line* a penalização de controle a ser utilizada pelo GPC-DTC para cada novo modelo determinado pelo algoritmo, seja para mudança de referência ou para a rejeição das perturbações. Este parâmetro pode ser reajustado para obter distintos tempos de acomodação caso requerido, mantendo uniformidade em toda a faixa de operação do processo, tanto para a variável controlada como para o controle.



**Figura 3.37:** Ganho versus penalização de controle e curva de ajuste.

### 3.3. COMENTÁRIOS

A filosofia da nova proposta e um procedimento sistemático para o projeto do controlador para plantas não lineares, de fácil aplicação, e que considera, dentro de suas etapas, a sintonia do controlador preditivo, foram apresentados neste capítulo.

Assim, mostrou-se a validade dos modelos locais obtidos com a nova proposta diante de diferentes situações que possam ser apresentadas na prática. Pode-se apreciar claramente, nos exemplos apresentados, que o modelo é capaz de reproduzir, às vezes com erro ínfimo, a dinâmica da planta, principalmente diante das trajetórias entre pontos de operação. Mostra-se também que o modelo obtido com a curva de reação serve para prever a evolução da planta diante de diferentes formas ou perfis do sinal de controle.

A obtenção de modelos para a rejeição das perturbações e a análise do efeito da ponderação do controle de forma não linear, também foram objeto de estudo deste capítulo.

Finalmente, a nova proposta foi comparada, qualitativamente, com outras técnicas de obtenção de modelos locais existentes, estabelecendo-se as suas vantagens, principalmente no uso de um

modelo único de predição, exatidão e a não dependência do tipo de modelo.

## CAPÍTULO 4

### APLICAÇÕES E COMPARAÇÕES POR SIMULAÇÃO

#### 4.1. INTRODUÇÃO

Neste capítulo, a técnica proposta é aplicada em dois sistemas não lineares. No primeiro, estuda-se um sistema tratado na literatura de controle não linear e que exhibe dinâmicas bastante especiais. Na segunda aplicação, descreve-se o procedimento proposto para o projeto do controlador de um processo de neutralização de pH e os resultados são comparados com outros algoritmos propostos na literatura e que fazem uso de modelos locais para o cálculo do controle.

Para as simulações apresentadas aqui foi utilizado o Matlab 7.0 e um computador Toshiba, modelo Satellite 2410, Processador x86, Genuine Intel, 2 GHz, RAM 256 MB, Cache 256 KB. Já para o algoritmo de controle preditivo, foi usada a função `quadprog` do *Toolbox* de otimização do Matlab, definida como segue:

$$\mathbf{x} = \text{quadprog}(\mathbf{H}, \mathbf{f}, \mathbf{A}, \mathbf{b}, \mathbf{A}_{\text{eq}}, \mathbf{b}_{\text{eq}}).$$

Esta função resolve o problema de programação quadrática:

$$\begin{aligned} \text{Min } J(\mathbf{x}) &= \min (0.5 \mathbf{x}' \mathbf{H} \mathbf{x} + \mathbf{f}' \mathbf{x}), \\ \text{s.a.} \\ \mathbf{A} \mathbf{x} &\leq \mathbf{b} \quad (\text{restrições de desigualdade}), \\ \mathbf{A}_{\text{eq}} \mathbf{x} &= \mathbf{b}_{\text{eq}} \quad (\text{restrições de igualdade}), \end{aligned}$$

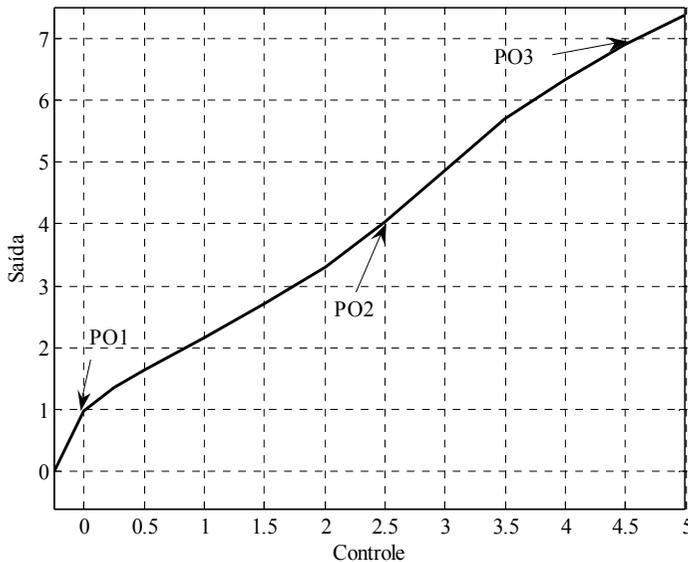
onde  $\mathbf{x}$  é um vetor  $N_u \times 1$  que representa a variável de decisão,  $\mathbf{H}$  é uma matriz  $N_u \times N_u$ ,  $\mathbf{f}$  é um vetor  $1 \times N_u$ ,  $\mathbf{A}$  é uma matriz  $M_a \times N_u$ ,  $\mathbf{b}$  um vetor  $M_a \times 1$ ,  $\mathbf{A}_{\text{eq}}$  é uma matriz  $M_c \times N_u$  e  $\mathbf{b}_{\text{eq}}$  um vetor  $M_c \times 1$ .

#### 4.2. CASO DE ESTUDO 1: MODELO LAZAR

O primeiro caso de estudo é o sistema apresentado na seção 3.2.2.1. Este sistema exhibe dinâmicas diferentes no seu intervalo de operação (Lazar, 2001). O modelo não linear, do tipo SISO, foi analisado e registrado no Capítulo 3 (eq. (3.1)) mesmo que o modelo estático inverso que apresenta-se, novamente, na eq.(4.1).

$$u_{eq} = \frac{-2.083y_{eq}^2}{1 + 2y_{eq}^2} + \frac{y_{eq} - 0.3\cos(y_{eq})}{1.2}. \quad (4.1)$$

A Figura 4.1 mostra a curva característica estática, com três pontos de operação distribuídos na faixa de operação do sistema. Os pontos foram escolhidos, principalmente, onde se apresentam mudanças de inclinação significativas.



**Figura 4.1:** Curva característica estática e pontos de operação definidos.

Os pontos de operação são representados nos seguintes vetores:

$$\text{Controle} = [0.0000 \ 2.5000 \ 4.5000], \quad \text{Saída} = [0.9837 \ 4.0210 \ 6.8840].$$

O tempo de amostragem e horizonte de predição se determinam facilmente da Figura 3.4. Considerando  $T_s=1$ , o horizonte de predição se escolhe  $N=10$  para cobrir o maior tempo de acomodação observado nessa figura. Para o horizonte de controle considera-se  $1/3$  de  $N$ , ou seja,  $N_u=3$ . O sistema não tem tempo morto.

Na continuação, e segundo o procedimento geral do projeto, determinam-se três modelos ARX. Os polinômios A e B de cada modelo

apresentam-se a seguir. A ordem do modelo ARX usado foi  $n_a=4$ ,  $n_b=4$  e  $n_k=1$ .

Polinômios do modelo ARX entre PO1=(0.000, 0.9837) e PO2=(2.500, 4.0217):

$$\begin{aligned} A &= 1.0000 - 0.6295z^{-1} - 0.0458z^{-2} + 0.0621z^{-3} - 0.0026z^{-4}, \\ B &= 1.2000 - 1.0272z^{-1} + 0.3599z^{-2} - 0.0673z^{-3}. \end{aligned}$$

Polinômios do modelo ARX entre PO2=(2.500, 4.021) e PO3=(4.500, 6.884):

$$\begin{aligned} A &= 1.0000 + 0.0610z^{-1} + 0.0775z^{-2} - 0.0021z^{-3} - 0.0003z^{-4}, \\ B &= 1.2001 + 0.1883z^{-1} + 0.2369z^{-2} + 0.0012z^{-3}. \end{aligned}$$

Polinômios do modelo ARX desde PO3=(4.500, 6.884) até o final da faixa de operação:

$$\begin{aligned} A &= 1.0000 - 0.1957z^{-1} + 0.1033z^{-2} - 0.0411z^{-3} + 0.0019z^{-4}, \\ B &= 1.2008 - 0.3639z^{-1} + 0.0217z^{-2} - 0.0032z^{-3}. \end{aligned}$$

Os ganhos de cada modelo,  $K_e$ , ordenados por ponto de operação, registram-se no seguinte vetor:

$$K_e = [0.9843 \quad 1.2112 \quad 1.4316].$$

Para cada modelo obtido ajusta-se o GPC, considerando um comportamento uniforme de mínimo tempo de acomodação, sem ultrapassagem. O ajuste realiza-se graficamente.

Os valores da penalização de controle,  $\lambda$ , para cada ajuste, ordenados de acordo com o vetor  $K_e$ , são os seguintes:

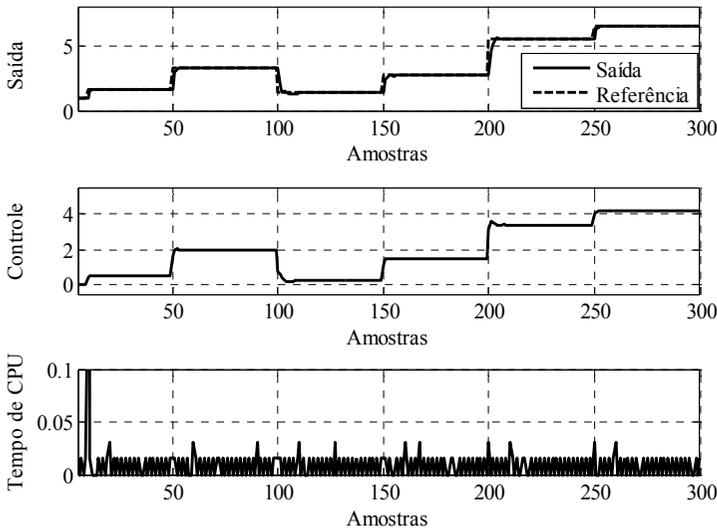
$$\lambda = [1.4 \quad 2.2 \quad 3.1].$$

A seguir, segundo o procedimento geral, deve-se ajustar uma relação quadrática entre os pontos ( $K_e$ ,  $\lambda$ ) obtidos previamente ( $\lambda = \lambda_n (K_e)^2$ ). O valor obtido para  $\lambda_n$  é de 1.5.

A Figura 4.2 mostra o resultado obtido com a aplicação do controle proposto para uma seqüência de mudanças de referência. A aplicação do algoritmo de controle permite obter um seguimento das

referências em concordância com o ajuste realizado no projeto. Observa-se também que o esforço do controle é uniforme e não apresenta picos significativos.

Neste exemplo, o tempo de CPU (*Central Processing Unit*) consumido é menor que 0.05 segundos e é devido, principalmente, ao processo de obtenção do modelo. Observa-se como o tempo de cálculo aumenta quando o sistema de controle precisa recalcular o modelo nas mudanças de referências e no cálculo dos modelos para as perturbações.

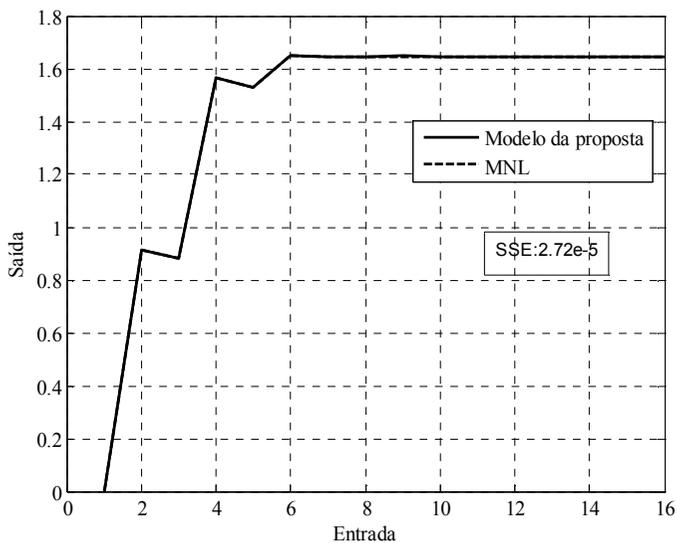


**Figura 4.2:** Seguimento de referência, controle e tempo de CPU com  $\lambda$  variável.

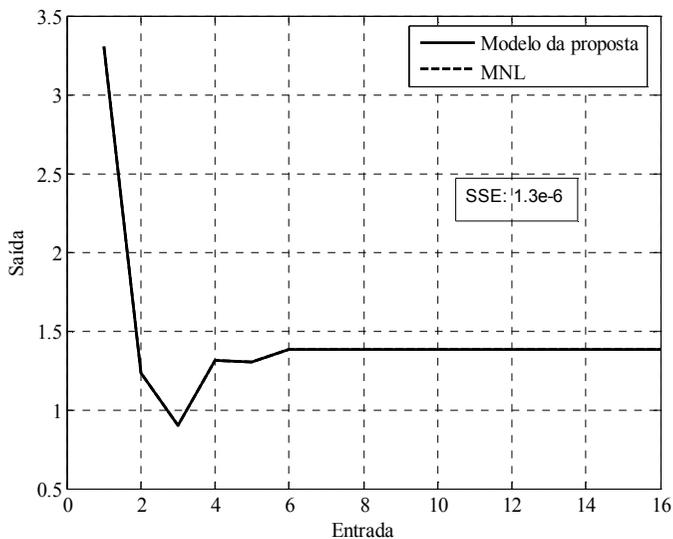
As Figuras 4.3 e 4.4 mostram, respectivamente, a dinâmica do sistema e do modelo linear (ML) calculado para o caso da primeira e terceira mudança de referência, apresentadas na Figura 4.2. O baixo índice SSE (*Sum of Square Error*) registrado avalia a fidelidade do modelo.

A seguir, compara-se a proposta com dois casos para mostrar o efeito do seu comportamento adaptativo sobre a resposta do sistema. No primeiro caso, considera-se constante a penalização de controle, ajustando seu valor para manter o critério de tempo mínimo de

acomodação, sem ultrapassagem, em toda faixa de operação, e o modelo é calculado de acordo com o procedimento da nova proposta.



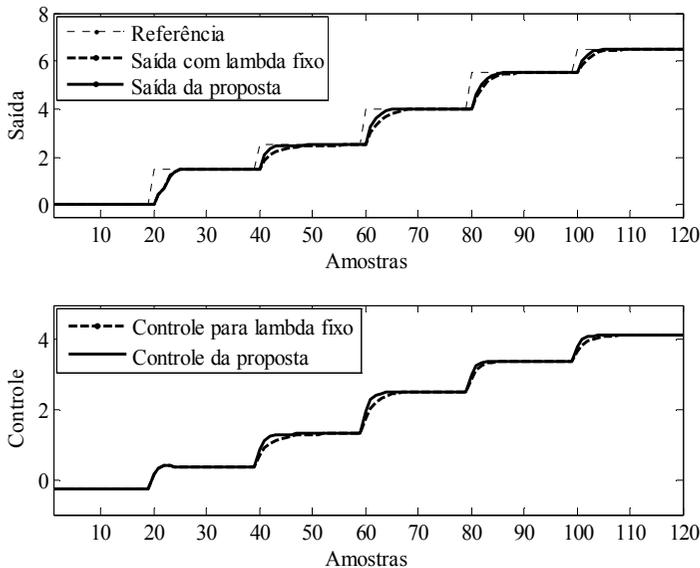
**Figura 4.3:** Saída do MNL e do ML da primeira mudança na referência.



**Figura 4.4:** Saída do MNL e do ML da terceira mudança na referência.

No segundo caso, utiliza-se um único modelo para as predições, calculado no centro da faixa de operação do sistema, e mantém-se o cálculo adaptativo da penalização de controle. Desta forma, o exemplo permite ilustrar o efeito da adaptação da dinâmica e do ganho do controle proposto.

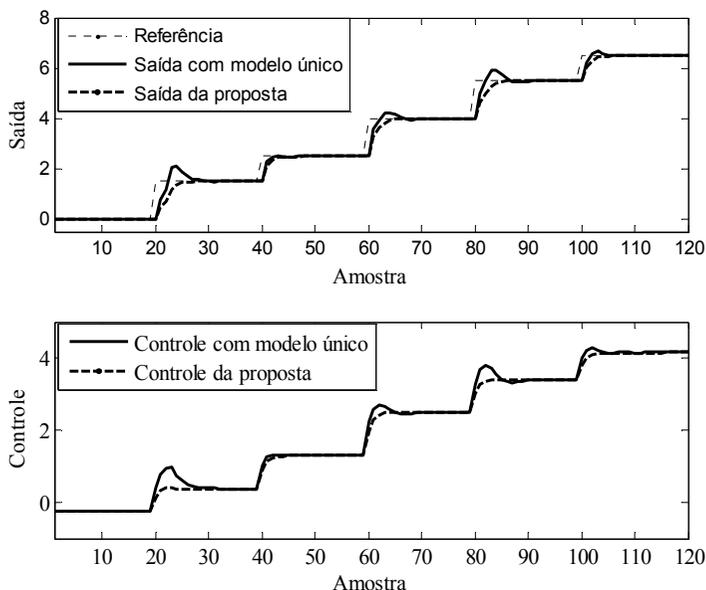
Na Figura 4.5, apresentam-se os resultados da primeira comparação, o caso de penalização de controle constante,  $\lambda=8$ . Para a proposta utiliza-se o  $\lambda_n=1.5$ . Observam-se diferenças nos tempos de acomodação em algumas das mudanças de referências. Neste exemplo o efeito não é muito importante em termos de mudança do padrão da resposta, mas nota-se que em alguns casos o sistema proposto tem tempo de acomodação até 50% menor. Este comportamento é justificável dado que o sistema apresenta pouca variação do ganho estático, portanto um lambda fixo ainda pode produzir uniformidade na resposta e no controle do sistema em toda sua faixa de operação. Esta diferença pode ser muito maior para sistemas com características estáticas que apresentem um grau de não linearidade mais forte, como veremos mais adiante.



**Figura 4.5:** Seguimento de referência e controle aplicando a proposta com  $\lambda_n=1.5$ .

No segundo caso de comparação observa-se, na Figura 4.6, como a saída e o controle apresentam diferentes tempos de acomodação, com níveis de ultrapassagem consideráveis em algumas das mudanças de referências. Isto ocorre porque o sistema apresenta comportamentos dinâmicos diferentes na sua faixa de operação. Deve-se considerar que a penalização de controle foi variada, da mesma forma que na proposta, em função do ganho calculado entre pontos de operação consecutivos, mas neste caso o ajuste adaptativo da ponderação do controle tem, como era esperado, pouco efeito.

Para testar o controle na rejeição de perturbações, realizaram-se vários testes. Aplicou-se um degrau de 10%, do valor máximo do controle, na entrada do processo, na amostra 65, e uma perturbação na saída do processo, também de 10% da saída máxima, na amostra 80. A Figura 4.7 mostra a resposta e o controle para ambas as situações.

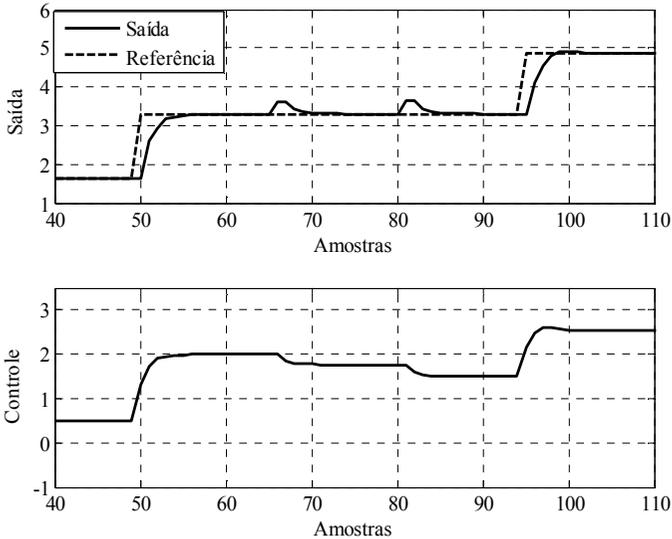


**Figura 4.6:** Seguimento de referência e controle com único modelo linear de predição e  $\lambda_n=1.5$ .

Observa-se que, mesmo mantendo a perturbação na entrada do sistema, o controlador consegue um bom desempenho diante da

perturbação da saída aplicada na amostra 80 e diante de uma nova mudança na referência feita na amostra 93.

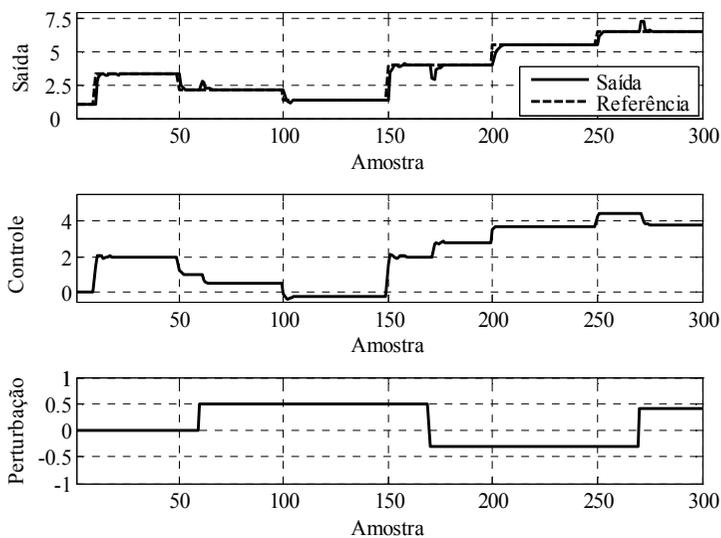
Na Figura 4.8, observa-se o comportamento da saída e o controle para distintas mudanças de referências, e com diferentes níveis de perturbações no controle. O sistema consegue manter um bom controle da saída, mantendo a uniformidade na forma da resposta, mesmo com variações de até 50% no controle em relação ao ponto de operação.



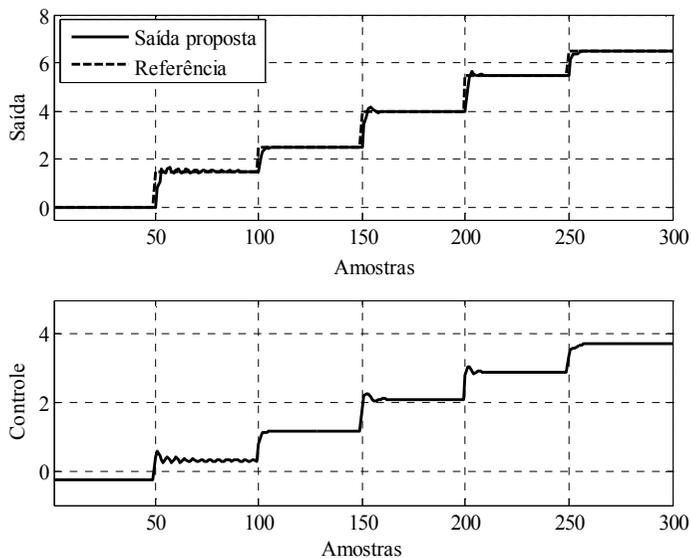
**Figura 4.7:** Saída e controle no caso de perturbação na entrada e saída da planta.

Finalmente, realizam-se variações em todos os parâmetros do sistema da ordem de 10% e testa-se a robustez da proposta nestas condições. Observa-se na Figura 4.9 que o sistema mantém a estabilidade e os tempos de resposta, mas aparecem oscilações nas respostas diante das mudanças de referências, causados pelas diferenças entre o processo e o modelo local nominal determinado pela proposta.

Na próxima seção, o algoritmo é aplicado numa planta de pH com característica fortemente não linear em relação às mudanças de inclinação (ganho) de sua curva característica estática, em toda a sua faixa de operação.



**Figura 4.8:** Referência, saída e controle com perturbação no controle.



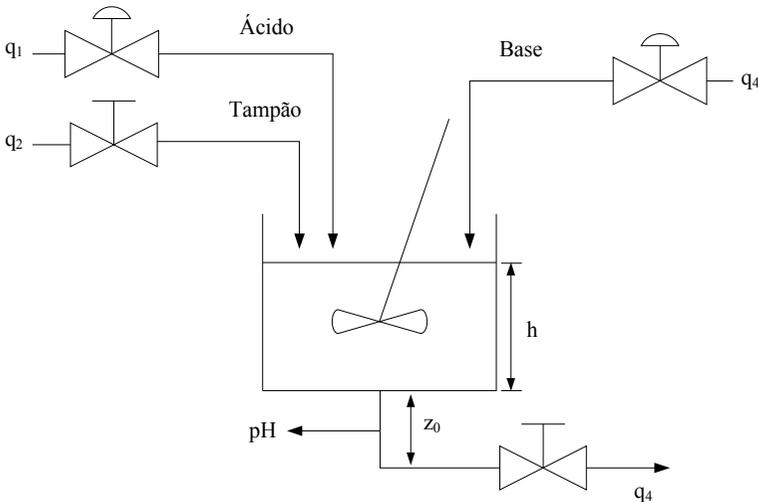
**Figura 4.9:** Referência, saída e controle com variações de 10% nos parâmetros do sistema.

### 4.3. CASO ESTUDO 2: CONTROLE DE PH

Um diagrama esquemático simplificado de uma planta de neutralização de pH mostra-se na Figura 4.10. O processo consiste de uma vazão de ácido ( $q_1$ ), vazão de tampão ( $q_2$ ) e vazão de base ( $q_3$ ) que são misturados no tanque. Para esta aplicação a vazão de ácido e de base é regulada com válvulas de controle de vazão e a vazão do tampão é regulada manualmente com o auxílio de um rotâmetro. A vazão de saída é dependente da altura do fluido dentro do tanque e da posição da válvula de saída que é posicionada manualmente. O objetivo do controle, neste caso, é o controle de pH da vazão de saída  $q_4$ , variando a vazão de entrada de base  $q_3$ . As variáveis medidas são o nível do tanque e o pH.

Os parâmetros nominais para o sistema são resumidos na Tabela 4.1. Uma descrição detalhada do processo encontra-se em Nahas *et al.* (1992) e Henson & Seborg (1994).

Os modelos desenvolvidos para o projeto do controlador preditivo e para a simulação da planta consideram, inicialmente, dinâmicas desprezíveis e sem atraso dos transmissores de nível, pH e válvula de controle. Com estas simplificações obtém-se um modelo não linear no espaço de estados do processo.



**Figura 4.10:** Planta de Neutralização de pH.

**Tabela 4.1:** Condições de operação nominal da planta de pH.

| Parâmetro/<br>variável | Nome                                 | Dimensão            |
|------------------------|--------------------------------------|---------------------|
| $A_1$                  | Área de base do tanque               | 207 cm <sup>2</sup> |
| $z_0$                  | Distância definida na Figura 4.10    | 11.5 cm             |
| $n$                    | Expoente da válvula                  | 0.607               |
| $h$                    | Altura do tanque                     | 14                  |
| $C_v$                  | Coefficiente da válvula              | 4.57                |
| $\tau_v$               | Constante de tempo da válvula        | 6.0 s               |
| $\Theta$               | Tempo morto                          | 10 s                |
| pH                     | pH no ponto de operação              | 7.0                 |
| $q_1$                  | Vazão de ácido no ponto de operação  | 16.6 ml/s           |
| $q_2$                  | Vazão de tampão no ponto de operação | 0.55 ml/s           |
| $q_3$                  | Vazão da base no ponto de operação   | 15.6 ml/s           |
| $q_4$                  | Vazão de saída no ponto de operação  | 32.8 ml/s           |

O equilíbrio químico para o processo é obtido pela definição de duas reações invariantes para cada fluxo de entrada e saída ( $i \in [1,4]$ ):

$$\begin{aligned} W_{ai} &= [H^+] - [OH^-] - [HCO_3^-] - 2[CO_3^{=}], \\ W_{bi} &= [H_2CO_3] + [HCO_3^-] + [CO_3^{=}], \end{aligned} \quad (4.2)$$

onde:

$W_{ai}$ : concentração da espécie invariante referida à carga (M) e

$W_{bi}$ : concentração do íon carbonato (M).

Definem-se variáveis de estado, perturbações e saída como segue:

$$\begin{aligned} \mathbf{x} &= [W_{a4} \ W_{b4} \ h]^T, \\ y &= \text{pH}, \quad u_c = q_3, \quad d = q_2. \end{aligned} \quad (4.3)$$

O modelo do processo é dado por:

$$\begin{aligned} \dot{\mathbf{x}} &= \mathbf{f}(\mathbf{x}) + \mathbf{g}(\mathbf{x})u_c + \mathbf{p}(\mathbf{x})d, \\ c(\mathbf{x},y) &= 0, \end{aligned} \quad (4.4)$$

onde:

$$\mathbf{f}(\mathbf{x}) = \left[ \frac{q_1}{A_1 x_3} (W_{a1} - x_1) \quad \frac{q_1}{A_1 x_3} (W_{b1} - x_2) \quad \frac{1}{A_1} (q_1 - C_v (h + z_0)^n) \right]^T, \quad (4.5)$$

$$\mathbf{g}(\mathbf{x}) = \left[ \frac{1}{A_1 x_3} (W_{a3} - x_1) \quad \frac{1}{A_1 x_3} (W_{b3} - x_2) \quad \frac{1}{A_1} \right]^T, \quad (4.6)$$

$$\mathbf{p}(\mathbf{x}) = \left[ \frac{1}{A_1 x_3} (W_{a2} - x_1) \quad \frac{1}{A_1 x_3} (W_{b2} - x_2) \quad \frac{1}{A_1} \right]^T, \quad (4.7)$$

e

$$c(x,y) = x_1 + 10^{y-14} - 10^{-y} + x_2 \frac{1 + 2(10^{y-pK_2})}{1 + 10^{pK_1-y} + 10^{y-pK_2}}, \quad (4.8)$$

onde  $pK_1$  e  $pK_2$  são a primeira e segunda constantes de dissociação do ácido fraco,  $H_2CO_3$ .

Derivando  $c(x,y)$ , se obtém:

$$\dot{y} = -\mathbf{c}_y^{-1}(x,y) \mathbf{c}_x(y) [\mathbf{f}(\mathbf{x}) + \mathbf{g}(\mathbf{x})u_c + \mathbf{p}(\mathbf{x})d], \quad (4.9)$$

onde  $\mathbf{c}_y(x,y)$  e  $\mathbf{c}_x(y)$  são:

$$c_y(x,y) = \ln 10 \left[ 10^{y-14} + 10^{-y} + x_2 \frac{10^{pK_1-y} + 10^{y-pK_2} + 4(10^{pK_1-y})(10^{y-pK_2})}{(1 + 10^{pK_1-y} + 10^{y-pK_2})^2} \right], \quad (4.10)$$

$$\mathbf{c}_x(y) = \left[ 1 \quad \frac{1 + 2(10^{y-pK_2})}{1 + 10^{pK_1-y} + 10^{y-pK_2}} \quad 0 \right], \quad (4.11)$$

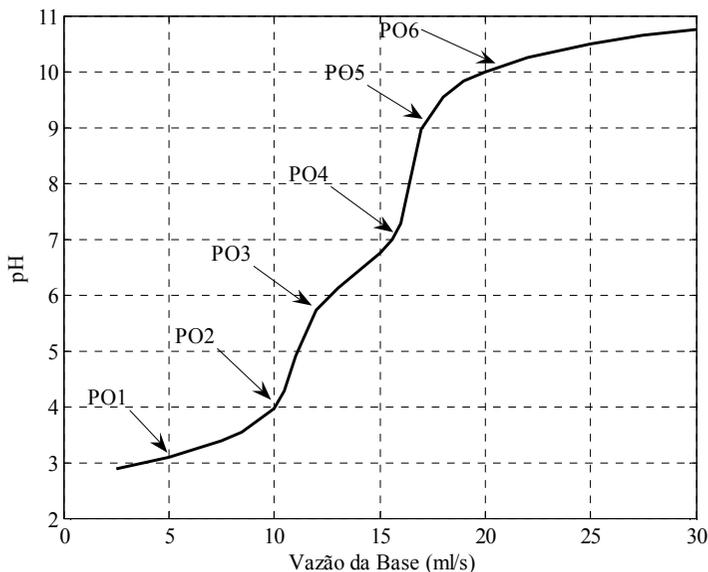
e correspondem respectivamente a

$$c_y(x,y) = \frac{\partial c(x,y)}{\partial y}, \quad c_x(y) = \frac{\partial c(x,y)}{\partial x}. \quad (4.12)$$

Para a aplicação do controle, considera-se o subsistema de controle vazão de base-pH (sistema monovariável). O ganho estático entre a vazão da base e o pH varia conforme se observa na Figura 4.11. Esta curva representa a característica estática do processo de pH.

#### 4.3.1. CONFIGURAÇÃO E AJUSTE DO CONTROLE

Seguindo o procedimento proposto no Capítulo 3, define-se a faixa de operação da planta para pH entre 3 e 11. Dentro desta faixa e de acordo com a característica estática da planta, definem-se 6 pontos de operação estáveis, cada um onde existe mudança de inclinação da característica estática (ver Figura 4.11). Nas provas dinâmicas feitas entre pontos de operação, determinam-se um modelo ARX, assim como a constante de tempo e o ganho  $K_e$  de um modelo de primeira ordem (ver Tabela 4.2). Os testes demonstram que o sistema não apresenta tempo morto. Também, registra-se a variação do controle utilizada,  $\Delta u$ , para determinar os dados usados em cada modelagem.



**Figura 4.11:** Curva característica estática do sistema.

A partir da constante de tempo mínima (60s) determina-se o tempo de amostragem (15s) e escolhe-se para o horizonte de predição

$N=30$  para cobrir o maior tempo de acomodação (aproximadamente 450s) obtido nos testes dinâmicos. O horizonte de controle  $N_u$  foi calculado como 1/3 do horizonte de predição.

Para cada modelo tipo ARX obtido, ajusta-se o controlador com um

mesmo critério de comportamento. O ajuste para cada ponto de operação foi realizado considerando para a saída o menor tempo de acomodação, sem ultrapassagem. A Tabela 4.3 registra os valores dos parâmetros de ajuste do controlador preditivo para cada mudança de PO

Com os dados de ajuste de  $\lambda$  da Tabela 4.3 e os ganhos dos modelos ARX,  $K_e$ , registrados na Tabela 4.2, ajusta-se a seguinte relação quadrática, eq.(4.13), onde  $\lambda_n$  representa o parâmetro a determinar:

$$\lambda = \lambda_n (K_e)^2. \quad (4.13)$$

**Tabela 4.2:** Modelos ARX e parâmetros dinâmicos do sistema.

| Transfe-<br>rência<br>entre POs | $\Delta u$<br>ml/s | Polinômios A e B do Modelo<br>Linear<br>$na=4, nb=4, nk=1$   | $K_e$<br>pH/(ml/s) | $\tau$<br>(s) |
|---------------------------------|--------------------|--|--------------------|---------------|
| PO1 a PO2                       | 5.0                | $A=1-1.9586z^{-1}+1.4227z^{-2}-$<br>$0.4776z^{-3}+0.0674z^{-4}$<br>$B=0.0674-0.0840z^{-1}+0.0336z^{-2}-$<br>$0.0065z^{-3}$ | 0.195              | 60            |
| PO2 a PO3                       | 2.0                | $A=1-1.2123z^{-1}+0.3698z^{-2}-$<br>$0.0401z^{-3}+0.0133z^{-4}$<br>$B=0.1925+0.0171z^{-1}-0.0715z^{-2}-$<br>$0.0233z^{-3}$ | 0.879              | 60            |
| PO3 a PO4                       | 3.7                | $A=1-2.3961z^{-1}+2.0478z^{-2}-$<br>$0.7167z^{-3}+0.0796z^{-4}$<br>$B=0.0729-0.1246z^{-1}+0.0681z^{-2}-$<br>$0.0108z^{-3}$ | 0.379              | 90            |
| PO4 a PO5                       | 1.3                | $A=1-1.4169z^{-1}+0.8807z^{-2}-$<br>$0.2925z^{-3}+0.0012z^{-4}$<br>$B=0.1323-0.0304z^{-1}+0.0933z^{-2}$<br>$+0.0636z^{-3}$ | 1.500              | 90            |
| PO5 a PO6                       | 4.0                | $A=1-2.1300z^{-1}+1.5383z^{-2}-$<br>$0.4211z^{-3}+0.0320z^{-4}$<br>$B=0.0744-0.1171z^{-1}+0.0541z^{-2}-$<br>$0.0066z^{-3}$ | 0.247              | 90            |

A eq.(4.13) representa como visto anteriormente, uma penalização ponderada do controle. Para os valores da Tabela 4.3, obtém-se  $\lambda_n = 100$ .

Finalmente, determina-se um modelo inverso estático (MEI) da planta a controlar. Para obter este modelo, utilizam-se os mesmos dados usados para gerar a curva característica estática.

**Tabela 4.3:** Parâmetros de ajuste do controlador.

| <b>Transferência entre POs</b> | <b>N</b> | <b>N u</b> | <b><math>\lambda</math>: Penalização do Controle</b> |
|--------------------------------|----------|------------|--|
| PO1 a PO2                      | 30       | 10         | 5  |
| PO2 a PO3                      | 30       | 10         | 80   |
| PO3 a PO4                      | 30       | 10         | 11   |
| PO4 a PO5                      | 30       | 10         | 230  |
| PO5 a PO6                      | 30       | 10         | 7  |

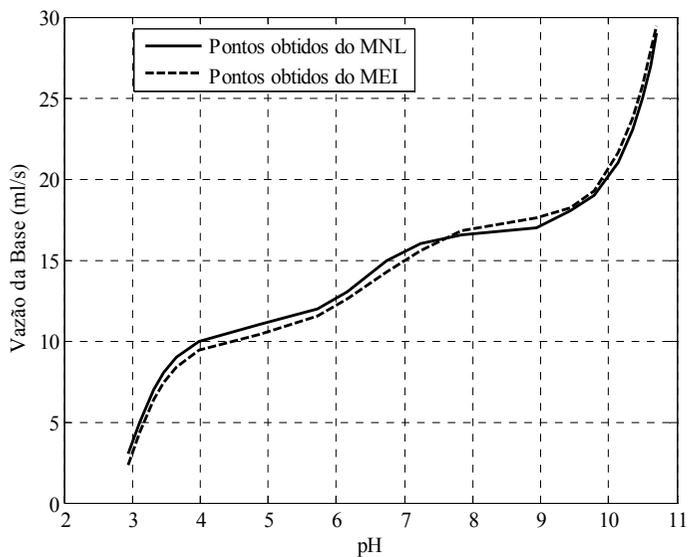
A eq.(4.14) representa o modelo matemático ajustado à característica estática inversa da planta, onde  $x$  é a vazão da base e  $y$  é o pH e a Figura 4.12 o gráfico representa a comparação da curva característica estática obtida do MNL e a curva do MEI calculado.

$$x = 0.02733y^5 - 0.9189y^4 + 11.89y^3 - 74.36y^2 + 226.2y^1 - 259.5. \quad (4.14)$$

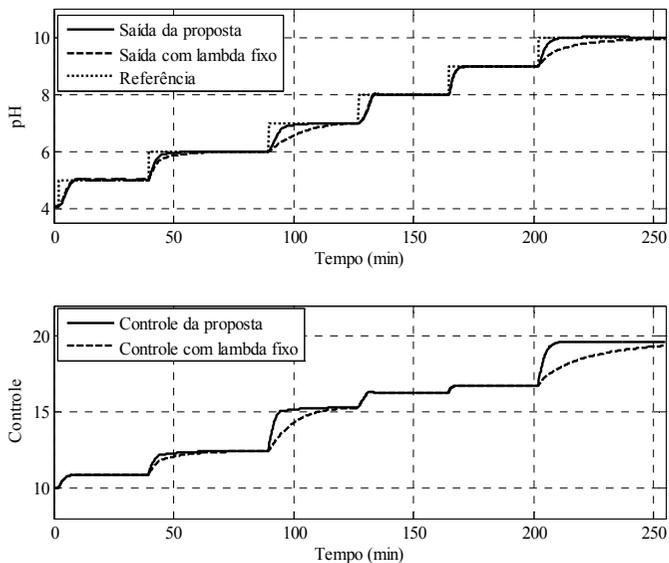
A Figura 4.13 representa os resultados obtidos com o controle proposto para diferentes mudanças na referência e um valor de  $\lambda_n = 100$  e também para uma penalização constante,  $\lambda = 120$ . Observa-se a resposta uniforme da proposta na saída e controle em todo o intervalo de operação da planta. Nas respostas obtidas com  $\lambda$  fixo, apresentam-se tempos de acomodação diferentes, principalmente nas mudanças de referências a pH=7 e pH=10 que correspondem às zonas de menor inclinação da curva característica estática apresentada na Figura 4.11.

Aplicando a mesma metodologia do caso de estudo 1, utiliza-se um único ML para as predições, determinado no centro da CEE, de tal forma que represente a dinâmica da planta, que, segundo os resultados obtidos na Tabela 4.2, possui uma dinâmica similar em toda a sua faixa de operação.

A seguir, realizam-se duas simulações. Na primeira se mantém o



**Figura 4.12:** CEI e curva obtida com MEI.



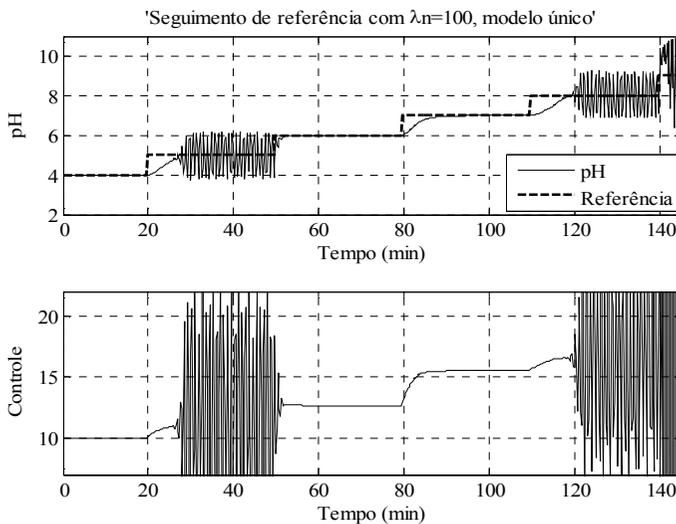
**Figura 4.13:** Seguimento de referência e controle com  $\lambda_n = 100$  e  $\lambda$  constante.

valor de  $\lambda_n=100$  para o cálculo *on-line* da penalização do controle, igual ao utilizado para obter o seguimento de referências mostradas na Figura 4.13. Os resultados são apresentados na Figura 4.14. Observa-se a perda de controle do sistema e como a simulação é abortada no tempo de aproximadamente 150 minutos.

Os polinômios do modelo utilizado apresentam-se a seguir.

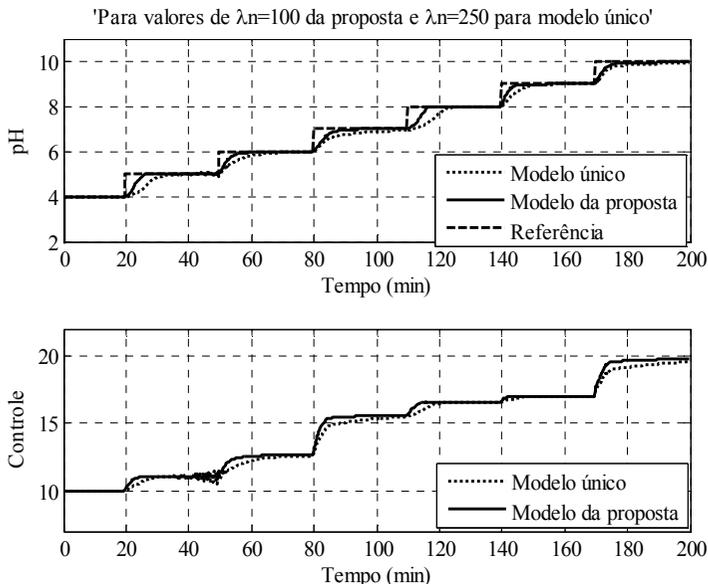
$$A=1.0000-2.3896z^{-1}+2.0688z^{-2}-0.7564z^{-3}+0.0942z^{-3},$$

$$B=0.0624-0.1023z^{-1}+0.0545z^{-2}-0.0088z^{-3}.$$



**Figura 4.14:** Seguimento de referência e controle com modelo único e  $\lambda_n=100$ .

Na segunda simulação, varia-se a constante de normalização da penalização de controle, até obter um comportamento sem oscilações, como aquele apresentado na Figura 4.15, e compara-se a saída da planta com a saída obtida na Figura 4.13 que utiliza a proposta com  $\lambda_n=100$ . Observa-se a vantagem da proposta nos tempos de acomodação e a falta de uniformidade da resposta ao usar um modelo único para as predições.



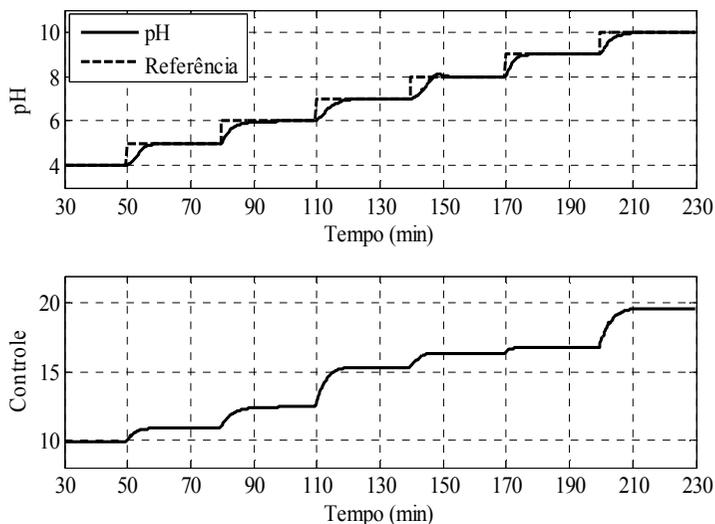
**Figura 4.15:** Referência, saída e controle com modelo da proposta e com modelo único.

#### 4.3.2. COMPARAÇÕES COM OUTRAS TÉCNICAS

Nesta seção comparam-se os resultados do controle proposto com os obtidos em Townsend & Irwin (2001), onde se utilizaram modelos de redes locais e as estratégias LM-GPC e LC-GPC. Utiliza-se a mesma planta e também as mesmas condições dos testes daquele trabalho que não considera restrições.

Para efeitos de comparação, considera-se um novo valor de  $\lambda_n$ , com a finalidade de ajustar as respostas da planta às respostas obtidas em Townsend & Irwin (2001) que apresentam certo nível de ultrapassagem. Deve-se lembrar que, inicialmente, o ajuste para cada ponto de operação foi realizado considerando para a saída o menor tempo de acomodação, sem ultrapassagem.

Como se observa da Figura 4.16, a aplicação do controle gera novamente uma resposta uniforme em todo o intervalo de operação da planta, mas com tempos de acomodação menores e uma pequena ultrapassagem para o pH de 8. Além disso, o sinal de controle tem um comportamento quase sem picos com suaves mudanças de inclinação.



**Figura 4.16:** Seguimento de referência e controle com  $\lambda_n = 40$ .

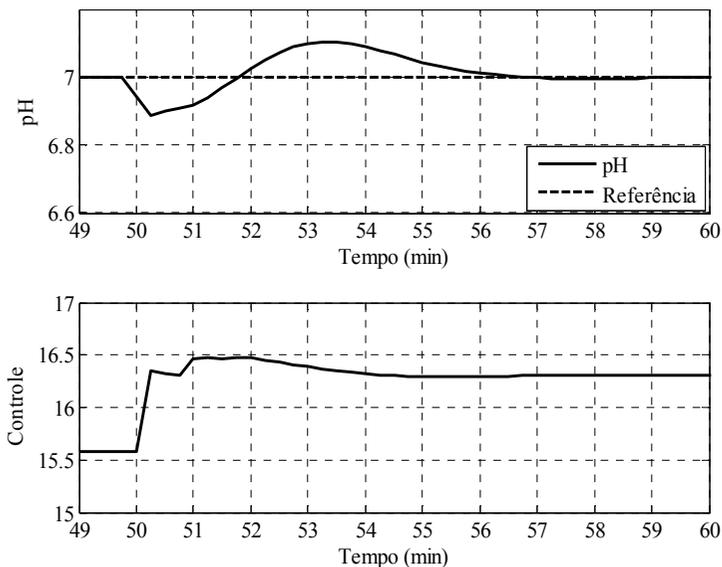
A Tabela 4.4 mostra os resultados do estudo comparativo. Observam-se as vantagens do método em relação à uniformidade dos tempos de acomodação principalmente nas mudanças de referência de pH=7 a pH=8 e de pH=9 a pH=10. Observa-se também que no caso do controlador proposto com  $\lambda$  fixo, os tempos de acomodação e ultrapassagem máxima ainda são melhores que os resultados obtidos em Townsend & Irwin (2001).

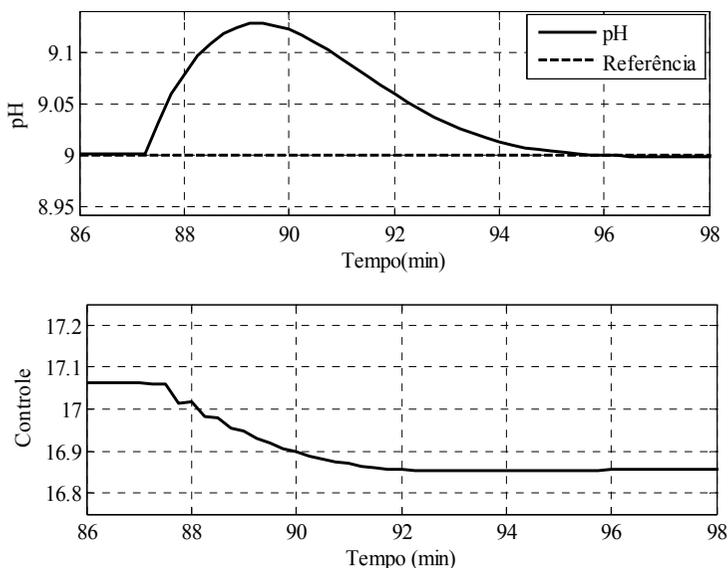
A Figura 4.17 registra o comportamento do controle e da saída da planta frente a perturbações na vazão do tampão ao mudar esta de 0.55 ml/s a 0.15 ml/s e operando no pH de 7.0.

A Figura 4.18 mostra o mesmo experimento de rejeição de perturbações para o ponto de operação pH=9.0.

**Tabela 4.4:** Parâmetros de resposta do LM-GPC, LC-GPC e proposta

| Parâmetros de Resposta      | Referência pH | LM-GPC | LC-GPC | Proposta com $\lambda$ Variável | Proposta com $\lambda=8$ Fixo |
|-----------------------------|---------------|--------|--------|---------------------------------|-------------------------------|
| Tempo de acomodação (min)   | 4 - 5         | 6      | 5      | 5                               | 4                             |
|                             | 5 - 6         | 9      | 6      | 5                               | 5                             |
|                             | 6 - 7         | 9      | 9      | 5                               | 8                             |
|                             | 7 - 8         | 12     | 8      | 6                               | 5                             |
|                             | 8 - 9         | 8      | 4      | 5                               | 4                             |
|                             | 9 - 10        | 16     | 16     | 6                               | 13                            |
| Ultrapassagem em máxima (%) | 4 - 5         | 0      | 5      | 0                               | 0                             |
|                             | 5 - 6         | 0      | 0      | 0                               | 0                             |
|                             | 6 - 7         | 0      | 0      | 0                               | 0                             |
|                             | 7 - 8         | 20     | 50     | 10                              | 20                            |
|                             | 8 - 9         | 0      | 0      | 0                               | 0                             |
|                             | 9 - 10        | 0      | 0      | 0                               | 0                             |

**Figura 4.17:** Resposta a um degrau de perturbação no  $q_2$  com referência no pH de 7.0.



**Figura 4.18:** Resposta a um degrau de perturbação no  $q_2$  com referência no pH de 9.0.

Comparando com os resultados obtidos em Townsend & Irwin (2001), observam-se na Tabela 4.5 vantagens tanto na amplitude como nos tempos de acomodação da saída. Como exemplo, para a referência de pH= 7.0 e aplicando a nova proposta, o pH varia entre 6.9 a 7.12 com um tempo de acomodação de aproximadamente 6 minutos.

**Tabela 4.5:** Parâmetros dinâmicos do LM-GPC, LC-GPC e a proposta com  $q_2= 0.15$  ml/s.

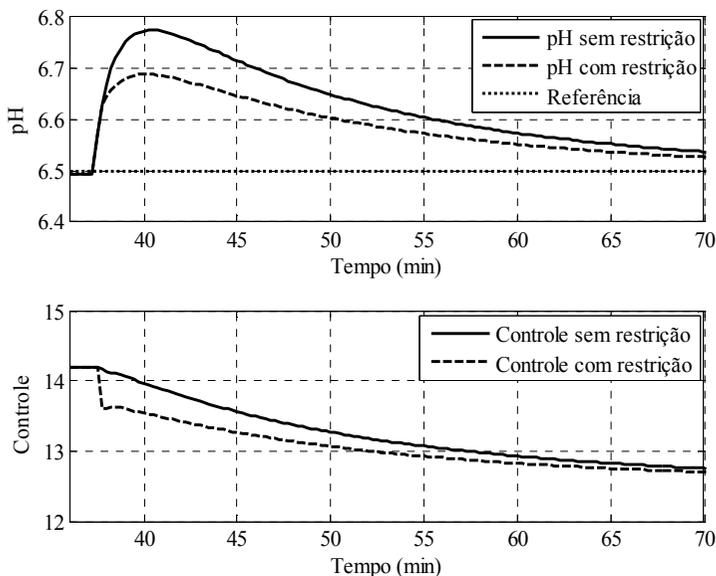
| Parâmetros de Resposta                             | Referência | LC-GPC    | LM-GPC    | Nova Proposta |
|--|------------|-----------|-----------|---------------|
| Tempo de acomodação                                | 7.0        | 10        | 10        | 6             |
|  | 9.0        | 9         | 10        | 8             |
| Faixa de variação da saída em relação à referência | 7.0        | 6.65-7.12 | 6.68-7.14 | 6.90-7.12     |
|  | 9.0        | 8.95-9.13 | 8.94-9.12 | 9.00-9.12     |

Entretanto, em Townsend & Irwin (2001), considerando seu melhor caso, o pH varia entre 6.65 a 7.12 com um tempo de acomodação de aproximadamente 10 minutos.

#### 4.3.3. ANÁLISE DO CASO COM RESTRIÇÕES

Para ilustrar o manejo das restrições do controlador proposto define-se, na saída da planta, uma restrição no pH de 6.7, como limite a não ser ultrapassado. Operando a planta no PO de pH=6.5, aplica-se uma perturbação na vazão do tampão mudando esta de 0.55 ml/s a 0.95 ml/s. A Figura 4.19 mostra a saída e o controle caso sem e com restrições.

Como pode ser observado, o controlador com restrições respeita os limites impostos mantendo a característica suave do sinal de controle. Esta é uma importante vantagem do controle preditivo.



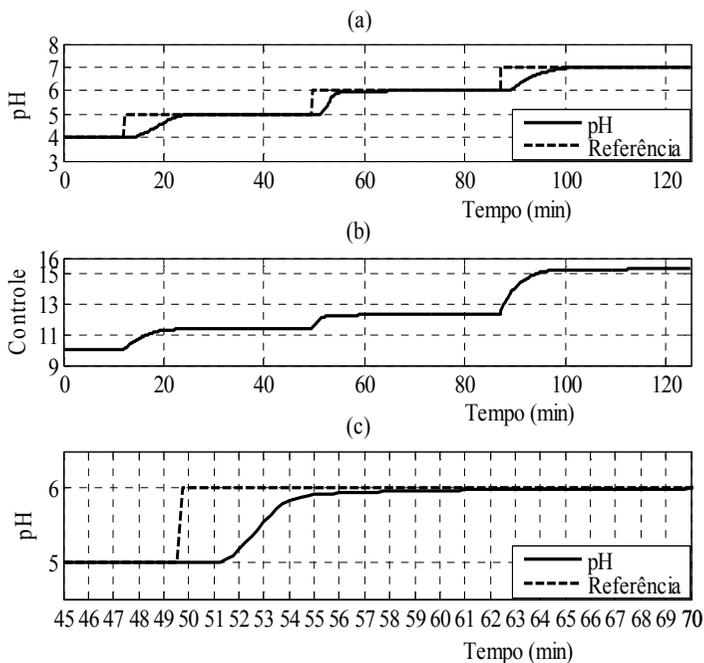
**Figura 4.19:** Respostas a perturbação no  $q_2$  com e sem restrição.

#### 4.3.4. ANÁLISE DO CASO COM TEMPO MORTO

Na seguinte simulação supõe-se que o processo apresenta um tempo morto de 1.5 minutos. O tempo morto considerado é constante

em toda a faixa de operação da planta e pode ser o resultado, por exemplo, do atraso na medição do pH causado pelo transporte do fluido até o medidor e pelo tempo de processamento do sensor. Neste caso o parâmetro  $dk$ , do modelo linear, se mantém constante e igual a 8.

Ressalta-se que, para alguns dos pontos de operação, registrados na Tabela 4.2, o atraso é maior que a constante de tempo respectiva. As Figuras 4.20(a) e 4.20(b) registram, respectivamente, a saída da planta e o controle para distintas mudanças na referência. Observa-se que se mantêm as mesmas características de comportamento da saída do sistema sem tempo morto, apresentadas na Figura 4.13. A Figura 4.20(c) mostra, em detalhe, a saída da planta quando a referência vai de  $\text{pH}=5$  a  $\text{pH}=6$ .



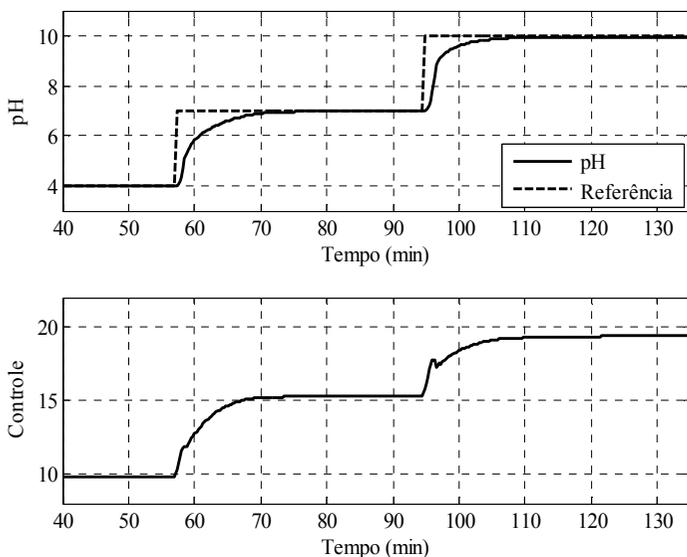
**Figura 4.20:** Respostas a mudanças de referências considerando tempo morto no processo.

Pode-se observar, nesta última figura, que o tempo morto é de 1.5 minutos e que a saída da planta tem uma resposta de acordo com o

critério de comportamento estipulado no projeto. Esta é outra importante vantagem do controle preditivo.

#### 4.3.5. MUDANÇAS MAIORES NA REFERÊNCIA

Finalmente, aplicam-se duas mudanças de referências de maior amplitude para testar o algoritmo em outras situações onde o efeito das não linearidades é mais importante. A Figura 4.21 mostra os resultados obtidos. Observa-se a uniformidade das respostas em tempos de acomodação, ultrapassagem e também no esforço de controle.



**Figura 4.21:** Seguimento de referência e controle com  $\lambda$  variável.

#### 4.4. CONCLUSÕES

Neste capítulo, a nova proposta foi aplicada em dois casos bem conhecidos na literatura. Em ambos os casos o algoritmo proposto mostrou-se bastante simples e eficiente para estabelecer a variável controlada no novo ponto de operação e rejeitar satisfatoriamente as perturbações. O tempo de computação *on-line* é reduzido a um simples processo de modelagem e de otimização quadrática. Pode-se observar, nesta última figura, que o tempo morto é de 1.5 minutos e que a saída da

planta tem uma resposta de acordo com o critério de comportamento estipulado no projeto. Esta é outra importante vantagem do controle preditivo.

No exposto, observam-se as vantagens do método em relação à uniformidade dos tempos de acomodação em comparação a outros métodos. Observa-se também que, com o ajuste de um só parâmetro, é possível obter diferentes tempos de acomodação, mantendo uniformidade na saída e controle em toda a faixa de operação da planta. Este procedimento de ajuste *on-line* do  $\lambda$  não foi proposto, até o momento, na literatura de controle não linear.

Ressalta-se também que mesmo com um atraso maior que a constante de tempo respectiva, ou com variações fortes de pontos de operação, o sistema mantém as características de comportamento definidas.

Estes casos de estudo também permitem confirmar que os modelos lineares direcionados da proposta representam apropriadamente a dinâmica não linear do sistema a controlar, principalmente diante das mudanças de referências. Esta forma de obter os modelos locais não foi registrada, até o momento, na literatura referente a controle não-linear.



## CAPÍTULO 5

### CONTROLE DA PLANTA AQUASOL

#### 5.1. INTRODUÇÃO

O uso da energia solar como fonte de calor de processos térmicos industriais tem aumentado nos últimos anos. Nestes sistemas se usam coletores solares para captar a energia solar. A temperatura de saída do fluido dos coletores solares pode ser controlada manipulando a vazão deste fluido. Entretanto, devem-se considerar vários fatores que afetam grandemente o uso desta energia. Como exemplos se podem citar o ciclo solar, o nível de nublado e as condições atmosféricas (Roca *et al.*, 2009).

Na literatura científica existem numerosas técnicas de controle avançado aplicadas em campos solares, como controle preditivo, controle adaptativo, controle ótimo, controle *fuzzy* e controle robusto (Camacho *et al.*, 2007). Vários podem ser os usos da energia armazenada pelo fluido quente que circula pelos coletores. Um exemplo é o uso para obter água destilada a partir de água do mar, como na planta AQUASOL, localizada na Plataforma Solar de Almeria (Espanha).

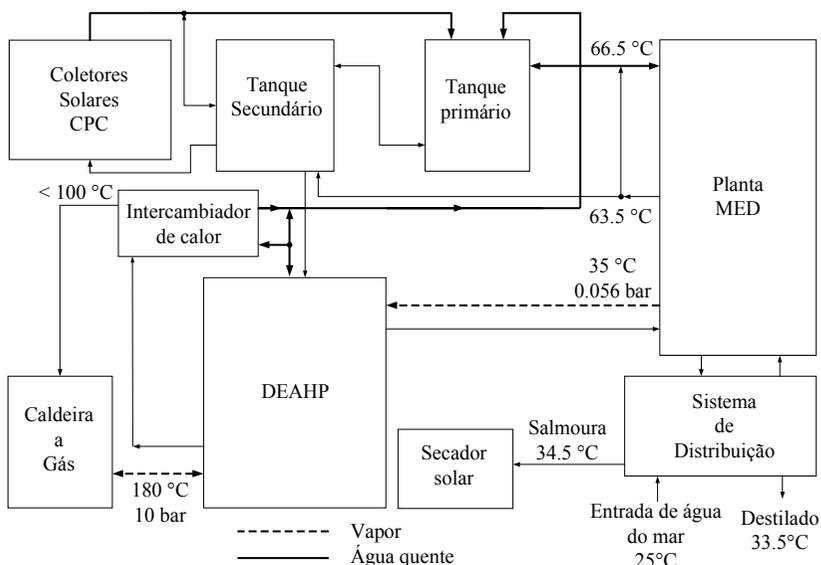
Neste capítulo apresenta-se uma aplicação do algoritmo proposto à planta solar AQUASOL indicada anteriormente. Este tipo de planta pode ser considerado como um sistema com não linearidade severa, em virtude do ganho variar mais de 100%, especialmente quando a radiação solar é afetada pelas nuvens. Além disso, o problema de controle é agravado pelo fato de que o processo exibe um tempo morto variável.

As seções seguintes apresentam uma descrição da planta AQUASOL, um modelo simplificado do processo, o projeto do controlador, os resultados das simulações e os testes na planta real.

#### 5.2. DESCRIÇÃO DO SISTEMA

O sistema desalinizador de água de mar AQUASOL, mostrado na Figura 5.1, é formado por uma planta de destilação multi-efeito (MED), um campo coletor solar concentrador parabólico composto (CPC) estacionário, um sistema armazenador térmico baseado em água, uma bomba de absorção de calor de duplo efeito, DEAHF, (LiBr-H<sub>2</sub>O), uma caldeira e um avançado secador solar para o tratamento final da salmoura (Alarcon-Padilla *et al.*, 2005). O fluido de transferência de calor é água, esquentada por coletores solares. Assim, a energia solar é

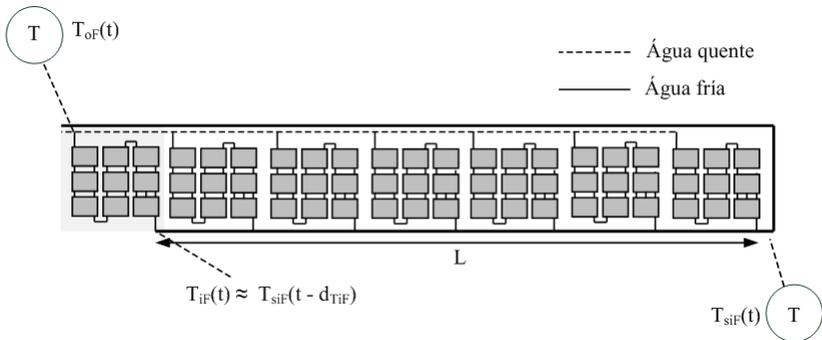
convertida em energia térmica, na forma de água quente, e então é armazenada em tanques. A energia térmica requerida pela planta MED é fornecida pela água quente desde o sistema de armazenamento. Na ausência de radiação solar, a caldeira alimenta o DEAHF. Este é também alimentado com um fluxo a baixa temperatura, desde o último efeito da planta MED, com o objetivo de incrementar a entalpia da água circulando dentro dos tubos do intercambiador de calor. O campo coletor solar está formado de 252 CPCs em quatro filas, ou malhas, de 63 coletores dispostas em sete grupos de nove coletores conectadas em paralelo, em cada uma das malhas (ver Figura 5.2).



**Figura 5.1:** Layout básico da planta AQUASOL.

### 5.3. MODELO SIMPLIFICADO DO CAMPO SOLAR

Como se descreve em Roca *et al.* (2008), a temperatura de saída do coletor solar,  $T_{of}$ , pode ser modelada considerando o comportamento de um hipotético tubo absorvedor equivalente, com o mesmo comportamento do campo solar completo. Este tubo equivalente é caracterizado por uma vazão mássica equivalente  $\dot{m}_{eq}$ , que depende da vazão mássica de entrada do campo solar,  $\dot{m}_F$ , número de malhas operativas do campo solar,  $n_i$ , número de grupo de coletores em cada



**Figura 5.2:** Uma malha do campo coletor solar.

uma das malhas,  $n_c$ , número de conexões paralelas conectadas em cada um dos grupos,  $n_{cp}$ , e o número de tubos absorvedores em cada coletor,  $n_a$ , expressada em

$$\dot{m}_{eq} = \frac{\dot{m}_F}{n_l n_c n_{cp} n_a} \quad (5.1)$$

O tubo absorvedor equivalente é também caracterizado por seu comprimento,  $L_{eq}$ , que depende do comprimento do tubo absorvedor real,  $L_a$ , e do número de conexões séries em cada subgrupo,  $n_{cs}$ ,

$$L_{eq} = L_a n_{cs} \quad (5.2)$$

Assim, a saída do campo solar do tubo equivalente varia em função da irradiação,  $I$ , temperatura ambiente,  $T_a$ , temperatura de entrada do campo solar,  $T_{iF}$ , e uma vazão volumétrica equivalente de acordo com a seguinte relação:

$$\rho C_p A \frac{\partial T_{oF}(t)}{\partial t} = \beta_1 I(t) - \frac{H}{L_{eq}} (\bar{T} - T_a(t)) - C_p \dot{m}_{eq}(t) \left( \frac{T_{oF}(t) - T_{iF}(t)}{L_{eq}} \right) \quad (5.3)$$

conforme os parâmetros da Tabela 5.1.

A temperatura absorvida é modelada como temperatura média,  $\bar{T}$ , entre as temperaturas de entrada e saída da água

$$\bar{T} = \frac{T_{oF}(t) + T_{iF}(t)}{2} \quad (5.4)$$

É importante mencionar que a potência solar incidente no coletor é representada na eq.(5.3) por meio de um parâmetro global  $\beta_1$ , que inclui não só a abertura do coletor e eficiência, mas também um fator de atenuação porque a irradiação, coletada pelo coletor de irradiação, não é global, mas é radiação direta e uma fração de radiação difusa que depende da concentração sobre o coletor.

**Tabela 5.1:** Registro dos parâmetros e variáveis associadas ao modelo do processo.

| Parâmetros/<br>Variáveis | Nome  | Unidades          |
|--------------------------|---|-------------------|
| $C_p$                    | Capacidade térmica específica                   | J/kg/°C           |
| $A$                      | Área da seção do coletor solar (CPC)            | m <sup>2</sup>    |
| $\beta_1$                | Parâmetro global                                | --                |
| $H$                      | Coefficiente de perda térmica                   | J/s/K             |
| $L_{eq}$                 | Comprimento do tubo absorvedor equivalente      | m                 |
| $\rho$                   | Densidade da água                               | kg/m <sup>3</sup> |
| $I$                      | Irradiação                                      | w/m <sup>2</sup>  |
| $T_{iF}$                 | Temperatura de entrada do campo solar           | °C                |
| $T_{oF}$                 | Temperatura de saída do campo solar             | °C                |
| $T_a$                    | Temperatura ambiente [°C]                       | °C                |
| $\dot{m}_{eq}$           | Vazão mássica equivalente                       | kg/s              |
| $L_s A$                  | Produto comprimento-área seção de tubo da malha | m <sup>3</sup>    |

Em virtude do sensor da temperatura de entrada estar localizado no começo da malha, existe um atraso de transporte,  $d_{TiF}$ , entre a temperatura da água de entrada no coletor  $T_{iF}$  e a temperatura no sensor  $T_{sIF}$ , que pode ser estimado para cada tempo de amostragem como um atraso dependente da vazão  $d_{TiF}$ , como é registrado em Roca *et al.* (2009) tal que

$$T_{iF} \approx T_{sIF}(t - d_{TiF}), \quad (5.5)$$

onde  $d_{TiF}$  pode ser estimado, usando os valores de vazão aplicados no processo, como:

$$d_{TiF} = T_s \sum_{i=1}^{n_s} \frac{n_s}{n_c - i} \cdot d_i, \quad (5.6)$$

com  $d_1$  sendo o atraso de transporte da seção 1, expressado em tempos de amostragem, que é calculado usando o comprimento de uma seção,  $L_s$ :

$$L_s \cdot A = T_s \sum_{i=0}^{i=d_1-1} f(k-i), \quad (5.7)$$

sendo  $f$  a vazão na primeira seção e  $k$  o tempo de amostragem.

É importante mencionar que este tempo não está incluído diretamente no algoritmo de controle. A perturbação,  $T_{iF}$ , é estimada a cada tempo de amostragem usando as medidas passadas da temperatura de entrada,  $T_{siF}$ , e avaliando o atraso  $d_{TiF}$  com as vazões passadas. Esta estimativa da temperatura é então uma aproximação da temperatura da água de entrada ao coletor solar e assim é usada no modelo do controlador preditivo.

Provas em Roca *et al.* (2008) têm demonstrado a existência de um atraso ( $d$ ) na temperatura do fluxo de saída. O atraso nominal  $d$  é de 40s, com uma variabilidade de 25% ( $d \in [30,50]$ s). Este atraso observado é produto de três causas diferentes:

- Um atraso de transporte da água nas conexões do grupo de coletores;
- Um atraso no fluxo de saída causado pela dinâmica de transferência de calor dos elementos diferenciais, dentro dos tubos absorvedores;
- Em alguns casos individuais, mudanças no fluxo produzem perturbações no grupo de coletores e tubos absorvedores. Observe que o processo foi modelado como uma coleção de tubos absorvedores com as mesmas características e comportamento. Esses desequilíbrios hidráulicos produzem diferenças dinâmicas nos tubos absorvedores e então um atraso aparece no sistema.

Finalmente, mostra-se na eq.(5.8) a expressão que relaciona a entrada  $\dot{m}_{eq}$ , a saída  $T_{oF}$  e o tempo de atraso,  $d$ , do processo a controlar.

$$\rho C_p A \frac{\partial T_{oF}(t)}{\partial t} = \beta_1 I(t) - \frac{H}{L_{eq}} (\bar{T} - T_a(t)) - C_p \dot{m}_{eq}(t-d) \left( \frac{T_{oF}(t) - T_{iF}(t)}{L_{eq}} \right). \quad (5.8)$$

Os parâmetros da planta AQUASOL se apresentam na Tabela 5.2.

**Tabela 5.2:** Valores dos parâmetros da planta.

| <b>Parâmetro</b> | <b>Dimensão</b>           |
|------------------|---------------------------|
| $C_p$            | 4190 J/kg/°C              |
| $A$              | 1.753e-004 m <sup>2</sup> |
| $\beta_1$        | 0.64                      |
| $H$              | 4 J/s/K                   |
| $L_{eq}$         | 5.67 m                    |
| $\rho$           | 975 kg/m <sup>3</sup>     |
| $n_c$            | 3                         |
| $n_{cp}$         | 7                         |
| $n_a$            | 7                         |
| $L_{sA}$         | 0.0055m <sup>3</sup>      |

#### 5.4. PROJETO DO CONTROLADOR

Nesta seção, desenvolve-se o projeto do controlador de acordo com a metodologia proposta no Capítulo 3.

Passo 1. Definição do intervalo de operação da planta e restrições do controle e da saída, caso existam.

Intervalo de operação da planta

- $T_{of}$  de 40°C a 90°C.

As restrições no controle (vazão) dependem da operação do campo. Uma vazão mínima de água deve ser assegurada com o propósito de manter, tanto quanto possível, o equilíbrio dinâmico no campo solar. Também, as características da bomba estabelecem a máxima vazão de água de entrada dependendo do número de malhas operativas,  $n_i$ . Assim quando  $n_i=2$  se usam os limites:

- Mínima vazão de entrada = 1.2 l/s,
- Máxima vazão de entrada = 2.0 l/s.

e quando  $n_i=4$ :

- Mínima vazão de entrada = 1.2 l/s,

- Máxima vazão de entrada = 4.5 l/s.

Mediante a eq.(5.1), e em m<sup>3</sup>/s, calcula-se, em cada caso, a vazão volumétrica de água de entrada no tubo absorvedor equivalente, ou seja:

$$\dot{m}_{\text{eqv}} = \frac{\dot{m}_F}{n_1 * 3 * 7 * 7 * 1000}. \quad (5.9)$$

Passos 2 e 3. Curva característica estática do processo, dentro de sua faixa de operação, e modelo estático inverso da planta. Neste passo se escolheram quatro pontos de operação.

A Figura 5.3 registra a curva característica estática, para I=750 (w/m<sup>2</sup>), T<sub>a</sub>=23°C e T<sub>IF</sub>=60°C, e também os pontos de operação escolhidos. Observe que as inclinações têm aproximadamente o dobro do valor entre POs consecutivos.

O modelo estático inverso foi obtido analiticamente neste caso e está representado por

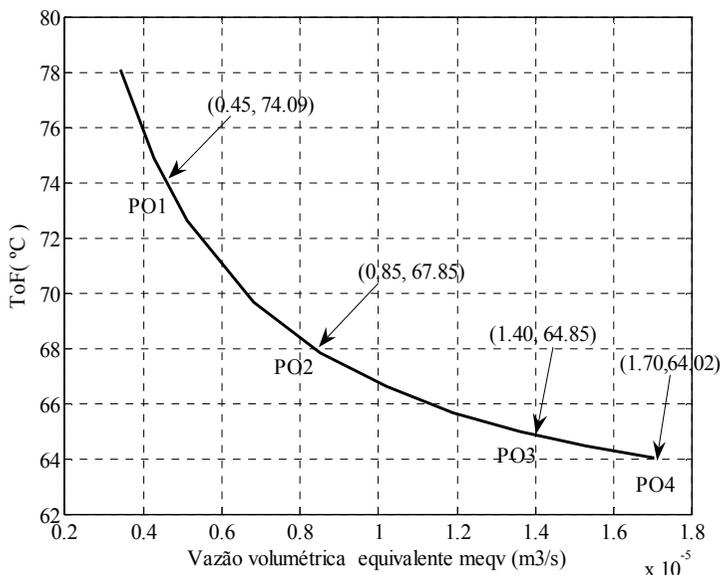
$$\dot{m}_{\text{eq}} = \left( \frac{\beta_1 L_{\text{eq}}}{\rho C_p (T_{\text{of}} - T_{\text{if}})} I \right) - \left( \frac{H}{\rho C_p (T_{\text{of}} - T_{\text{if}})} (\bar{T} - T_a) \right) \quad (5.10)$$

As equações 5.9 e 5.10 permitem determinar a vazão necessária  $\dot{m}_{\text{eqv}}$  (m<sup>3</sup>/s) para levar a planta a uma nova referência, frente às condições particulares de irradiação, temperatura ambiente e temperatura na entrada do campo solar.

Passos 4 e 5. Obtenção de modelos ARX e parâmetros dinâmicos entre pontos de operação. A Tabela 5.3 mostra os resultados destes testes.

A partir da constante de tempo mínima (1.17 min), determina-se o tempo de amostragem, T<sub>s</sub>=5s, e escolhe-se para o horizonte de predição N=100 para cobrir, aproximadamente, o maior tempo de acomodação obtido nos testes dinâmicos. O horizonte de controle N<sub>u</sub> foi calculado como 1/3 do horizonte de predição.

O atraso que será usado no modelo é o encontrado nas provas experimentais apresentadas em Roca *et al.* (2008), com valor nominal de 40s, com uma variabilidade de 25%. Esta variabilidade não pode ser atribuída ao ponto de operação e será considerada como erro de modelagem para o ajuste do DTC-GPC.



**Figura 5.3:** Pontos de operação da planta a controlar.

**Tabela 5.3:** Parâmetros dinâmicos entre pontos de operação.

| Transferência entre POs | Modelo ARX   | Ganho $K_e$ (°C/m <sup>3</sup> /s) (x10 <sup>6</sup> ) | $\tau$ (min) |
|-------------------------|--|--|--------------|
| PO1 - PO2               | $A=1.0000-0.9131z^{-1}$ ,<br>$B=-1.3600 \times 10^5$ | -1.5657  | 2.00         |
| PO2 - PO3               | $A=1.0000-0.8637z^{-1}$ ,<br>$B=-7.4201 \times 10^4$ | -0.5443  | 1.33         |
| PO3 - PO4               | $A=1.0000-0.8378z^{-1}$ ,<br>$B=-4.4698 \times 10^4$ | -0.2756  | 1.17         |

**Passo 6.** Ajusta-se o controlador preditivo para cada um dos modelos ARX, considerando-se as restrições da saída e do controle e mantendo um critério de comportamento uniforme.

A Tabela 5.4 apresenta os parâmetros de sintonia para os POs definidos no passo 3. O critério de comportamento para a determinação das penalizações de controle estabeleceu-se como: mínimo tempo de acomodação com nível de ultrapassagem máxima de 10%. Esse comportamento é apresentado na Figura 5.4.

**Tabela 5.4:** Parâmetros de Ajuste.

| <b>Transferência entre POs</b> | <b>Ganho Ke (°C/m<sup>3</sup>/s) (x10<sup>6</sup>)</b> | <b>λ (x10<sup>14</sup>)</b> |
|--------------------------------|--|-----------------------------|
| PO1 - PO2                      | -1.5657  | 2.50                        |
| PO2 - PO3                      | -0.5443  | 0.35                        |
| PO3 - PO4                      | -0.2756  | 0.05                        |

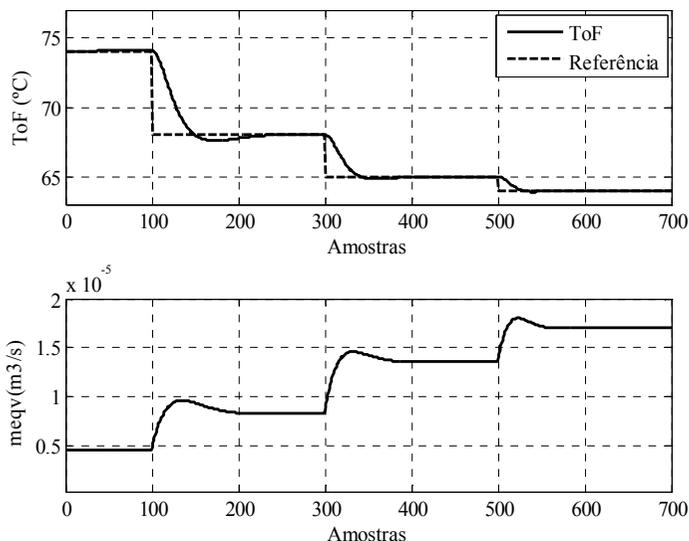
Passo 7. Ajusta-se a relação quadrática, apresentada na eq. (5.11), entre os ganhos (Ke) dos modelos obtidos no Passo 5 e as penalizações de controle obtidas no Passo 6, referentes a cada PO (Tabela 5.5). O valor obtido deste ajuste para  $\lambda_n$  é 100.

**Tabela 5.5:** Parâmetros dinâmicos para cada PO.

| <b>Transferência entre POs</b> | <b>Ganho Ke (x10<sup>6</sup>) (°C/m<sup>3</sup>/s)</b> | <b>λ (x10<sup>14</sup>)</b> |
|--------------------------------|--|-----------------------------|
| PO1 - PO2                      | -1.5657  | 2.50                        |
| PO2 - PO3                      | -0.5443  | 0.35                        |
| PO3 - PO4                      | -0.2756  | 0.05                        |

$$\lambda = \lambda_n (Ke)^2. \quad (5.11)$$

A eq.(5.11) representa uma penalização ponderada do controle. Para o cálculo do valor a ser usado em cada situação de operação, utiliza-se o ganho Ke do modelo obtido em tempo real.



**Figura 5.4:** Resposta em malha fechada e sinal de controle para os POs escolhidos.

## 5.5. SIMULAÇÕES PRÉVIAS

Nesta seção, apresentam-se os resultados das simulações do controle da temperatura de saída do campo solar, usando o algoritmo de controle com os parâmetros obtidos na seção 5.4.

O objetivo principal do sistema de controle é manter a diferença de temperatura entre a entrada e a saída de 5°C e 20°C para otimizar a eficiência do coletor e evitar o *stress* no material do CPC, assim, as referências de simulação foram fixadas em  $T_{if} + \Delta T$ .

As duas simulações a seguir, ilustram o desempenho do controlador proposto num dia parcialmente nublado e um dia ensolarado. Os dados utilizados nas perturbações são reais.

As restrições de entrada são os seguintes. A mínima vazão de entrada se fixou em 1.2l/s, já a máxima teve dois ajustes. No experimento do dia nublado se utilizou  $n_1=2$ , e máxima vazão de entrada=2.0l/s. No dia ensolarado se usou  $n_1=4$  e máxima vazão de entrada=4.5l/s.

O atraso da planta foi fixado em 50s, para analisar o efeito de um erro de modelagem de 10s e reproduzir uma situação próxima da real.

Depois de realizar alguns testes com os parâmetros de sintonia determinados previamente, escolheram-se os seguintes parâmetros para o controlador preditivo:

- $T_s = 5s$ ,
- $N = 60$ ,
- $N_u = 20$ ,
- $\alpha = 0.8$ ,
- $\lambda_n = 50$ .

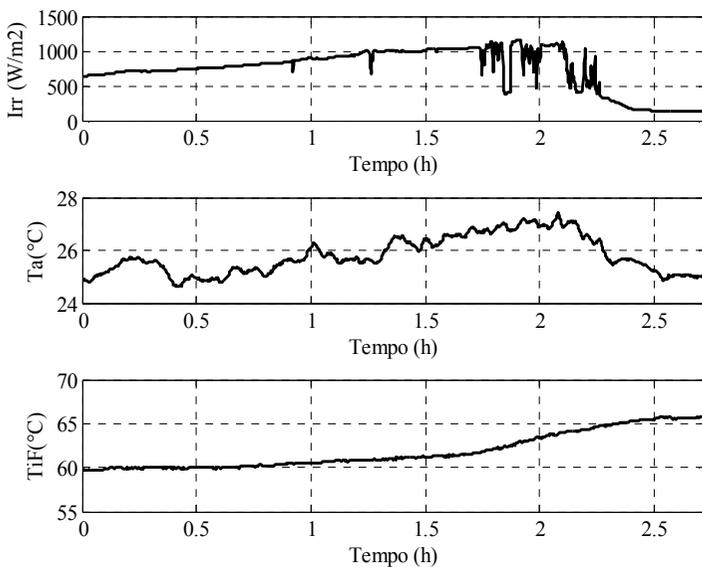
Os resultados das simulações são apresentados a seguir.

### 5.5.1. DIA PARCIALMENTE NUBLADO

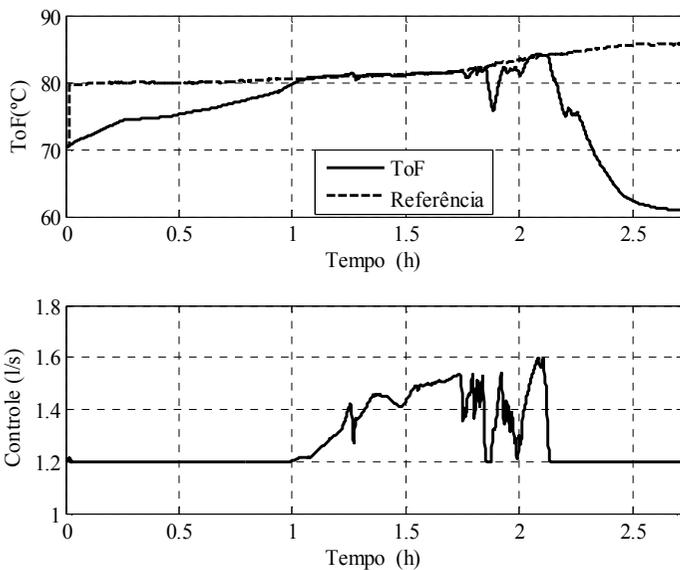
A Figura 5.5 mostra as entradas (perturbações) na planta real em 12 de Junho de 2008, começando aproximadamente às 9hs, num dia nublado.

A radiação solar varia levemente no início da operação, mas apresenta grandes variações no final do experimento, devido a efeitos das nuvens. A temperatura ambiente está na faixa de 25°C a 27.5°C, aproximadamente. A temperatura de entrada  $T_{iF}$  varia lentamente de 60°C a 66°C. A referência é estabelecida com 20 graus acima da entrada,  $T_{iF}+20^\circ\text{C}$ .

A Figura 5.6 registra o resultado da simulação com o controlador proposto. Inicialmente, e por efeito da saturação observada no controle, a temperatura de saída demora um tempo apreciável (1h) para alcançar a referência. Porém, a partir deste ponto o controlador segue a referência adequadamente. Entre  $t=1.7\text{h}$  e  $t=2.3\text{h}$  observam-se algumas oscilações no sinal do controle devido às fortes perturbações na radiação solar. Depois desta faixa, a partir de  $t=2.3\text{h}$ , a saída não pode seguir a referência porque a radiação solar não é capaz de esquentar a água.



**Figura 5.5:** Entradas no processo real, dia parcialmente nublado.



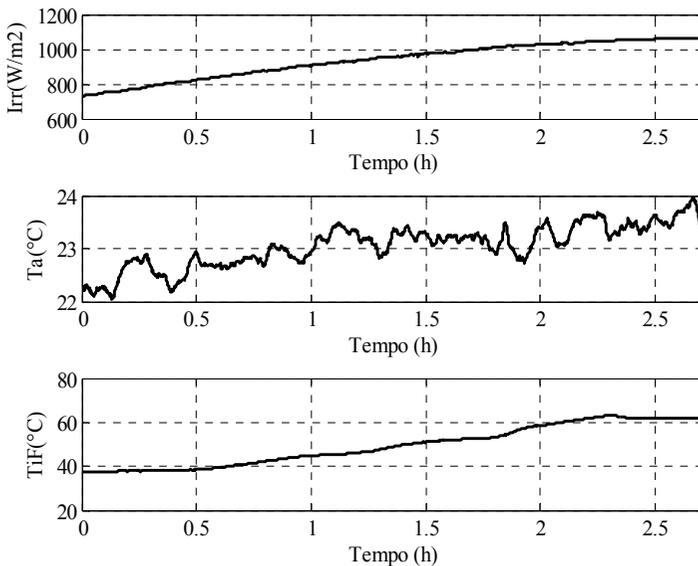
**Figura 5.6:** Saída e controle no caso dia parcialmente nublado.

### 5.5.2. DIA ENSOLARADO

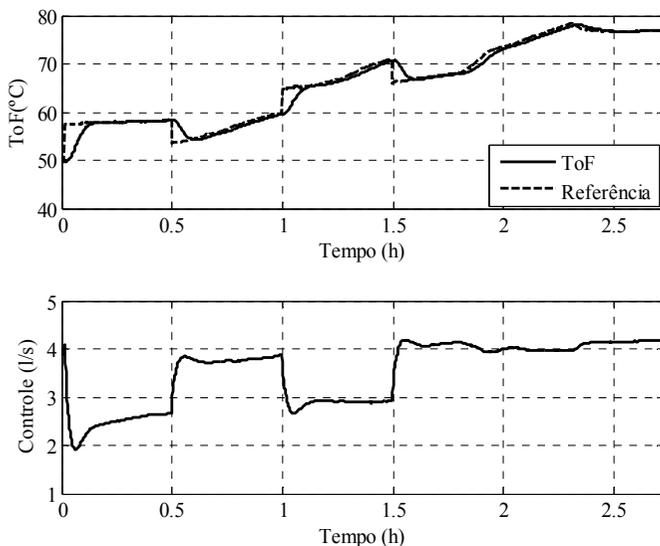
A Figura 5.7 mostra as entradas reais na planta num dia ensolarado, em 25 de abril de 2008, começando aproximadamente às 9hs. Observa-se no gráfico que a radiação solar varia lentamente e vai aumentando no período considerado.

A temperatura ambiente varia dentro da faixa de 22°C a 24°C e a temperatura de entrada  $T_{if}$  varia lentamente desde 38°C a 66°C. Considerando 4 (quatro) malhas ativas na operação de campo solar em operação, a máxima e mínima vazão de entrada são limitadas entre 4.5l/s e 1.2l/s. A Figura 5.8 mostra a saída e o controle produto das simulações com o controle proposto.

Inicialmente  $\Delta T$  é estabelecido em 20°C e logo é trocado para 15°C, 20°C e 15°C a  $t=0.5h$ ,  $t=1h$  e  $t=1.5h$  respectivamente. Observa-se que o controlador proposto segue as diferentes mudanças de referência apropriadamente, apesar das perturbações do ciclo solar diário. O tempo para alcançar a referência é bem menor que no caso anterior, pois há mais energia disponível.



**Figura 5.7:** Entradas no processo real, dia ensolarado.



**Figura 5.8:** Saída e controle no processo simulado, dia ensolarado.

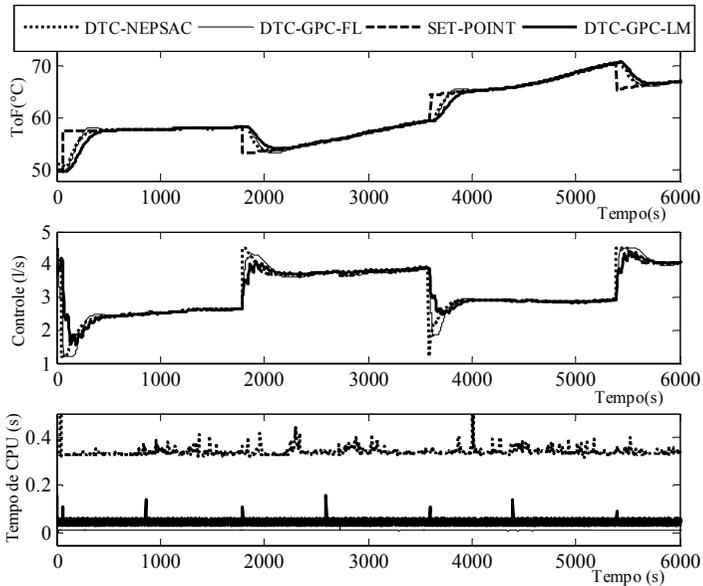
### 5.5.3. COMPARAÇÕES

Como foi comentado no Capítulo 1, diversos algoritmos de controle foram aplicados na planta AQUASOL, e uma análise comparativa é interessante para determinar as vantagens ou desvantagens do algoritmo proposto. Assim, nas simulações, comparou-se o algoritmo proposto, DTC-GPC-LM (DTC-GPC *Local Models*), com outros algoritmos para o controle de processos não lineares: DTC-GPC-FL (DTC-GPC *Feedback Linearization*) e DTC-NEPSAC (DTC *Nonlinear Extended Prediction Self-Adaptive Control*), nas mesmas condições, com base em dados utilizados na seção 5.5.2, dia ensolarado. O algoritmo DTC-GPC-FL utiliza uma estratégia que combina linearização por realimentação e MPC (Roca *et al.*, 2008) e o algoritmo DTC-NEPSAC combina a idéia do NEPSAC para computar a lei de controle e o compensador de tempo morto (DTC) para melhorar a robustez ante as incertezas no tempo morto (Torrico *et al.*, 2009).

O estudo comparativo considera o comportamento dinâmico e a carga de cálculo de cada controlador, assim, a Figura 5.9 mostra a temperatura de saída, o sinal de controle e o tempo relativo da CPU. Os parâmetros de sintonia estão registrados na Tabela 5.6.

**Tabela 5.6:** Parâmetros dos controladores.

| Controlador             | $T_s(s)$ | Filtro DTC     | Preditivo                        |
|-------------------------|----------|----------------|----------------------------------|
| DTC-GPC Modelos Locales | 5        | $\alpha=0.8$   | $N=40, N_u=5,$<br>$\lambda_n=12$ |
| DTC-NEPSAC              | 5        | $\alpha=0.92$  | $N=50, N_u=1,$<br>$\lambda=0$    |
| DTC-GPC-FL              | 5        | $\alpha=0.925$ | $N=50, N_u=8,$<br>$\lambda=10^5$ |

**Figura 5.9:** Comparação do algoritmo proposto com outros algoritmos de controle.

Na análise realizada durante as simulações, usando uma referência computada como  $T_{ref}=T_{iF}+\Delta T$  ( $\Delta T$  é o incremento de temperatura desejado), os controladores DTC-GPC-FL e o DTC-NEPSAC mostram alta sensibilidade ao ruído em  $T_{ref}$  causado por  $T_{iF}$ . Assim,  $\lambda$  no DTC-GPC-FL e  $N$  no DTC-NEPSAC foram ajustados para atenuar estas oscilações, obtendo  $\lambda=10^5$  e  $N=50$ .

Para o caso sob estudo, o controlador proposto apresenta duas principais vantagens: não mostra um comportamento agressivo ante as mudanças de referências, como ocorre ao utilizar linearização por

realimentação no DTC-GPC-FL (Roca *et al.*, 2009), e seu custo computacional<sup>1</sup> é inferior a metade do DTC-NEPSAC apesar de ser um pouco maior que o do DTC-GPC-FL (gráfico inferior na Figura 5.9). A uniformidade no comportamento dinâmico é outra vantagem da proposta, não apresentando, em nenhum caso, ultrapassagens na saída, nem saturações no controle. Esta característica pode ser vista também como uma vantagem operacional, pois se evita submeter os equipamentos a exigências mecânicas ou elétricas. Observa-se também que a proposta apresenta, em alguns casos, um tempo de acomodação maior que o das outras técnicas, para o parâmetro de ajuste escolhido ( $\lambda_n$ ). Esta diferença ocorre porque as outras técnicas operam no limite das restrições ou em saturação. Variando o  $\lambda_n$  a proposta permitiria acelerar as respostas mantendo seu comportamento uniforme.

Em termos gerais, o custo computacional do DTC-GPC-FL deve ser sempre o menor na comparação das três técnicas (não somente para esta aplicação), mas esta última técnica nem sempre pode ser aplicada num sistema não linear, dependendo da sua característica.

## 5.6. EXPERIMENTOS

Nesta seção, aplica-se o algoritmo proposto à planta AQUASOL em duas experiências com mudanças de referências, perturbações e restrições na vazão de entrada.

Os parâmetros do controlador e condições de operação são:

- $T_s = 5s$ ,
- $N = 50$ ,
- $N_u = 30$ ,
- $\alpha = 0.9$ ,
- $\lambda_n = 50$ ,
- $n_l = 4$ .

### 5.6.1. PRIMEIRA EXPERIÊNCIA

Restrições:

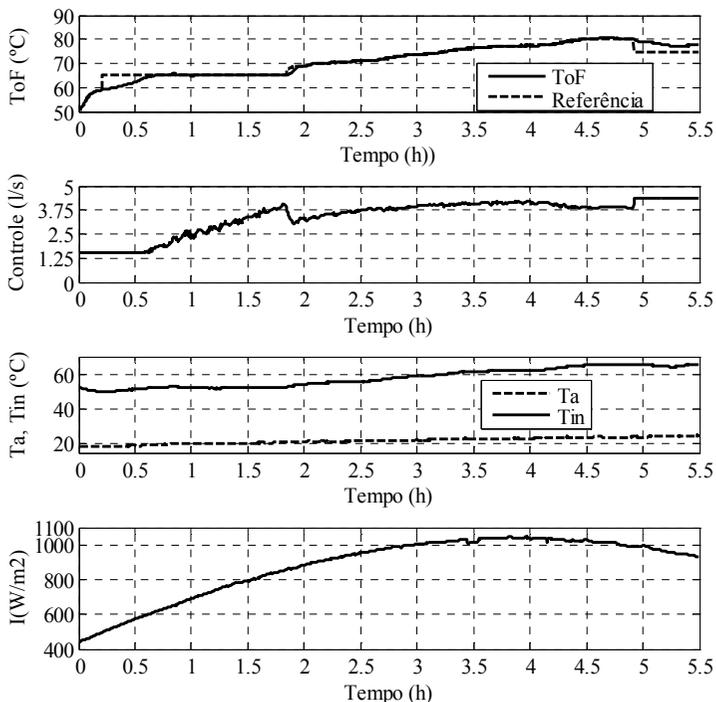
- Mínima vazão de entrada = 1.50l/s,

---

<sup>1</sup> Usando um Intel(R) Core (TM)2 com 2.00 GHz CPU, 2048 MB RAM e *Microsoft Windows XP Professional*.

- Máxima vazão de entrada = 4.40l/s.

A Figura 5.10 mostra a saída, o controle e as perturbações durante uma experiência real na planta AQUASOL, utilizando o controlador proposto. O controle começa aproximadamente às 10 h:12min (0h no gráfico) com uma mudança de referência na temperatura de saída,  $T_{oF}$ , para 65°C. Às 10h:48min muda-se a referência para uma diferença de 15°C entre  $T_{oF}$  e  $T_{in}$ . Às 14h:50min muda-se novamente a referência de  $T_{oF}$  para 75°C.



**Figura 5.10:** Saída, controle e perturbações do processo real da primeira experiência.

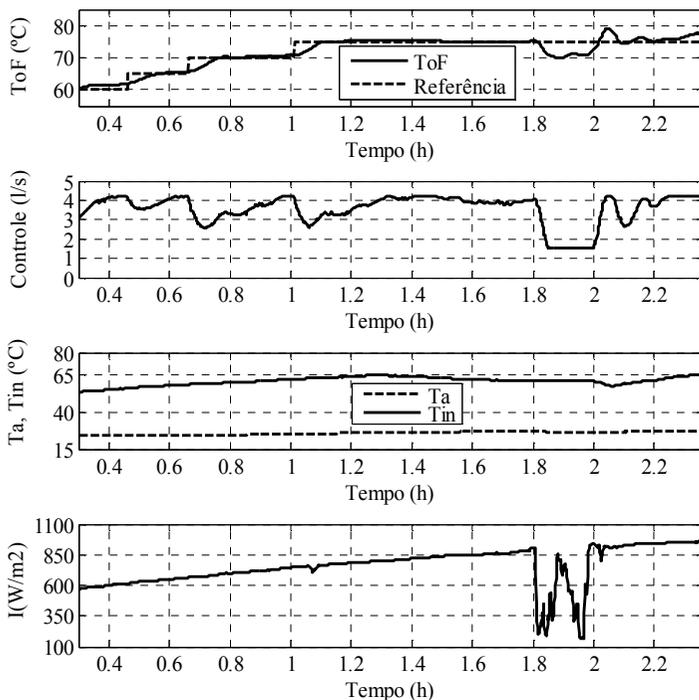
Inicialmente, pela saturação do controle, a saída demora para alcançar o PO solicitado. Depois deste transitório, o sistema de controle proposto mantém a saída na referência, apresentando bom desempenho diante das variações importantes na radiação e também, para o

seguimento de referência (a referência se escolhe para manter  $15^{\circ}\text{C}$  de diferença entre a temperatura de saída e a temperatura de entrada).

Ao final do teste, a referência é fixada em  $75^{\circ}\text{C}$ , mas, devido à saturação do controle, o sistema não é capaz de levar a saída da planta ao novo PO solicitado.

### 5.6.2. SEGUNDA EXPERIÊNCIA

Utilizando os mesmos parâmetros do caso anterior, mas com uma vazão máxima de entrada de  $4.2\text{l/s}$ , obtêm-se os resultados registrados na Figura 5.11.



**Figura 5.11:** Saída, controle e perturbações do processo real da segunda experiência.

Observa-se que, nos primeiros momentos, a saída está acima da referência por causa da saturação do controle. Nas seguintes mudanças

de referências, observa-se um comportamento uniforme com tempo de acomodação praticamente constante, quase sem ultrapassagem. Este comportamento está em concordância com a sintonia projetada. Quase ao final da experiência real o sistema é submetido a fortes perturbações na radiação. O controle tenta regular a temperatura de saída, mas, devido à saturação da vazão, o sistema demora em recuperar-se.

## 5.7. CONCLUSÕES E COMENTÁRIOS

Neste capítulo foram apresentados o projeto e aplicação do controlador proposto, no controle de temperatura dos coletores solares da planta AQUASOL. Os resultados das simulações e experiências reais mostraram que o controlador é capaz de controlar o sistema com o desempenho esperado em toda a faixa de operação da planta. O controlador proposto foi comparado com outros algoritmos, recentemente usados na mesma planta, mostrando um melhor compromisso desempenho-esforço de controle-custo computacional.



## CAPÍTULO 6

### CONCLUSÕES FINAIS

Esta tese centrou-se no desenvolvimento de um controlador preditivo baseado em modelos locais para o controle de plantas não lineares com atrasos, em toda a sua faixa de operação, considerando sua operação com restrições e submetidas a mudanças de referências, mas que operam em zonas de equilíbrio estáveis.

O objetivo desta tese é contribuir para a melhoria da solução do controle de processos não lineares, propondo um novo algoritmo que considera, fundamentalmente, questões como simplicidade no desenvolvimento e no ajuste de parâmetros, baixo custo computacional, robustez ante as incertezas no tempo morto, e uniformidade no desempenho de suas variáveis em toda a faixa de operação do processo.

O algoritmo proposto é do tipo adaptativo e utiliza um único modelo linear para as previsões. O modelo e a penalização de controle são calculados *on-line*, utilizando para isto o modelo não linear do processo.

O procedimento de projeto proposto é sistemático e simples, o que é uma vantagem para sua aplicação no meio industrial. Este procedimento e o algoritmo de controle foram aplicados a dois sistemas simulados (um sistema dinâmico teórico e um modelo de um reator CSTR) e numa planta real (um processo de destilação que usa energia solar).

O algoritmo demonstrou ter as potencialidades esperadas, com resultados superiores a outras técnicas de modelos locais no que diz respeito à captura do comportamento dinâmico do processo não linear, e com uma relação desempenho-custo-simplicidade superior a técnicas de controle de processos não lineares mais complexas.

Na continuação, apresentam-se as principais contribuições deste trabalho, campos de aplicação, as publicações realizadas e pesquisas futuras.

## 6.1. PRINCIPAIS CONTRIBUÇÕES DESTE TRABALHO

1. Formulou-se uma nova técnica para a obtenção de modelos locais para usar num controlador preditivo linear que permite capturar fielmente a dinâmica não linear da planta, principalmente nas mudanças de referências. A idéia inovadora da proposta estabelece que um modelo linear de baixa ordem, determinado na direção do movimento do controle, é capaz de capturar a dinâmica de um processo não linear de forma simples e efetiva. Esta solução evita trabalhar com modelos de baixa precisão ou com múltiplos modelos ou múltiplos controladores.

2. Um procedimento de ajuste *on-line* da penalização do controle. Este resultado é útil pela grande incidência que tem este parâmetro no desempenho do controlador preditivo. A técnica proposta permite que o controlador seja menos conservador na sua sintonia outorgando também maior uniformidade no controle e na variável controlada em toda a faixa de operação do processo.

3. A combinação da técnica de modelagem e ajuste adaptativa do controle com o DTC-GPC, um algoritmo de controle preditivo especialmente proposto para controlar processos com atraso.

Estas contribuições permitem obter os resultados já mostrados nas aplicações que outorgam ao sistema de controle características específicas importantes para sua aplicação industrial:

- Simplicidade na sua conceituação e aplicação;
- Baixo tempo computacional em sua execução;
- Robustez ante a incerteza nos atrasos;
- Uniformidade no comportamento das variáveis;
- Procedimento sistemático de projeto e sintonia de parâmetros.

## 6.2. PUBLICAÇÕES

Ayala, C., Normey-Rico, J.E., Torrico, B.C. (2008). Nova técnica para controle de plantas não lineares utilizando controle preditivo baseado em modelo. *XVII Congresso Brasileiro de Automática*, Juiz de Fora, MG.

Este artigo apresenta os fundamentos preliminares do algoritmo proposto na tese para o controle de plantas não-lineares, descrevendo a metodologia de desenvolvimento do controlador e apresentando uma aplicação numa planta de pH.

Ayala, C. & Normey-Rico, J. E. (2009). Controle de plantas não lineares utilizando controle preditivo linear baseado em modelos locais. *SBA Controle & Automação* **20**(4): 465–481.

Este artigo é uma versão mais completa do trabalho anterior, que contempla alguns aspectos adicionais, como o tratamento das restrições. Além disso, apresentam-se comparações com outras técnicas de controle preditivo aplicadas a plantas não-lineares disponíveis na literatura.

Tito, L., Ayala, C. & Normey-Rico, J.E. (2010). Controle preditivo robusto para aplicações não-lineares baseado em modelos locais. *XVIII Congresso Brasileiro de Automática*, Bonito, MS.

Neste artigo apresenta-se uma extensão do algoritmo proposto na tese para conseguir garantia de estabilidade robusta, utilizando o conceito de robustez baseada em tubos. Um exemplo de simulação com o modelo de uma planta de neutralização de pH é utilizado para aprofundar as discussões.

Trabalho enviado para publicação na revista *Renewable Energy*.

Ayala, C., Roca, L., Guzman, J.L., Normey-Rico, J. & Berenguel, M. (2010). Local model predictive controller in a solar desalination plant collector field.

Este artigo apresenta basicamente os resultados do capítulo 6 desta tese.

### 6.3. PESQUISAS FUTURAS

Tomando como base os resultados obtidos, propõe-se como linha futura de pesquisa continuar o estudo voltado à aplicação prática dos controladores preditivos. Os possíveis temas a serem tratados são:

- Estender o algoritmo para o caso de sistemas MIMO,
- Investigar questões de estabilidade e robustez de forma teórica para algum conjunto de processos não lineares.



## REFERÊNCIAS BIBLIOGRÁFICAS

- Alarcon-Padilla, D., Blanco, J., Malato, S., Maldonado, I., & Fernández, P. (2005). Design and setup of a hybrid solar seawater desalination system: the AQUASOL project. *In Proceedings of the ISES Solar World Congress*, Orlando, Florida, USA.
- Al-Duwaish, H. & Naeem, W. (2000). Nonlinear Model Predictive Control of Hammerstein and Wiener Models Using Generic Algorithm. *IEEE Conference on Control Applications*, México.
- Altinten, A. (2007). Generalized predictive control applied to a pH neutralization process. *Computers and Chemical Engineering* **31**(10): 1199-1204.
- Arahal, M. R., Berenguel, M. & Camacho, E. F. (1998). Neural Identification Applied to Predictive Control of a Solar Plant, *Control Engineering Practice* **6**(3): 333-344.
- Ayala, C. & Normey-Rico, J. E. (2009). Controle de plantas não lineares utilizando controle preditivo linear baseado em modelos locais, *SBA Controle & Automação* **20**(4): 465-481.
- Ayala, C., Normey-Rico, J.E. & Torrico, B.C. (2008). Nova técnica para controle de plantas não lineares utilizando controle preditivo baseado em modelo, *XVII Congresso Brasileiro de Automática*, Juiz de Fora, MG.
- Bequette, B. W. (1991). Nonlinear control of chemical processes: a review, *Industrial & Engineering Chemistry Research* **30**: 1391-1413.
- Bordons, C. & Camacho, E.F. (1998). A Generalized Predictive Controller for a Wide Class of Industrial Processes. *IEEE Transactions on Control Systemes Technology* **6**(3): 372-387
- Camacho, E.F. & Bordons, C. (2004). *Model Predictive Control*, Springer-Verlag, London, United Kingdom.
- Camacho, E.F., Rubio, F.R., Berenguel, M., & Valenzuela, L. (2007). A survey on control schemes for distributed solar collector fields Part II: Advanced control approaches, *Solar Energy* **81**(10): 1252-1272.
- Clarke, D. W., Mohtadi, C. & Tuffs, P. S. (1987). Generalized predictive control: Part I: The Basic Algorithm and Part II: Extensions and Interpretations. *Automatica* **23**(2): 137-160.
- Clarke, D. W., & Mohtadi, C. (1989). Properties of generalized predictive control. *Automatica* **25**(6): 859-875.

- Clarke, D.W. & Scattolini, R. (1991). Constrained receding-horizon predictive control. *IEE Proceedings Part D* **138**(4): 347-354.
- Cutler, C. R., & Ramaker, B. C. (1980). Dynamic matrix control: A computer control algorithm, *Proceedings of American Control Conference*, San Francisco.
- De Keyser, R. M. C. & Van Cuawenberghe, A. R. (1985). Extended prediction self-adaptive control, *Proceedings of IFAC Symposium on Identification and System Parameter Estimation*, York, UK, p. 1317-1322.
- De Keyser, R. & Lazar, M. (2003). A 'Gent'-le Approach to Nonlinear Predictive Control, the NEPSAC Strategy, Plenary Paper in the *ACA-Congress of the Automatic Control Association*, Medellin, Colombia.
- De Prada, C. (2004). El Futuro del Control de Procesos, *Revista Iberoamericana de Automática e Informática Industrial* **4**(1): 5-20.
- Doyle, F. J., Pearson, R. K. & Ogunnaike, B. A. (2001). *Identification and Control of process Using Volterra Models*, Springer-Verlag, New York.
- Drogies, S. (1999). Predictive Control: Propositions for the design methodology. *Proceedings of the 1999 American Control Conference*, San Diego, California, USA.
- Froisy, J. B. (2006). Model predictive control-Building a bridge between theory and practice, *Computers and Chemical Engineering* **30**(10-12): 1246-1435.
- Gao, R., O'Dwyer, A. & Coyle, E. (2002). Model Predictive Control of CSTR Based on Local Model Networks, *Proceedings of the Irish Signals and Systems Conference*, University College p. 397-402.
- Han, K., Zhao, J. & Qian J. (2006). A Novel Robust Tuning Strategy for Model Predictive Control, *Proceedings of the 6th World Congress on Intelligent Control and Automation*, Dalian, China.
- Jalili-Kharaajoo, M. & Araabi, B. N. (2004). Neural network based predictive control of a heat exchanger nonlinear process, *Journal of Electrical & Electronics Engineering* **4**(2): 1219-1226.
- Henson, M.A. & Seborg, D.E. (1994). Adaptive Non-linear Control of a pH Neutralization Process, *IEEE Transactions on control systems technology* **2**(3): 169-182.
- Henson, M. A. (1998). Nonlinear Model Predictive Control: Current Status and Future Directions. *Computers and Chemical Engineering* **23**(2): 187-202.

- Hernandez, E. & Arkun, Y. (1991). A Nonlinear DMC Controller: Some Modeling and Robustness Considerations. *Proceedings of the American Control Conference*, Boston, MA., USA.
- Iino, Y., Tomida, K., Fujiwara, H., Takagi, Y., Shigemasa, T. & Yamamoto, A. (1993). A New Input/output Constrained Model Predictive Control with Frequency Domain Tuning Technique and Its Application to an Ethylene Plant, *Proceedings of the IECON 93*, Maui, Hi 1: 457-462.
- Irwin, G. W. & Townsend, S. (1999). Predictive control using multiple model networks, *IEE Colloquium on Model Predictive Control: Techniques and Applications Day 1*, London, UK.
- Khalil, H.K. (1996). *Nonlinear Systems*, Prentice Hall, second edition, Michigan State University, USA.
- Kawai, F., Ito, H., Nakazawa, Ch., Matsui, M., Fukuyama, Y., Suzuki, R. & Aiyoshi, E. (2007). Automatic Tuning for Model Predictive Control: Can Particle Swarm Optimization find a better parameter?, 22nd IEEE International Symposium on Intelligent Control, *Proceedings IEEE Multi-conference on Systems and Control*, Singapore.
- Kouvaritakis, B., Rossiter, J.A. & Chang, A.O.T. (1992). Stable Generalized Predictive Control: An algorithm with Guaranteed Stability, *Proceedings IEE*, Part D **139**(4): 349-362.
- Kouvaritakis, B. & Cannon, M. (2001). *Nonlinear predictive control*, chapter: *Nonlinear Model Based Predictive Control Using Multiple Local Models*, The Institute of Electrical Engineers: London, United Kingdom.
- Lazar, M. (2001). *Non-linear Controller Based on the Epsac Approach*, Master's thesis, University of Ghent, Departament of Control Engineering and Automation, Flanders, Belgium.
- Limon, D. M. (2002). *Control predictivo de sistemas no lineales con restricciones: estabilidad y robustez*, Tese Doctoral, Escuela superior de Ingenieros de la Universidad de Sevilla, Sevilla.
- Liu, X.J., Guan, P. & Liu, J.Z. (2006). Power Plant Coordinated Predictive Control using Neurofuzzy Model, *Proceedings of American Control Conference*, Minneapolis, Minnesota, USA.
- Ljung, L., (1987). *System Identification. Theory for the User*. Prentice Hall, Englewood Cliffs, NJ, USA.
- Mahfouf, M., Kandiah, S. & Linkens, D.A. (2002). Fuzzy model-based predictive control using an ARX structure with feedforward, *Journal Fuzzy Sets and Systems* **125**(1): 39-59.

- Mayne, D.Q., Rawlings, J.B. Rao, C.V. & Sokaert, P.O.M. (2000). Constrained Model Predictive Control: Stability and Optimality, *Automatica* **36**(6): 789-814.
- Mayne, D. Q. (2001). Control of constrained dynamic systems, *European Journal of Control* **7**(2-3): 87–99.
- Mosca, E., Lemos, J.M. & Zhang, J. (1990). Stabilizing I/O receding horizon Control, *Proceedings of the 29th IEEE Conference on Decision and Control* **4**: 2518-2523
- Nahas, E.P., Henson, M.A. & Seborg, D.E. (1992). Non-linear internal model control strategy for neural network models, *Computers & Chemical Engineering* **16**(12): 1039-1057.
- Normey-Rico, J.E. & Camacho, E.F. (2000). Multivariable Generalized Predictive Controller Based on the Smith Predictor, IEE Proceedings, *Control Theory and Applications* **147**(5): 538-546.
- Normey-Rico, J.E. & Camacho, E.F. (2007). *Control of Dead-Time Processes*, Springer-Verlag, London.
- Normey-Rico, J. E., & Camacho, E. F. (2008b). Unified approach for robust dead-time compensator design, *Journal of Process Control* **19**(1): 38-47.
- Peng, H., Nakano, K., & Shioya, H. (2007). Nonlinear Predictive Control Using Neural Nets-Based Local Linearization ARX Model—Stability and Industrial Application, *IEEE transactions on Control Systems Technology* **15**(1): 130-143.
- Plucenio, A., Normey, J., Pagano, D. & Bruciapaglia, A. (2007). Controle Preditivo não Linear na indústria de petróleo e gás, 4<sup>o</sup> Congresso de Pesquisa e Desenvolvimento em Petróleo e Gás, Campinas, SP.
- Qin, S. J., & Badgwell, T. A. (1997). An overview of industrial model predictive control technology, *Fifth International Conference on Chemical Process Control CACHE and AIChE*, New York, p. 232-256.
- Qin, S. J. & Badgwell, T. A. (2002). A survey of industrial model predictive control technology, *Control Engineering Practice* **11**(7): 733-764.
- Richalet, J., Rault, A., Testud, J. L. & Papon, J. (1978). Model Predictive Heuristic Control: Applications to Industrial Process. *Automatica* **14**(2): 413-428.
- Robinson, B.D. & Clarke, D.W. (1991). Robustness effects of a prefilter in generalized predictive control, *Proceedings of IEE, Part D* **138**(1): 2-8.

- Roca, L., Berenguel, M., Yebra, L., & Alarcón-Padilla, D. (2008). Solar field control for desalination plants, *Solar Energy* **82**: 772-786.
- Roca, L., Guzman, J.L., Normey-Rico, J.E., Berenguel, M. & Yebra, L. (2009). Robust constrained predictive feedback linearization controller in a solar desalination plant collector field, *Control Engineering Practice* **17**(9): 1076-1088.
- Rossiter, J.A. & Kouvaritakis (1993). Constrained stable generalized predictive control, *IEE Proceedings D*, **140**(4): 243-254.
- Rowe, C. & Maciejowski, J. (2000). Tuning MPC using H-infinity Loop Shaping. *Proceedings of the American Control Conference*, Chicago, Illinois, USA, **2**: 1332-1336.
- Scokaert, P. O. M., Mayne, D. Q. & Rawlings, J. B. (1999). Suboptimal model predictive control (feasibility implies stability), *IEEE Transactions on Automatic Control* **44**(3): 648-654.
- Shorten, R. & Murray-Smith, R. (1997). *Side-effects of normalising basis functions in local model networks*. In: Murray-Smith, R. & Johansen, T.A. (eds.) *Multiple Model Approaches to Modelling and Control*, Taylor and Francis systems and control book series, Taylor and Francis, London, UK, pp. 211-229.
- Takatsu, H, Itoh, T. & Araki, M. (1998). Future needs for the control theory in industries-report and topics of the control technology survey in the japanese industry. *Journal of Process Control*, **8**(5-6): 369-374.
- Tamas, L., Nascu, I. & De Keyser, R. (2007). The NEPSAC Nonlinear Predictive Controller in a Real Life Experiment, *Proceedings of 11<sup>th</sup> International Conference on Intelligent Engineering Systems*, Budapest, Hungary.
- Torrico, B. C., Roca, L., Normey-Rico, J. E., Guzman, J. L. & Yebra, L. (2009). Predictive temperature control of solar collectors in a desalination plant, In: *European Control Conference*, Budapest.
- Townsend, S. & Irwin, G.W. (2001). *Nonlinear model based predictive control using multiple local models*, *IEE, Control Engineering Book Series 61, Nonlinear predictive control; theory and practice*, (eds. Kouvaritakis, B. & Cannon, M.), Chapter 11, p. 223-243.
- Trierweiler, J. O. & Secchi, A. R. (2000). *Nonlinear Model Predictive Control: Assessment and Future Directions for Research* (eds. Allgower & Zhen), chapter: Exploring the Potentiality of Using Multiple Model Approach, ed. :Birkhaus, p. 191.
- Van der Lee, J.H., Svrcek, W.Y. & Young B.R. (2008). A tuning algorithm for model predictive controllers based on genetic

algorithms and fuzzy decision making, *ISA Transactions* **47**(1): 53-59.

Yoon, T. & Clarke, D. (1995). Observer design in receding-horizon control, *International Journal of Control* **61**(1): 171-191.