

UNIVERSIDADE FEDERAL DE SANTA CATARINA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

**CONTROLE PREDITIVO NÃO-LINEAR PARA
SISTEMAS DE HAMMERSTEIN**

Tese de Doutorado submetida à Universidade Federal de Santa Catarina como
parte dos requisitos para a obtenção do grau de
Doutor em Engenharia Elétrica

José Eli Santos dos Santos

Orientador: Antonio Augusto Rodrigues Coelho

Florianópolis, Abril de 2007.

Livros Grátis

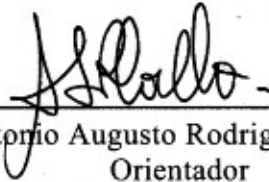
<http://www.livrosgratis.com.br>

Milhares de livros grátis para download.

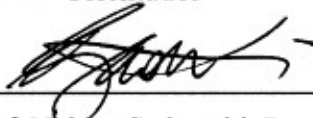
CONTROLE PREDITIVO NÃO-LINEAR PARA SISTEMAS DE HAMMERSTEIN

José Eli Santos dos Santos

“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.”

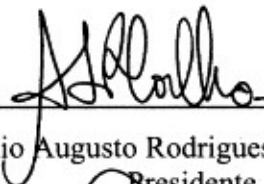


Prof. Antonio Augusto Rodrigues Coelho, Dr.
Orientador

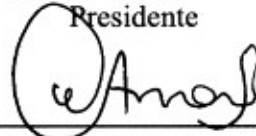


Prof. Nelson Sadowski, Dr.
Coordenador da Pós-Graduação em Engenharia Elétrica

Banca Examinadora:



Prof. Antonio Augusto Rodrigues Coelho, Dr. - UFSC
Presidente



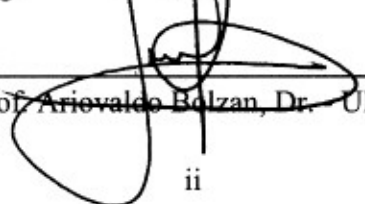
Prof. Wagner Caradori do Amaral, Dr. - UNICAMP



Prof. Francisco José Gomes, Dr. - UFJF



Prof. Nestor Roqueiro, Dr. - UFSC



Prof. Ariovaldo Balzan, Dr. - UFSC

"The best material model of a cat is another, or preferably the same, cat."

Norbert Wiener (1894 - 1964)

*À Fabiane, Alana, Esther e Lúcia,
mulheres de minha vida.*

AGRADECIMENTOS

Ao professor Antonio Augusto Rodrigues Coelho, pela orientação e dedicação demonstrada em todas as etapas deste trabalho. Sua atitude séria e profissional é um exemplo.

A minha esposa Fabiane e minhas filhas: Alana, Esther e Lúcia que sempre ajudaram nos momentos difíceis com suas palavras de carinho e incentivo.

Aos integrantes da banca examinadora pelas valiosas contribuições apresentadas.

Aos colegas e amigos do Colégio Técnico Industrial - Prof. Mário Alquati, da Fundação Universidade Federal do Rio Grande (FURG), que possibilitaram o meu afastamento e muito incentivaram para a realização deste trabalho.

Aos amigos e integrantes do Grupo de Pesquisa em Tecnologias de Controle Aplicado (GPqTCA): Jaime, Laurinda, Rodrigo Goytia e Rodrigo Sumar que muito contribuíram para o andamento deste trabalho com preciosas contribuições, brilhantes observações, maciça ingestão de cafeína e grandes doses de bom humor.

A todos os professores e colegas do Departamento de Automação e Sistemas que de diversas formas contribuíram neste período de aprendizado.

Ao professor Eduardo Fernández Camacho pela supervisão do estágio em Sevilla. Seu brilhantismo só é superado por sua simpatia e simplicidade.

Aos demais componentes do Grupo de Control Predictivo da Escuela de Ingenieros da Universidad de Sevilla pela acolhida: Alfonso, Amparo, Asun, Carlos Bordons, Dani Limón, Dani Rodríguez, Fernando Dorado, Ignacio, José Cueli, José Gamboa, Manolo Ruiz, Miguel Angel, Mercedes, Teodoro.

A CAPES, Fundação Universidade Federal do Rio Grande e Universidade Federal de Santa Catarina e Universidad de Sevilla pelo apoio financeiro e logístico.

Resumo de Tese de Doutorado submetida à UFSC como parte dos requisitos para a obtenção do grau de Doutor em Engenharia Elétrica

CONTROLE PREDITIVO NÃO-LINEAR PARA SISTEMAS DE HAMMERSTEIN

José Eli Santos dos Santos

Abril/2007.

Orientador: Antonio Augusto Rodrigues Coelho, Dr.

Área de Concentração: Automação e Sistemas.

Palavras-chave: identificação, controle de processos, controle preditivo, sistema não-linear, modelo de Hammerstein.

Número de Páginas: 139.

As pesquisas associadas às estratégias de controle preditivo não-linear têm apresentado grande crescimento ultimamente registrando, também, um número considerável de aplicações na indústria. A representação de um processo complexo através de um modelo não-linear, com o objetivo de melhorar seu desempenho dinâmico, tende a sacrificar a simplicidade de projeto do controlador preditivo. Visando aliar a capacidade de representação da não-linearidade de um processo com a simplicidade de projeto, torna-se interessante a utilização de controladores preditivos baseados no modelo de Hammerstein o qual é constituído de um bloco estático, não-linear, seguido de um bloco linear dinâmico. Esta tese apresenta um estudo de modelagem, identificação e controle preditivo não-linear baseado em modelos de Hammerstein. Algumas técnicas de seleção de estrutura e identificação do modelo de Hammerstein são apresentadas e algumas inovações são propostas. Estratégias de controle preditivo baseado no modelo de Hammerstein são discutidas e são propostas modificações num controlador para a inclusão de perturbações mensuráveis e uma técnica analítica para solucionar a multiplicidade do sinal de controle. Para avaliar as técnicas de identificação e controle estudadas, são apresentados resultados de simulação e experimentais em uma planta solar de climatização.

Abstract of Thesis presented to UFSC as a partial fulfillment of the requirements for to
degree of Doctor in Electrical Engineering

NONLINEAR PREDICTIVE CONTROL FOR HAMMERSTEIN SYSTEMS

José Eli Santos dos Santos

April/2007.

Advisor: Antonio Augusto Rodrigues Coelho, Dr.

Area of Concentration: Automation and Systems.

Keywords: identification, control of process, predictive control, nonlinear system, Hammerstein model.

Number of Pages: 139.

The research associated to nonlinear predictive control strategies has increase lately, presenting also a number of industrial applications. The complex process representation by nonlinear model, with aim of improve the dynamical performance, conduces to sacrifice the simplicity of predictive controller design. Aiming ally the representation of process nonlinearity capability with the design simplicity, is interesting the use of Hammerstein model based predictive controllers, model with is formed by a nonlinear static block followed by a linear dynamical block. This work presents an investigation of modeling, identification and Hammerstein model based predictive control. Any techniques of structure selection and identification of the Hammerstein model are showing and innovations are proposed. Hammerstein model based predictive control strategies are discussed and modifications are developed for the inclusion of measurable disturbances, moreover and the analytical strategy for solution of control signal multiplicity is introduced. The identification and control techniques are evaluated by simulation and experimental results on refrigeration solar plant.

SUMÁRIO

1. INTRODUÇÃO.....	01
1.1 OBJETIVOS DO TRABALHO	04
1.2 ESTRUTURA DA DE TESE	04
2. MODELOS DE PROCESSOS LINEARES E NÃO-LINEARES.....	06
2.1 INTRODUÇÃO	06
2.2 MODELOS LINEARES.....	07
2.2.1 Modelos Paramétricos.....	07
2.2.2 Modelos Não-Paramétricos.....	09
2.3 MODELOS NÃO-LINEARES	15
2.3.1 Modelo NCARMA.....	15
2.3.2 Modelo de Volterra.....	16
2.3.3 Modelo Bilinear.....	18
2.3.4 Modelo de Hammerstein.....	19
2.3.5 Modelo de Wiener.....	23
2.4 COMPARAÇÃO ENTRE OS MODELOS	24
2.5 CONCLUSÃO	26
3. IDENTIFICAÇÃO DE SISTEMAS NÃO-LINEARES.....	27
3.1 INTRODUÇÃO	27
3.2 SELEÇÃO DO MODELO	28
3.2.1 Detecção de Não-Linearidade.....	30
3.3 SELEÇÃO DE ESTRUTURA.....	33
3.3.1 Razão entre Determinantes para o Modelo de Hammerstein	34
3.4 ESTIMAÇÃO DE PARÂMETROS	39
3.4.1 Método dos Mínimos Quadrados	39
3.4.2 Método do Erro de Predição.....	43

3.4.3 Método de Narendra – Gallman.....	44
3.4.4 Método de Boutayeb.....	45
3.4.5 Método de Bai.....	48
3.5 VALIDAÇÃO DO MODELO.....	51
3.6 CONCLUSÃO	54
4. CONTROLE PREDITIVO BASEADO NO MODELO DE HAMMERSTEIN	56
4.1 INTRODUÇÃO	56
4.2 CONTROLE PREDITIVO BASEADO EM MODELOS LINEARES	58
4.2.1 Controle por Matriz Dinâmica (DMC)	59
4.2.2 Controle Preditivo Generalizado (GPC).....	61
4.2.3 Abordagem Mean Level Control (MLC)	63
4.2.4 Comparação entre Estratégia MPC.....	66
4.3 CONTROLE PREDITIVO BASEADO EM MODELOS NÃO-LINEARES	67
4.3.1 Controlador Preditivo de Bars e Haber.....	68
4.3.2 Controlador Preditivo Baseado num Modelo Quase-Linear	69
4.3.3 Controlador Preditivo de Katende e Jutan	70
4.3.4 Controlador Preditivo de Fruzzetti	72
4.3.5 GPC com Perturbações Mensuráveis para o Modelo de Hammerstein	73
4.3.6 Multiplicidade de Soluções para a Lei de Controle.....	77
4.4 PREDITORES DE HAMMERSTEIN BASEADO EM MODELOS NÃO-LINEARES	80
4.4.1 Preditor para o Modelo Linear	81
4.4.1 Preditor para o Modelo de Hammerstein	82
4.4.1 Preditor para o Modelo Bilinear.....	83
4.4.1 Preditor para o Modelo de Volterra	84
4.5 CONCLUSÃO	85
5. RESULTADOS DE SIMULAÇÃO	86
5.1 INTRODUÇÃO	86
5.2 APLICATIVO DE IDENTIFICAÇÃO DE UM PROCESSO DE HAMMERSTEIN	86
5.3 AVALIAÇÃO DA MULTIPLICIDADE DE SOLUÇÕES PARA A LEI DE CONTROLE.....	90
5.4 APLICATIVO DE IDENTIFICAÇÃO E CONTROLE DE UM REATOR CSTR	94

5.4.1 Etapa de Identificação.....	97
5.4.2 Etapa do Controle Preditivo Não-Linear.....	99
5.5 PLANTA SOLAR DE CLIMATIZAÇÃO	100
5.5.1 Descrição da Planta	101
5.5.2 Constituição.....	102
5.5.3 Funcionamento	106
5.5.4 Operação	106
5.5.5 Resultados Experimentais	110
5.5 CONCLUSÃO	124
6. CONCLUSÃO.....	125
6.1 CONTRIBUIÇÕES	126
6.1.1 Publicações Geradas.....	126
6.2 PERSPECTIVAS PARA TRABALHOS FUTUROS	129
6.2.1 Identificação de Modelos Não-Lineares.....	129
6.2.1 Controle Preditivo Baseado em Modelos Não-Lineares.....	129
REFERÊNCIAS BIBLIOGRÁFICAS.....	130

LISTA DE TABELAS

Tabela 2.1 – Particularizações do Modelo <i>CARIMA</i>	08
Tabela 2.2 – Particularizações do Modelo Não-Paramétrico.	14
Tabela 2.3 – Seleção do Modelo: Paramétrico X Não-Paramétrico.....	14
Tabela 2.4 – Representação de <i>NL</i> com Estrutura Conhecida.....	21
Tabela 2.5 – Particularizações do Modelo <i>NCARMA</i>	25
Tabela 2.6 – Comparação da Complexidade dos Modelos.	26
Tabela 3.1 – Comportamento Não-Linear.....	30
Tabela 4.1 – Aplicações Comerciais de <i>MPC</i>	59
Tabela 4.2 – Comparação entre Estratégias <i>MPC</i>	66
Tabela 4.3 – Aplicações Comerciais de <i>NMPC</i>	67
Tabela 5.1 – Comparação entre os Resultados de Identificação.	89
Tabela 5.2 – Desempenho das Técnicas de Seleção de Raízes.	94
Tabela 5.3 – Notação para o Reator <i>CSTR</i>	95

LISTA DE FIGURAS

Figura 1.1 – Publicações sobre Controle Preditivo Não-Linear.....	03
Figura 1.2 – Estrutura da Tese.....	05
Figura 2.1 – Coeficientes da Resposta Impulsiva.	09
Figura 2.2 – Coeficientes da Resposta ao Degrau.	12
Figura 2.3 – Modelo de Hammerstein.	19
Figura 2.4 – Tipos Comuns de Não-Linearidades.	21
Figura 2.5 – Estrutura de um modelo Hammerstein Neural.....	22
Figura 2.6 – Estrutura de um modelo Hammerstein Nebuloso.	22
Figura 2.7 – Modelo de Wiener.....	23
Figura 2.8 – Modelo Wiener-Hammerstein.....	24
Figura 2.9 – Relação entre os modelos não-lineares.	25
Figura 3.1 – Diagrama do Protocolo de Identificação.....	27
Figura 3.2 – Diagrama para Seleção de Modelo.	29
Figura 3.3 – Teste de Simetria.....	31
Figura 3.4 – Teste de Dependência de Amplitude da Entrada.	32
Figura 3.5 – Teste de Entradas Periódicas.....	33
Figura 3.6 – Representação da <i>NL</i> do Exemplo 3.4.	36
Figura 3.7 – Teste <i>DR</i> para o Exemplo 3.4.	37
Figura 3.8 – Teste <i>DR</i> para o Exemplo 3.5.	38
Figura 3.9 – Não-Linearidade Tipo Saturação.	49
Figura 3.10 – Função de Autocorrelação de um Resíduo Ruído Branco.	52
Figura 4.1 – Estrutura de um Controlador Preditivo.....	57
Figura 4.2 – Horizontes de Predição.	58

Figura 4.3 – Estrutura do <i>RST</i> Controlador <i>GPC</i>	62
Figura 4.4 – Abordagem <i>Mean Level Control</i>	63
Figura 4.5 – Estrutura do Controlador de Fruzzetti.....	72
Figura 4.6 – Seleção do Sinal de Controle.	80
Figura 5.1 – Processo com Saturação na Entrada.....	87
Figura 5.2 – Ensaio em Malha Aberta para Identificação.	87
Figura 5.3 – Teste <i>DR</i> para um Processo com Saturação na Entrada.....	88
Figura 5.4 – Comparação Saída Real x Estimada.	88
Figura 5.5 – NL estimada e Saturação do Processo.	89
Figura 5.6 – Validação do Modelo Obtido (Boutayeb).....	90
Figura 5.7 – Representação de um Trocador de Calor Casco-Tubo.....	91
Figura 5.8 – Controladores Preditivos com Sintonia: $N_2 = 5$; $N_u = 2$; $\lambda = 200$	92
Figura 5.9 – Controladores Preditivos com Sintonia: $N_2 = 5$; $N_u = 1$; $\lambda = 2000$	93
Figura 5.10 – Representação Esquemática de um reator <i>CSTR</i>	95
Figura 5.11 – Resposta do <i>CSTR</i> a Aplicação de um Degrau.	97
Figura 5.12 – Dados de Entrada-Saída do Processo para Estimação.	97
Figura 5.13 – Comparação Resposta da Planta x Modelo Estimado.....	98
Figura 5.14 – Comparação das Respostas para Validação.	98
Figura 5.15 – Análise de Comportamento Servo para o <i>CSTR</i>	99
Figura 5.16 – Análise de Comportamento Regulatório para o <i>CSTR</i>	100
Figura 5.17 – Esquema da Planta Solar de Refrigeração.	102
Figura 5.18 – Coletores Solares.....	103
Figura 5.19 – Acumuladores de Água.	103
Figura 5.20 – Caldeira de Gás.	104
Figura 5.21 – Torre de Resfriamento.....	104
Figura 5.22 – Bomba de Calor.....	105
Figura 5.23 – Máquina de Absorção.	106
Figura 5.24 – Sistema de Refrigeração por Absorção.....	107
Figura 5.25 – Esquema do Sistema de Controle.....	108
Figura 5.26 – Esquema Simplificado das Malhas de Controle.	109
Figura 5.27 – Tela do Supervisório da Planta Solar.....	109

Figura 5.28 – Sistema de Controle via <i>OPC</i>	110
Figura 5.29 – Temperatura na Saída dos Coletores X Posição de VM1.	112
Figura 5.30 – Temperatura X Radiação num Dia de Céu Limpo.	112
Figura 5.31 – Temperatura X Radiação num Dia de Céu Nebuloso.	113
Figura 5.32 – Dados do Ensaio para Identificação.	114
Figura 5.33 – Teste DR para a Planta Solar.	114
Figura 5.34 – Identificação e Validação do Modelo de Hammerstein.	115
Figura 5.35 – Influência da Radiação Solar na Temperatura.	116
Figura 5.36 – Ensaio com o <i>HGPC</i> (nebulosidade, $N_2 = 20$; $N_u = 3$; $\Lambda = 0.01$).	118
Figura 5.37 – Estimação da Radiação Solar.	119
Figura 5.38 – Predição da Radiação Solar.	120
Figura 5.39 – Ensaio com o <i>HGPC</i> (céu claro, $N_2 = 20$; $N_u = 3$; $\Lambda = 0.02$).	121
Figura 5.40 – Ensaio com o <i>HGPC</i> (céu claro, $N_2 = 25$; $N_u = 2$; $\Lambda = 0.015$).	122
Figura 5.41 – Ensaio com o <i>HGPC</i> (nebulosidade, $N_2 = 25$; $N_u = 2$; $\Lambda = 0.015$).	123

NOTAÇÃO

Símbolos

δ, μ	passo de iteração
$\Delta, \Delta(q^{-1})$	$\Delta u(t) = (1 - q^{-1})u(t) = u(t) - u(t-1)$
$\varepsilon(t), \xi(t)$	incerteza de modelagem, erro de medição, ruído
$\varphi, \varphi(t)$	vetor de medidas
$\phi(t)$	saída generalizada
Φ	matriz de informação
γ_i	elementos do polinômio da não-linearidade
Ψ, Γ, Λ	ponderações da saída, referência e controle, respectivamente
$\Xi(.)$	esperança matemática
$\theta, \theta(t)$	vetor de parâmetros
$\hat{\theta}, \hat{\theta}(t)$	vetor de parâmetros estimados
θ_γ	parâmetros da parcela não-linear
θ_a, θ_b	parâmetros da parcela linear
θ_b^+	pseudo-inversa de θ_b
$A(q^{-1}), B(q^{-1})$	polinômios em q^{-1}
d	atraso de transporte no tempo discreto
$e, e(t)$	erro de predição, erro de estimação
f	fator de filtro
\mathbf{G}	matriz de coeficientes da resposta ao degrau
$G(q^{-1})$	função de transferência discreta
g_i	elementos da resposta ao degrau
$g(\theta_k)$	gradiente
g_s	ganho estático do processo

$H(\theta_k)$	Hessiana
h_i, h_{ij}	elementos da resposta impulsiva, <i>kernels</i> do modelo de Volterra, elementos do modelo <i>NCARMA</i>
\mathbf{I}, \mathbf{I}_n	matriz identidade, matriz identidade $n \times n$
J, V	função custo
k, a	constantes
L	atraso de transporte no tempo contínuo
l, m	grau da não-linearidade, ordem do modelo
N_1, N_2	horizonte de predição da saída, inicial e final, respectivamente
N_u	horizonte de controle
N	número de termos de uma série, número de medidas
$\mathcal{N}(\cdot)$	não-linearidade
na, nb	ordem dos polinômios $A(q^{-1}), B(q^{-1})$, respectivamente
nu, ny	número de termos das parcelas de $u(t)$ e $y(t)$ nos modelos, respectivamente
q^{-1}	operador atraso, $q^{-1}u(t) = u(t-1)$
R, S, T	polinômios de um controlador com dois graus de liberdade, estrutura <i>RST</i>
$r_{ee}(\tau)$	função de autocorrelação do erro de estimação
t	tempo, instante de tempo
T_s	período de amostragem
$u, u(t)$	sinal de entrada, controle
\bar{u}	controle <i>mean level</i>
W	matriz de ponderações
$w, w(t)$	pseudo-entrada do sistema, entrada do bloco linear
$x, x(t), v, v(t)$	pseudo-saída do sistema, saída do bloco linear
Y	vetor de saídas
$y, y(t)$	sinal de saída
\bar{y}	valor médio da saída
\hat{y}	valor estimado para a saída

Abreviaturas

<i>AIC</i>	<i>Akaike's Information Criterion</i>
<i>ANN</i>	<i>Artificial Neural Networks</i>
<i>CARIMA</i>	<i>Controlled Auto-Regressive Integrated Moving Average</i>
<i>CARMA</i>	<i>Controlled Auto-Regressive Moving Average</i>
<i>CSTR</i>	<i>Continuous Stirred Tank Reactor</i>
<i>DC</i>	<i>Direct Current</i>
<i>DMC</i>	<i>Dynamic Matrix Control</i>
<i>DR</i>	<i>Determinant Ratio</i>
<i>ERR</i>	<i>Error Reduction Ratio</i>
<i>FIR</i>	<i>Finite Impulsive Response</i>
<i>FPE</i>	<i>Final Prediction Criterion</i>
<i>FSR</i>	<i>Finite Step Response</i>
<i>GMV</i>	<i>Generalized Minimum Variance</i>
<i>GPC</i>	<i>Generalized Predictive Control</i>
<i>HGPC</i>	<i>Hammerstein Based Generalized Predictive Control</i>
<i>I/O</i>	<i>Input / Output</i>
<i>IIR</i>	<i>Infinite Impulsive Response</i>
<i>ISR</i>	<i>Infinite Step Response</i>
<i>MAC</i>	<i>Model Algorithmic Control</i>
<i>MISO</i>	<i>Multiple Input, Single Output</i>
<i>MLC</i>	<i>Mean Level Control</i>
<i>MPC</i>	<i>Model Predictive Control</i>
<i>MQ</i>	<i>Algoritmo dos mínimos quadrados</i>
<i>NARMAX</i>	<i>Nonlinear Auto-Regressive Moving Average Model with Exogenous Variables</i>
<i>NCARMA</i>	<i>Nonlinear Controlled Auto-Regressive Moving Average</i>
<i>NEOxITE</i>	<i>Next Generation Open Control System Internet Ready</i>
<i>NL</i>	<i>Não-Linearidade</i>
<i>NGPC</i>	<i>Nonlinear Generalized Predictive Control</i>

<i>NMPC</i>	<i>Nonlinear Model Predictive Control</i>
<i>OLE</i>	<i>Object Linking and Embedding</i>
<i>OPC</i>	<i>OLE for Process Control</i>
<i>PMC</i>	<i>Programmable Multi-function Controller</i>
<i>PI</i>	<i>Controlador Proporcional + Integral</i>
<i>PRBS</i>	<i>Pseudo-Random Binary Signal</i>
<i>RMSE</i>	<i>Root Mean Square Error</i>
<i>SCADA</i>	<i>Supervisory Control And Data Acquisition</i>
<i>SISO</i>	<i>Single Input, Single Output</i>
<i>SSE</i>	<i>Sum of Squared Error</i>

1. INTRODUÇÃO

Nos últimos anos o controle de sistemas não-lineares tem recebido considerável atenção tanto no meio acadêmico como no industrial. Este recente interesse na análise e projeto de sistemas de controle não-linear é devido ao desempenho insatisfatório de controladores lineares quando aplicados a plantas com acentuada não-linearidade ou plantas não-lineares atuando sobre uma ampla faixa de operação, além do grande desenvolvimento de estratégias de controle baseado em modelo para sistemas não-lineares (Henson e Seborg, 1997; Hapoglu *et al.*, 2001; Camacho e Bordons, 2004).

Estas estratégias de controle de processos complexos utilizam o modelo não-linear diretamente no projeto do controlador sem a necessidade da aplicação de algum tipo de linearização em torno do ponto de operação (Henson e Seborg, 1997; Hapoglu *et al.*, 2001).

Nas estratégias de controle não-linear convencionais o objetivo é fazer com que o sistema em malha fechada comporte-se linearmente mantendo o ganho constante. A técnica do ganho escalonado foi amplamente aplicada para compensar as características não-lineares dos processos. Nesta abordagem os parâmetros do controlador são ajustados para compensar as não-linearidades conhecidas de maneira que o ganho de malha seja mantido tão constante quanto possível. Generalizando, o controlador deve conter a inversa da não-linearidade estática do processo (Pearson e Ogunaiké, 1997; Rawlings, 2000).

Estratégias de controle baseado em modelo para processos não-lineares são, tradicionalmente, baseadas na aplicação de uma linearização local e num projeto de controlador realizado a partir do modelo linearizado obtido.

Ultimamente, tem ressurgido o interesse no desenvolvimento de novas estratégias de identificação e controle para sistemas não-lineares motivadas pelos avanços na teoria de sistemas não-lineares, pelo desenvolvimento de métodos eficientes de identificação de modelos não-lineares empíricos, pela disponibilidade de pacotes computacionais comerciais

e pela melhoria contínua na capacidade de *hardware* e *software*. Isto torna possível a utilização de modelos não-lineares complexos nos sistemas de controle de processos.

O controle preditivo baseado em modelo tem-se apresentado atualmente como uma das mais populares e eficientes estratégias de controle na indústria de processos. Isto ocorre porque muitos dos aspectos fundamentais num projeto de controle industrial prático podem ser explorados num controle preditivo baseado em modelo, como a trajetória de referência futura, predição de perturbações e inclusão de restrições, verificando assim a flexibilidade de projeto desta técnica de controle (Ogunnaike e Ray, 1994; Scheffer-Dutra *et al.*, 2002).

A utilização de modelos lineares numa aplicação de controle preditivo é bastante comum pois, além da popularidade deste tipo de modelo, muitas vezes, torna-se necessário o emprego de um modelo simplificado para possibilitar que todos os cálculos envolvidos sejam realizados dentro do intervalo correspondente a um período de amostragem viabilizando, assim, o controle em tempo-real. Um modelo linear possibilita, também, solução analítica para o problema de minimização da função custo quando não são consideradas restrições (Zambrano e Camacho, 2002; Núñez-Reyes *et al.*, 2005).

As aplicações bem sucedidas de sistemas de controle preditivo baseados em modelos lineares motivaram a idéia de que estes podem apresentar desempenhos superiores caso o modelo empregado possa representar o processo de forma mais eficiente. Ocorreu, então, nos últimos anos, um grande crescimento nas aplicações industriais de controle preditivo não-linear visto que este se apresenta como uma estratégia de controle promissora para diversas áreas da engenharia (Giannakis e Serpedin, 2001).

Atualmente é grande o interesse de diversos pesquisadores na área de controle preditivo baseado em modelos não-lineares, pois apresentam muitas questões para pesquisa ainda em aberto relacionadas à estimação, adaptação, robustez e, principalmente, ao problema de otimização não-convexa (Mayne, 2000). Uma possível solução está no emprego de modelos não-lineares que aliem simplicidade com uma boa capacidade de representação do processo, além do aprofundamento de estudos relacionados a preditores não-lineares (McCannon, *et al.*, 1982; Favier e Dubois, 1990). A Figura 1.1 apresenta o número de trabalhos publicados anualmente em revistas e eventos associados a *Elsevier Science*, *IEE (The Institution of Electrical Engineers)* e *IEEE (Institute of Electrical and Electronics Engineers)* na área de controle preditivo não-linear nos últimos anos.




Figura 1.1 – Publicações sobre Controle Preditivo Não-Linear.

A modelagem de um processo dinâmico consiste na obtenção de um modelo matemático capaz de representar adequadamente as características de interesse da planta em estudo. A necessidade de representar um sistema da forma eficiente empregando um modelo que não provoque um aumento significativo no esforço computacional estabelece um compromisso entre a qualidade do modelo e a sua simplicidade de representação. Neste aspecto o modelo de Hammerstein apresenta boas características pois alia uma boa capacidade de representação de não-linearidades fracas com uma inerente simplicidade de representação. O modelo de Hammerstein possibilita a representação adequada de vários processos da indústria química como reatores, colunas de destilação, trocadores de calor, dentre outros (Fruzzetti *et al.*, 1997; Menold *et al.*, 1997; Pearson e Pottman, 2000; Fink e Nelles, 2001; Aguirre *et al.*, 2005).

O emprego de controladores preditivos baseados no modelo de Hammerstein tem motivado uma série de aplicações bem sucedidas ao longo dos últimos anos (Bars e Haber, 1991; Katende e Jutan, 1996; Fruzzetti *et al.*, 1997, Zou *et al.*, 2006). Isto se deve ao fato que este modelo apresenta propriedades que simplificam o projeto do controlador preditivo não-linear possibilitando, inclusive, uma solução analítica para o problema de minimização da função custo (caso sem restrições), embora, a maioria dos resultados apresentados restrinja-se ao nível de simulação. Deste modo, estudos de implementação de estratégias de controle preditivo não-linear em processos reais apresentam-se, ainda, como um interessante campo de pesquisa com diversas questões em aberto.

1.1 OBJETIVOS DO TRABALHO

Este trabalho consiste de um estudo das estratégias de modelagem, identificação e controle preditivo não-linear baseados no modelo de Hammerstein onde, os principais objetivos são:

- realização de um estudo comparativo entre diversas técnicas de controle preditivo aplicadas a processos representados pelo modelo de Hammerstein;
- implementação prática das estratégias de identificação e controle em estudo possibilitando a validação dos resultados já obtidos em ambiente de simulação, avaliando seu desempenho na presença de dificuldades encontradas na prática (ruídos, incertezas de modelagem, variações paramétricas);
- estudo de preditores não-lineares com ênfase na estrutura de Hammerstein;
- adequação da estrutura de controle *mean level control* no tratamento de processos não-lineares visando aplicações em controle preditivo;
- obtenção de modelos matemáticos não-lineares e implementação de estratégias de controle preditivo não-linear aplicadas a uma planta solar de climatização;
- proposição de modificações e/ou novas estratégias de controle preditivo não-linear visando superar as dificuldades observadas.

1.2 ESTRUTURA DA TESE

Este trabalho apresenta um estudo em relação às diversas estratégias de modelagem, identificação e controle preditivo com aplicação a processos monovariáveis que possam ser representados pelo modelo de Hammerstein.

A tese está organizada de acordo com a Figura 1.2 apresentando os seguintes capítulos: além desta introdução, os modelos empregados na representação de processos lineares e não-lineares são abordados no capítulo 2. As técnicas de identificação de sistemas não-lineares baseados no modelo de Hammerstein são apresentadas no capítulo 3. Os algoritmos de controle preditivo linear e não-linear são discutidos no capítulo 4. O

capítulo 5 apresenta resultados de simulação e experimentos realizados, finalmente, o capítulo 6 apresenta as conclusões, contribuições e propostas para trabalhos futuros.




Figura 1.2 - Estrutura da Tese.

2. MODELOS DE PROCESSOS LINEARES E NÃO-LINEARES

2.1 INTRODUÇÃO

A modelagem de um processo dinâmico consiste da obtenção de um modelo matemático capaz de representar adequadamente as características de interesse de uma planta em estudo.

Toda vez que a experimentação num processo real apresenta restrições de ordem operacional, econômico-financeira ou de segurança, torna-se fundamental a realização de estudos de simulação a partir de um modelo do processo. Além disso, um modelo pode ser empregado com o objetivo de treinamento de operadores de plantas, projeto de controladores e previsão de fenômenos.

O modelo de um sistema pode ser obtido de duas formas: a partir das equações básicas do sistema – **Modelagem Fenomenológica** ou a partir da medição de dados de entrada e saída do sistema – **Identificação de Sistemas**. A dificuldade na obtenção de um modelo fenomenológico adequado, devida a complexidade dos sistemas reais, aliada a grande evolução dos computadores e o desenvolvimento de estratégias de identificação eficientes, fizeram a Identificação de Sistemas tornar-se o principal procedimento para a obtenção de modelos matemáticos sendo, atualmente, objeto de estudo de inúmeros pesquisadores das mais diversas áreas de atuação (Ljung e Glad, 1994; Coelho e Coelho, 2004).

A necessidade de representar um sistema da forma mais eficiente possível empregando um modelo que não provoque um aumento significativo no esforço computacional estabelece um compromisso entre a qualidade do modelo e a sua simplicidade de representação que pode ser observada nos diversos tipos de modelos existentes.

A representação de um processo pode ser feita através de um **modelo contínuo**, ou seja, com base no tempo contínuo e representado, normalmente, por equações diferenciais,

ou por um **modelo discreto** ou **amostrado**, representado por equações a diferenças. Por ser o caso mais usado em implementações práticas, dada a disponibilidade dos sinais de entrada/saída apenas em instantes discretos de tempo. Neste trabalho destaca-se a representação de sistemas *SISO* (*Single-Input, Single-Output*) pela utilização de modelos discretos (Coelho e Coelho, 2004).

2.2 MODELOS LINEARES

Um modelo linear apresenta-se como a forma mais popular de representar um sistema devido à sua simplicidade restringindo-se, no entanto, a um caso particular dos sistemas reais que, em geral, são não-lineares. A validade deste tipo de modelo depende das especificações de controle e das características da não-linearidade. Algumas classes de não-linearidades, por exemplo, podem não se manifestar quando o sistema trabalha numa faixa de operação limitada.

Considerar um sistema linear significa supor que seu comportamento independe do ponto de operação, ou seja, que satisfaz o **Princípio da Superposição dos Efeitos**.

Princípio da Superposição dos Efeitos		
“A resposta produzida pela aplicação da combinação linear de duas ou mais excitações diferentes é igual à combinação linear das respostas individuais a cada uma das excitações.”		
Entrada		Saída
u_1	→	y_1
u_2	→	y_2
$k_1u_1 + k_2u_2$	→	$k_1y_1 + k_2y_2$

2.2.1 Modelos Paramétricos

Correspondem aos modelos que apresentam parâmetros característicos. Estes parâmetros são os coeficientes de uma equação a diferenças ou função de transferência discreta que representa o sistema.

► **Modelo CARMA** (*Controlled Auto-Regressive Moving Average*) - é representado pela estrutura da equação (2.1), isto é,

$$A(q^{-1})y(t) = q^{-d}B(q^{-1})u(t) + C(q^{-1})\xi(t) \quad (2.1)$$

onde

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

$$B(q^{-1}) = b_0 + b_1 q^{-1} + \dots + b_{nb} q^{-nb}$$

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

$y(t)$ é a saída do sistema, $u(t)$ é o sinal de controle (entrada), $\xi(t)$ é uma seqüência aleatória que pode representar incertezas de modelagem, erros de medição ou ruídos presentes na saída e d é o atraso de transporte discreto onde $dT_s \leq L \leq (d+1)T_s$ e L é o atraso de transporte no tempo contínuo (Ljung e Glad, 1994).

► **Modelo CARIMA** (*Controlled Auto-Regressive Integrated Moving Average*) - é representado pela seguinte equação a diferenças:

$$A(q^{-1})y(t) = q^{-d} B(q^{-1})u(t) + C(q^{-1})\xi(t) / \Delta \tag{2.2}$$

que pode ser reescrita na forma

$$A(q^{-1})\Delta y(t) = q^{-d} B(q^{-1})\Delta u(t) + C(q^{-1})\xi(t) \tag{2.3}$$

onde $\Delta = (1 - q^{-1})$ de maneira que $\Delta y(t) = y(t) - y(t-1)$.

Comumente encontram-se casos particulares do modelo *CARIMA*, como ilustrado na Tabela 2.1 (Coelho e Coelho, 2004).

Tabela 2.1 – Particularizações do Modelo *CARIMA*.

Coefficientes	MA	AR	ARMA	CAR	CARMA	ARIMA	CARIMA
$A(q^{-1})$	1	☑	☑	☑	☑	☑	☑
$B(q^{-1})$	–	–	–	☑	☑	–	☑
$C(q^{-1})$	☑	1	☑	–	☑	☑	☑
Δ	1	1	1	1	1	$(1 - q^{-1})$	$(1 - q^{-1})$

onde ☑ denota um coeficiente presente no modelo
 – denota um coeficiente inexistente

2.2.2 Modelos Não-Paramétricos

Representam a dinâmica do processo através dos coeficientes da resposta impulsiva ou da resposta ao degrau. Estas estruturas apresentam, como característica principal, a capacidade de representar dinâmicas que não podem ser bem representadas por modelos paramétricos de ordem reduzida sem a introdução de incertezas estruturais.

Embora tenham como um inconveniente a necessidade de um número elevado de parâmetros, estes modelos possuem um bom desempenho para representar processos que apresentem dinâmicas rápidas (Ljung e Glad, 1994, Aguirre, 2007).

► **Modelo Matemático Baseado na Resposta ao Impulso** - representa o processo com um número infinito de termos que correspondem aos coeficientes da resposta impulsiva do sistema.

$$y(t) = \sum_{i=1}^{\infty} h_i u(t-i) \quad (2.4)$$

Para sistemas estáveis os coeficientes do modelo *IIR* (*Infinite Impulsive Response*) tendem assintoticamente para zero conforme ilustra a Figura 2.1.




Figura 2.1 – Coeficientes da Resposta Impulsiva.

Como se pode observar na Figura 2.1, depois de um tempo suficientemente grande, os coeficientes h_i tendem a zero, caso o sistema seja estável. Esta constatação possibilita o uso de um número finito de termos permitindo, assim, a implementação do modelo *FIR* (*Finite Impulsive Response*).

■ Modelo *FIR* Convencional

Corresponde ao modelo de resposta ao impulso onde é empregado, no entanto, um número finito de termos N suficientemente grande de maneira que $h_i \cong 0$ para $i > N$.

$$y(t) = \sum_{i=1}^N h_i u(t-i) \quad (2.5)$$

Caracteriza-se pela necessidade de empregar um número de parâmetros (N) elevado para conseguir capturar a dinâmica de processos lentos, além de, em algumas aplicações de controle posicional, não garantir erro em regime permanente (*off set*) nulo.

■ Modelo *FIR* Incremental

Baseia-se, também, na equação (2.5) que pode ser reescrita como

$$y(t-1) = \sum_{i=1}^N h_i u(t-1-i) \quad (2.6)$$

e subtraindo a equação (2.6) da equação (2.5) têm-se que

$$y(t) - y(t-1) = \sum_{i=1}^N h_i u(t-i) - \sum_{i=1}^N h_i u(t-1-i)$$

que pode ser reescrita na forma (Clarke e Zhang, 1987)

$$y(t) = y(t-1) + \sum_{i=1}^N h_i \Delta u(t-i) \quad (2.7)$$

Apresenta-se como uma solução ao problema de *off set* nulo para aplicações em controle posicional mantendo, porém, a necessidade de um N elevado quando o processo possui dinâmica lenta.

■ Modelo *FIR* Dinâmico

Este modelo considera que a dinâmica de baixa frequência da maioria dos processos pode ser aproximada por um modelo de 1^a ordem (Auslander *et al.*, 1978)

$$y(t) = \sum_{i=1}^{N-1} h_i u(t-i) + \frac{h_N}{1-pq^{-1}} u(t-N) \quad (2.8)$$

que pode ser reescrita como a equação

$$G(q^{-1}) = \frac{b_1 q^{-1} + b_2 q^{-2} + \dots + b_N q^{-N}}{1 - p q^{-1}}$$

onde $b_1 = h_1$, $b_i = h_i - p h_{i-1}$ para $i = 2, \dots, N$ e p é determinado de maneira a garantir que o ganho do modelo seja igual ao ganho estático do processo (g_s), isto é,

$$p = 1 - \frac{h_N}{g_s - \sum_{i=1}^{N-1} h_i} \quad (2.9)$$

O modelo é garantido estável e sobre-amortecido desde que

$$g_s < \sum_{i=1}^N h_i \quad (2.10)$$

Embora de aplicação restrita ao caso sobre-amortecido, este modelo apresenta como atrativo a possibilidade da utilização de um número menor de termos (N) em relação aos anteriores devido à parcela de compensação. Esta característica viabiliza sua aplicação também em processos de dinâmica lenta.

► Modelo Matemático Baseado na Resposta ao Degrau

Representa o processo com um número infinito de termos que correspondem aos coeficientes da resposta ao degrau do sistema (*ISR – Infinite Step Response*).

$$y(t) = \sum_{i=1}^{\infty} (g_i - g_{i-1}) u(t-i) \quad (2.11)$$

A equação (2.11) pode ser representada na forma

$$y(t) = \sum_{i=1}^{\infty} g_i \Delta u(t-i) \quad (2.12)$$

Para sistemas estáveis estes coeficientes tendem assintoticamente para um valor constante (g_s) conforme ilustra a Figura 2.2.




Figura 2.2 – Coeficientes da Resposta ao Degrau.

■ Modelo *FSR* (*Finite Step Response*)

Corresponde ao modelo de resposta ao degrau, considerando que o número de coeficientes seja limitado a N .

$$y(t) = G(q^{-1}) \Delta u(t-1) \quad (2.13)$$

onde $G(q^{-1})$ é um polinômio cujos termos são os coeficientes da resposta do sistema a uma entrada do tipo degrau unitário, podendo ser reescrita como

$$y(t) = \sum_{i=1}^N (g_i - g_{i-1}) u(t-i)$$

que através de uma comparação com a equação (2.5) pode-se concluir que $h_i = g_i - g_{i-1}$ ou ainda, de forma recursiva, que $g_i = g_{i-1} + h_i$.

A equação (2.13) pode ser representada na forma

$$y(t) = \sum_{i=1}^N g_i \Delta u(t-i) \quad (2.14)$$

onde a principal diferença em relação ao modelo *FIR* deve-se ao fato de que, enquanto os coeficientes da resposta impulsiva de um sistema estável tendem a zero ($h_i \rightarrow 0$), os coeficientes da resposta ao degrau tendem a um valor constante que para uma entrada degrau unitário corresponde ao ganho estático do processo ($g_i \rightarrow g_s$), como ilustrado na Figura 2.2.

A aplicação do modelo *FSR* é bastante popular em aplicações práticas devido à grande familiaridade dos engenheiros de processos com ensaios de resposta ao degrau (Aguirre, 2007). Uma aplicação popular do modelo *FSR* é no controlador *MAC* (*Model Algorithmic Control*), enquanto modelos do tipo *FIR* têm aplicação no controlador *DMC* (*Dynamic Matrix Control*) (Qin e Badgwell, 2003; Camacho e Bordons, 2004; Zou *et al.*, 2006).

► Comparação entre os Modelos Não-Paramétricos

Os diversos modelos lineares não-paramétricos apresentados podem ser considerados como casos particulares de uma representação mais geral, baseado na representação da equação (2.15). Assim, é possível verificar cada caso através da Tabela 2.2.

$$y(t) = p_1 y(t-1) + \sum_{i=1}^{N-1} h_i \Delta u(t-i) + \frac{h_N}{1-p_2 q^{-1}} \Delta u(t-N) \quad (2.15)$$

Tabela 2.2 – Particularizações do Modelo Não-Paramétrico.

Coefficientes	FIR	FIR Incremental	FIR Dinâmico	FSR
p_1	–	1	–	–
p_2	–	☑	☑	–
Δ	1	$(1 - q^{-1})$	1	$(1 - q^{-1})$
h_i	☑	☑	☑	☑ *

onde ☑ denota um coeficiente presente no modelo
 * neste caso os termos h_i correspondem à resposta ao degrau
 – denota um coeficiente inexistente

A escolha de uma representação paramétrica ou não-paramétrica para a representação de um processo deve levar em conta, além das características da planta, as propriedades de cada modelo que estão apresentadas na Tabela 2.3 (Shook, *et al.*, 1992; Kwok e Shah, 1994; Haber, 1995).

Tabela 2.3 – Seleção do Modelo: Paramétrico X Não-Paramétrico.

Características	Paramétrico	Não-Paramétrico
Representação de dinâmicas complexas	Baixa capacidade para modelos de ordem reduzida	Alta capacidade, função do número de termos (N)
Número de termos	Baixo, função das ordens selecionadas para os polinômios	Elevado, principalmente, para processos que apresentem uma dinâmica lenta
Estrutura do Processo	Requer conhecimento prévio em relação ao atraso de transporte e a ordem da função de transferência	Nenhum conhecimento prévio é necessário bastando selecionar o número de termos empregado
Características do Processo	Capaz de representar tanto processos estáveis quanto instáveis	Restrito à representação de processos estáveis em malha aberta
Forma Preditiva	Necessita transformações de forma analítica ou algorítmica conforme o caso	A característica preditiva é inerente a este tipo de modelo

2.3 MODELOS NÃO-LINEARES

O apelo de técnicas de controle baseadas em modelos lineares é, em parte, devido à simplicidade dos modelos empregados para representar o comportamento do processo, no entanto, isto também constitui uma deficiência potencial porque tais modelos lineares são, muitas vezes, inadequados quando se faz necessária uma aproximação mais realística de um processo complexo. Por outro lado, os esquemas de controle não-linear, os quais empregam modelos mais realistas e, portanto, mais complexos, para a descrição de processos não-lineares, sacrificam a simplicidade associada às técnicas lineares a fim de alcançar um desempenho elevado (Maner *et al.*, 1994; Pearson, 2003).

Modelos não-lineares possibilitam um “retrato” mais fiel do processo quando este se faz necessário. Apesar de apresentar uma complexidade maior, apenas a representação a partir de um modelo não-linear permite a análise de algumas características do sistema como oscilações e bifurcações (Pearson, 2003).

2.3.1 Modelo NCARMA (Nonlinear Controlled Auto-Regressive Moving Average)

Este modelo, que na literatura aparece comumente como NARMAX (Nonlinear Auto-Regressive Moving Average Model with Exogenous Inputs), representa o sistema através de uma função polinomial com grau de não-linearidade ℓ cuja parcela determinística é apresentada como o somatório de termos com graus de não-linearidade m ($1 \leq m \leq \ell$). Cada termo de grau m pode conter um fator de grau p do tipo $y(t-i)$ e um fator de grau $(m-p)$ do tipo $u(t-i)$ multiplicados por um parâmetro $h_{p,m-p}(n_1, \dots, n_m)$, ou seja,

$$y(t) = \sum_{m=0}^{\ell} \sum_{p=0}^m \sum_{n_1, n_m}^{n_y, n_u} h_{p,m-p}(n_1, \dots, n_m) \prod_{i=1}^p y(t-n_i) \prod_{i=p+1}^m u(t-n_i) \quad (2.16)$$

onde $\sum_{n_1, n_m}^{n_y, n_u} \equiv \sum_{n_1=1}^{n_y} \cdots \sum_{n_m=1}^{n_u}$, podendo ainda ser representado na forma

$$\begin{aligned} y(t) = & h_0 + \sum_{n_1=1}^{n_y} h_{1,0}(n_1) y(t-n_1) + \sum_{n_1=1}^{n_u} h_{0,1}(n_1) u(t-n_1) + \sum_{n_1=1}^{n_y} \sum_{n_2=n_1}^{n_y} h_{2,0}(n_1, n_2) y(t-n_1) y(t-n_2) \\ & + \sum_{n_1=1}^{n_y} \sum_{n_2=1}^{n_u} h_{1,1}(n_1, n_2) y(t-n_1) u(t-n_2) + \sum_{n_1=1}^{n_y} \sum_{n_2=n_1}^{n_y} h_{0,2}(n_1, n_2) u(t-n_1) u(t-n_2) + \dots \end{aligned} \quad (2.17)$$

Exemplo 2.1 - A equação (2.18) representa um modelo *NCARMA* com $n_y = 2$, $n_u = 2$, e $m = 3$, usado para descrever um aquecedor elétrico obtido experimentalmente, conforme Aguirre (2007).

$$\begin{aligned}
 y(t) = & 0.4455y(t-1) + 0.5777y(t-2) + 0.4860u(t-1) - 0.6363u(t-2) \\
 & - 1.1458 \cdot 10^{-6} y^2(t-1)u(t-1) - 9.9776 \cdot 10^{-5} u^2(t-1)u(t-3) \\
 & - 2.9271 \cdot 10^{-5} y^3(t-3) + 7.8831 \cdot 10^{-3} y(t-2)u(t-2) \\
 & + 7.4386 \cdot 10^{-8} y^2(t-3)u(t-3)
 \end{aligned} \tag{2.18}$$

O modelo *NCARMA* apresenta-se como o caso mais geral de representação de sistemas não-lineares, cujos casos particulares podem representar os modelos de Volterra e Bilinear, dentre outros (Doyle, 2001).

2.3.2 Modelo de Volterra

A representação de um sistema não-linear através de uma série de Volterra pode ser vista como uma generalização da representação de resposta impulsiva para sistemas lineares, que no seu caso discreto é dada por

$$\begin{aligned}
 y(t) = & h_0 + \sum_{i=1}^{\infty} h_{1i} u(t-d-i) + \sum_{i=1}^{\infty} \sum_{j=i}^{\infty} h_{2ij} u(t-d-i)u(t-d-j) + \\
 & + \dots + \sum_{i=1}^{\infty} \dots \sum_{m_i}^{\infty} h_{m_i \dots} u(t-d-i) \dots u(t-d-\dots) + \varepsilon(t)
 \end{aligned} \tag{2.19}$$

No caso particular de um sistema linear a equação (2.19) fica reduzida ao modelo da resposta impulsiva, equação (2.20). Para viabilizar a aplicação prática deste modelo utiliza-se uma série de Volterra truncada numa ordem desejada e com memória finita (Favier *et al.*, 2004), isto é,

$$\begin{aligned}
 y(t) = & h_0 + \sum_{i=1}^N h_{1i} u(t-d-i) + \sum_{i=1}^N \sum_{j=i}^N h_{2ij} u(t-d-i)u(t-d-j) + \\
 & + \dots + \sum_{i=1}^N \dots \sum_{m_i}^N h_{m_i \dots} u(t-d-i) \dots u(t-d-\dots) + \varepsilon(t)
 \end{aligned} \tag{2.20}$$

onde os parâmetros h_0 , h_{1i} e h_{2ij} são coeficientes do modelo, N representa a memória e o número de parcelas está relacionado, também, à ordem m do modelo. O modelo de Volterra pode ser visto como um caso particular do *NCARMA* onde todas as parcelas h_{ij} associadas à saída são nulas. O número de termos do modelo pode ser representado pela seguinte expressão:

$$N^\circ \text{ termos} = \frac{(N+m)! - N!}{m!} \quad (2.21)$$

A tentativa de explicar a saída do processo utilizando apenas informação da entrada pode causar a necessidade de um grande número de parâmetros para o modelo de Volterra (Haber *et al.*, 2000; Doyle *et al.*, 2001). Uma alternativa a esta representação é utilizar, também, informação das saídas passadas. A representação da equação (2.20) na forma paramétrica ou AR-Volterra (*Auto-Regressive Volterra*) torna-se (Doyle, 2001)

$$A(q^{-1})y(t) = b_0 + B_1(q^{-1})u(t-d) + \sum_{i=1}^{nb} \sum_{j=i}^{nb} b_{2ij}u(t-d-i)u(t-d-j) + \dots + \varepsilon(t) \quad (2.22)$$

onde $B_1(q^{-1}) = b_{10} + b_{11}q^{-1} + \dots + b_{1nb}q^{-nb}$

Exemplo 2.2 - A equação (2.23) representa um modelo de Volterra, com $N = 6$ e $m = 2$, usado para descrever um processo *Fan and Plate* em escala de laboratório obtido experimentalmente por identificação conforme presente em Marchi (1999).

$$y(t) = 0.0700 - 0.1505u(t-1) - 1.2058u(t-2) + 0.1174u(t-3) + 0.1600u(t-4) \\ - 0.1168u(t-5) + 0.0320u(t-6) + \sum_{i=1}^6 \sum_{j=1}^6 h_{2ij}u(t-i)u(t-j) \quad (2.23)$$

onde

$$h_{2ij} = \begin{bmatrix} +0.0714 & +0.2362 & -0.0510 & -0.0904 & -0.0780 & -0.0885 \\ 0 & +0.2701 & -0.0171 & -0.0566 & -0.0442 & -0.0546 \\ 0 & 0 & +0.0723 & +0.0329 & +0.0453 & +0.0348 \\ 0 & 0 & 0 & +0.0437 & +0.0561 & +0.0456 \\ 0 & 0 & 0 & 0 & +0.0420 & +0.0315 \\ 0 & 0 & 0 & 0 & 0 & +0.0281 \end{bmatrix}$$

A representação de processos não-lineares por meio de séries de Volterra possibilita a descrição de dinâmicas assimétricas e variações no sinal do ganho do processo (Maner *et al.*, 1994) possuindo várias aplicações bem sucedidas em controle de processos nas áreas de telecomunicações, processos químicos, sistemas biológicos, eletrônica, forno de gesso, controle de pressão (Haber, 1995; Aguirre, 2007; Giannakis e Serpedin, 2001; Dorado e Bordons, 2003 e Zhang *et al.*, 2005).

2.3.3 Modelo Bilinear

O modelo bilinear é baseado em um modelo linear do tipo *ARMA* mais termos não-lineares constituídos pelos produtos entre entradas e saídas na equação:

$$A(q^{-1})y(t) = b_0 + B_1(q^{-1})u(t-d) + \sum_{i=0}^{ny} \sum_{j=0}^{nu} b_{2ij} y(t-d-i)u(t-d-j) + \dots + \varepsilon(t) \quad (2.24)$$

onde os termos do polinômio b_{2ij} são coeficientes não-lineares, ny e nu representam o grau de não-linearidade. Também pode ser visto como um caso particular do *NCARMA* onde apenas os parâmetros associados à entrada e aos termos cruzados de segunda ordem são diferentes de zero.

Exemplo 2.3 - A equação (2.25) representa um modelo Bilinear, com $ny = 3$ e $nu = 1$, usado para descrever o mesmo processo *Fan and Plate* do exemplo 2.2 (Marchi, 1999).

$$\begin{aligned} y(t) = & 1.2515y(t-1) - 0.5607y(t-2) - 0.3267y(t-3) - 0.1243u(t-1) + 0.3829u(t-2) \\ & + 0.3026y(t-1)u(t-1) - 0.3314y(t-1)u(t-2) - 0.4992y(t-2)u(t-1) \\ & + 0.5181y(t-2)u(t-2) + 0.2347y(t-3)u(t-1) - 0.1264y(t-3)u(t-2) \end{aligned} \quad (2.25)$$

A aplicação de um modelo bilinear na representação de um processo industrial está associada às plantas cujas características são inerentemente bilineares como processos de fermentação, colunas de destilação, reatores nucleares e reatores químicos. Como a estrutura do modelo bilinear é linear em relação aos parâmetros é possível aplicar as mesmas técnicas de identificação empregadas nos modelos lineares (Haber, 1995; Marchi, 1999; Fontes *et al.*, 2002a).

2.3.4 Modelo de Hammerstein

Este modelo consiste de um elemento estático não-linear seguido por um sistema dinâmico linear como ilustrado na Figura 2.3.




Figura 2.3 – Modelo de Hammerstein.

O bloco da não-linearidade estática (NL) pode ser representado por um polinômio, pela equação da não-linearidade ou por modelos semi-paramétricos.

► Representação da NL por um Polinômio

Este caso é o mais comum quando não se dispõe de informações a respeito da natureza da não-linearidade, aproximado-a por uma expansão polinomial finita do tipo

$$x(t) = \gamma_1 u(t) + \gamma_2 u^2(t) + \dots + \gamma_m u^m(t) \quad (2.26)$$

onde t é o instante de tempo, $x(t)$ é a pseudo-saída, não-mensurável, do bloco não-linear, $u(t)$ é a variável de entrada, γ_i ($i = 1, \dots, m$) representam os coeficientes do polinômio e m é o grau de não-linearidade do modelo (Boutayeb *et al.*, 1996).

Normalmente considera-se $\gamma_1 = 1$ transferindo o ganho estático para a parcela dinâmica linear, $G(q^{-1})$, que pode ser representada por qualquer um dos modelos lineares apresentados na seção 2.2.

O modelo de Hammerstein pode ser apresentado, ainda, como um caso particular do modelo de Volterra, equação (2.20), com $h_{ij} = 0$, $i \neq j$, tornando-se

$$y(t) = h_0 + \sum_{j=0}^{nu} b_{1j} u(t-d-j) + \sum_{j=0}^{nu} b_{2j} u^2(t-d-j) + \sum_{j=0}^{nu} b_{3j} u^3(t-d-j) + \dots + \varepsilon(t) \quad (2.27)$$

Outra representação comum, na forma paramétrica, pode ser obtida a partir da forma AR-Volterra, equação (2.22), resultando

$$A(q^{-1})y(t) = b_0 + B_1(q^{-1})u(t-d) + \sum_{j=0}^{nu} b_{2j} u^2(t-d-j) + \sum_{j=0}^{nu} b_{3j} u^3(t-d-j) + \dots + \varepsilon(t) \quad (2.28)$$

que pode ser reescrita como

$$A(q^{-1})y(t) = B(q^{-1}) \sum_{i=1}^m \gamma_i u^i(t-d) + \varepsilon(t) \quad (2.29)$$

ou, ainda, substituindo a equação (2.26),

$$A(q^{-1})y(t) = B(q^{-1})x(t) + \varepsilon(t) \quad (2.30)$$

que apresenta a relação linear entra a saída $y(t)$ e a pseudo-saída $x(t)$.

Exemplo 2.4 - A equação (2.31) representa um modelo de Hammerstein, com $na = 1$, $nb = 2$ e $m = 3$, usado para descrever um reator (Sahli *et al.*, 2002).

$$y(t) = 0.962y(t-1) + 0.032u(t-1) + 0.085u(t-2) - 0.114u^2(t-1) + 0.061u^2(t-2) - 0.035u^3(t-1) + 0.031u^3(t-2) \quad (2.31)$$

► Representação pelo Mapeamento Estático da NL

Este caso é aplicado quando a não-linearidade envolvida apresenta uma estrutura conhecida como saturação, zona-morta, histerese ou relé, dentre outras (Bai, 2002). A Figura 2.4 ilustra a representação de alguns tipos comuns de não-linearidades cujas equações aparecem representadas na Tabela 2.4.




Figura 2.4 – Tipos Comuns de Não-Linearidades.

Tabela 2.4 – Representação de *NL* com Estrutura Conhecida.

Não-Linearidade	Equação
Saturação	$x(t) = \frac{1 + \operatorname{sgn}(a - u(t))}{2} u(t) + \frac{1 + \operatorname{sgn}(u(t) - a)}{2} a \cdot \operatorname{sgn}(u(t))$
Zona-morta	$x(t) = u(t) - a \cdot \operatorname{sgn}(u(t)) - \frac{1 + \operatorname{sgn}(a - u(t))}{2} [u(t) - a \cdot \operatorname{sgn}(u(t))]$
Histerese	$x(t) = \frac{\operatorname{sgn}(u(t) - a) + \operatorname{sgn}(u(t) + a)}{2}$
Relé	$x(t) = \begin{cases} u(t) - a & \text{se } u(t) > u(t-1), \\ u(t) + a & \text{se } u(t) < u(t-1), \\ x(t-1) & \text{se } u(t) = u(t-1) \end{cases}$

onde “sgn” representa a função sinal.

► Representação da *NL* por um Modelo Semi-paramétrico

Esta terminologia foi empregada por Unbehauen (1996) para descrever uma classe de modelos baseada em redes neurais artificiais (*ANN – Artificial Neural Networks*) e informação lingüística difusa. Nestes casos os modelos são formados por números que correspondem às ponderações de uma *ANN* ou ao grau de pertinência num conjunto difuso.

- Modelos *ANN* – Estes modelos têm a capacidade de “aprender” o comportamento entrada-saída do sistema. Uma rede neural consiste de vários elementos computacionais simples, denominados de nós, arranjados em camadas e operando em paralelo (Figura 2.5). Os pesos das conexões entre os nós são adaptados durante a operação de treinamento da rede que tem por objetivo melhorar o seu desempenho (Unbehauen, 1996; Al-Duwaish e Karim, 1997; Bauer e Ninness, 2000; Jordanov *et al.*, 2005).




Figura 2.5 – Estrutura de um modelo Hammerstein Neural.

- Modelos Nebulosos (*fuzzy models*) – este modelo combina informação numérica e lingüística (do tipo pequeno, médio, grande, etc.) possibilitando a aplicação do conhecimento prévio das características do processo mesmo que este seja incompleto e/ou com incertezas (Sjöberg *et al.*, 1995, Abonyi *et al.*, 2000; Coelho, 2000; Jurado, 2006).




Figura 2.6 – Estrutura de um modelo Hammerstein Nebuloso.

A popularidade do modelo de Hammerstein deve-se ao fato da maior simplicidade em relação às representações de Volterra e Bilinear aliada a uma capacidade de representação da não-linearidade da maioria dos processos práticos sendo capaz de representar processos com atuadores não-lineares e ganhos variantes (Santos *et al.*, 2004).

A literatura de controle e identificação de sistemas conta com inúmeras aplicações do modelo de Hammerstein na representação de processos de fermentação (Roux *et al.*, 1996), colunas de destilação (Pearson e Pottmann, 2000), trocadores de calor (Eskinat *et al.*, 1991; Al-Duwaish e Naeem, 2001; Fink e Nelles, 2001), processos de nível (Katende *et al.*, 1998; Coelho *et al.*, 2002), turbina de gás (Chiras, 2002), motor D.C. (Kara e Eker, 2004), reatores químicos (Katende e Jutan, 1996; Menold *et al.*, 1997; Sahli *et al.*, 2002; Aguirre *et al.*, 2005), controle de pH (Zhu *et al.*, 1991; Zhu e Seborg, 1994; Fruzzetti *et al.*, 1997; Zou *et al.*, 2006), motor diesel (Pérez *et al.*, 2006), além de qualquer processo do **Tipo Hammerstein**, ou seja, que possa ser representado por uma não-linearidade seguida de uma parcela dinâmica linear (Hwang e Hsu, 1995; Haber *et al.*, 2000; Coelho e Santos, 2002).

2.3.5 Modelo de Wiener

Este modelo apresenta um sistema dinâmico linear seguido por um elemento não-linear, de forma contrária ao modelo de Hammerstein, como ilustrado na Figura 2.7.




Figura 2.7 – Modelo de Wiener.

Da mesma forma que o caso de Hammerstein, a parcela linear pode ser representada por um dos modelos apresentados na seção 2.2 enquanto que a não-linearidade (NL) pode ser representada por um polinômio do tipo

$$y(t) = \gamma_1 w(t) + \gamma_2 w^2(t) + \dots + \gamma_m w^m(t) \quad (2.32)$$

onde $w(t)$ é a pseudo-saída do bloco linear ou, ainda, baseada nas outras formas de representação válidas para o modelo de Hammerstein visto que o modelo de Wiener é considerado o seu dual (Doyle *et al.*, 2001).

Exemplo 2.5 - As equações (2.33) e (2.34) representam um modelo de Wiener, com $na = 2$, $nb = 1$ e $m = 3$, utilizado em Chiras (2002) para representar o comportamento de uma turbina a gás.

$$y(t) = 5.46w(t) + 0.167w^2(t) + 0.0669w^3(t) \quad (2.33)$$

onde

$$w(t) = 0.9993w(t-1) - 0.0373w(t-2) + 0.0043u(t-1) - 0.00028u(t-2) \quad (2.34)$$

O modelo de Wiener conta com diversas aplicações registradas na literatura de controle de processos como na representação do comportamento muscular sob anestesia (Mahfouf e Linkens, 1998), controle de pH (Norquay *et al.*, 1998; Wellers e Rake, 2000), colunas de destilação (Hagenblad, 1999; Pearson e Pottmann, 2000), controle de válvulas (Al-Duwaish e Naeem, 2001), turbina a gás (Chiras, 2002), reatores químicos (Menold *et al.*, 1997; Al-Seyab e Cao, 2006), além de qualquer processo do **Tipo Wiener**, ou seja, que possa ser representado por uma parcela dinâmica linear seguida de uma não-linearidade estática (Gerksic *et al.*, 2000).

Na tentativa de criar modelos mais abrangentes surgiram combinações dos modelos de Wiener e Hammerstein na forma ilustrada na Figura 2.8.




Figura 2.8 – Modelo Wiener-Hammerstein.

2.4 COMPARAÇÃO ENTRE OS MODELOS

Os diversos modelos apresentados nas seções anteriores podem ser considerados como casos particulares do modelo *NCARMA* de maneira que, baseado na representação da equação (2.35), particularização da equação (2.17) para o caso onde o grau de não-linearidade $\ell = 2$, é possível verificar cada caso através da Tabela 2.5.

$$\begin{aligned}
 y(t) = & h_0 + \sum_{n_1=1}^{n_u} h_u(n_1)u(t-n_1) + \sum_{n_1=1}^{n_y} h_y(n_1)y(t-n_1) + \sum_{n_1=1}^{n_y} \sum_{n_2=n_1}^{n_y} h_{uu}(n_1, n_2)u(t-n_1)u(t-n_2) \\
 & + \sum_{n_1=1}^{n_y} \sum_{n_2=1}^{n_u} h_{yu}(n_1, n_2)y(t-n_1)u(t-n_2) + \sum_{n_1=1}^{n_y} \sum_{n_2=n_1}^{n_y} h_{yy}(n_1, n_2)y(t-n_1)y(t-n_2)
 \end{aligned}
 \tag{2.35}$$

Tabela 2.5 – Particularizações do Modelo *NCARMA*.

Coefficientes	Linear	Hammerstein	Bilinear	Volterra	<i>NCARMA</i>
h_u	☑	☑	☑	☑	☑
h_y	–	☑	☑	☑	☑
h_{uu}	–	☑ *	–	☑	☑
h_{yu}	–	–	☑	–	☑
h_{yy}	–	–	–	–	☑

onde ☑ denota um coeficiente presente no modelo
 * apenas quando $n_1 = n_2$
 – denota um coeficiente inexistente

Pela análise do diagrama de Venn da Figura 2.9, que ilustra a relação entre os tipos de modelos apresentados, é possível comprovar a informação já disponível na Tabela 2.5 em relação à capacidade de generalização de cada modelo desde o modelo *NCARMA*, caso geral, até o modelo linear, caso particular comum a todos os demais.

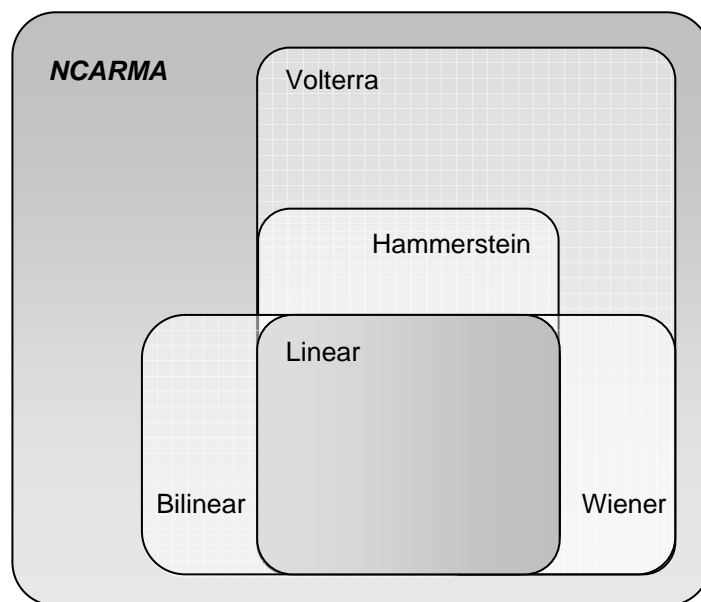


Figura 2.9 – Relação entre os modelos não-lineares.

Como a complexidade dos modelos estudados está diretamente relacionada ao número de termos envolvidos, a Tabela 2.6 apresenta uma comparação levando em conta o caso não-paramétrico na representação do modelo linear.

Tabela 2.6 – Comparação da Complexidade dos Modelos.

Modelo	Número de Termos
Linear	N
Hammerstein / Wiener	$N + m$
Bilinear	$N + ny.nu$
Volterra	$\frac{(N + m)! - N!}{m!}$
NCARMA	$\frac{(N + ny + m)!}{(N + ny)! m!}$

Embora os modelos de Volterra e *NCARMA* possam apresentar um número bastante elevado de termos é comum a aplicação de técnicas de redução de modelo ao longo do procedimento de identificação visando empregar apenas aqueles termos que sejam mais relevantes em relação às características de interesse do processo (Aguirre, 2007; Favier *et al.*, 2004).

2.5 CONCLUSÃO

Neste capítulo foram discutidos os aspectos da modelagem de processos lineares e não-lineares. Os principais tipos de modelos discretos para sistemas *SISO* foram apresentados e suas características fundamentais foram destacadas de maneira a permitir a seleção daquele que se apresente como o mais adequado a uma aplicação particular. Exemplos presentes na literatura foram apresentados para caracterizar a forma de representação de cada modelo discreto.

Destaca-se como principal contribuição deste capítulo a generalização dos modelos apresentados e a comparação de sua complexidade visando sua aplicação em modelagem, predição ou controle.

A aplicação de alguns dos modelos não-lineares apresentados através de técnicas de identificação é desenvolvida no capítulo 3.

3. IDENTIFICAÇÃO DE SISTEMAS NÃO-LINEARES

3.1 INTRODUÇÃO

A identificação de sistemas busca a representação do comportamento de um processo por meio de um modelo matemático independente do conhecimento prévio a respeito do mesmo. Um procedimento de identificação pode ser dividido em várias etapas dentre as quais se destacam: tratamento das medidas, seleção do modelo, determinação da estrutura, estimação dos parâmetros e validação do modelo como ilustrado na Figura 3.1.

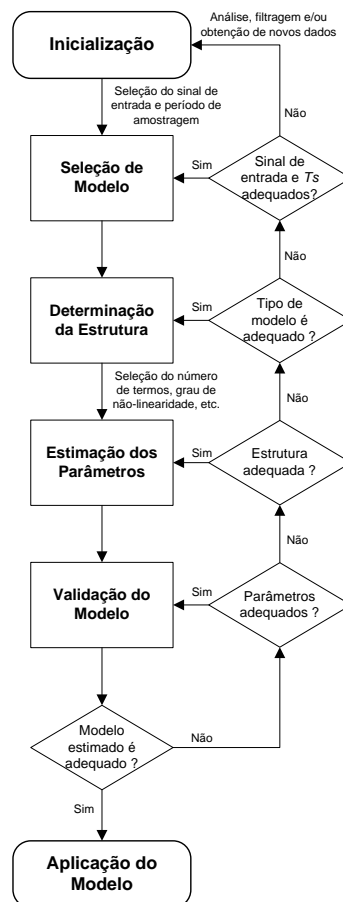


Figura 3.1 – Diagrama do Protocolo de Identificação.

O sinal empregado na identificação do sistema deve ser capaz de excitá-lo em toda a faixa de interesse pois, caso contrário, estas características não são registradas e, portanto, o modelo identificado não é capaz de representá-las. Sinais de entrada aleatórios possibilitam a condição de excitação persistente para os problemas de estimação que aplicam a técnica dos mínimos quadrados e a aplicação de um sinal do tipo ruído branco é, também, desejável (Ljung, 1999).

Enquanto que na identificação de sistemas lineares a característica do sinal de entrada mais importante é o conteúdo de frequências no seu espectro, para sistemas não-lineares destaca-se também a amplitude do sinal que deve ser capaz de fazer o sistema operar em toda a faixa de operação de interesse fazendo-o revelar as suas características não-lineares. Na prática, sinais do tipo **ruído branco** (sinal aleatório cujo espectro tem potência em todas as frequências) e **PRBS** (*Pseudo-Random Binary Signal*) são comumente utilizados tanto na identificação de processos lineares como não-lineares (Ljung e Glad, 1994; Aguirre, 2000; Gómez e Baeyens, 2001).

A literatura apresenta diversas técnicas de identificação para sistemas lineares, representados por equações a diferenças, sendo as mais populares aquelas baseadas no algoritmo dos mínimos quadrados (*MQ*). Neste capítulo é discutida a identificação de sistemas *SISO* não-lineares rerepresentados pelo modelo de Hammerstein baseadas nas medidas de entrada e saída do processo (Coelho e Coelho, 2004).

3.2 SELEÇÃO DO MODELO

Os modelos matemáticos mais comuns para a representação de um processo dinâmico estão apresentados no capítulo 2 e cada um possui características distintas que devem ser levadas em conta na seleção. Para escolher o modelo mais adequado para uma aplicação particular deve-se considerar sua capacidade de representar as características da planta sem, no entanto, desconsiderar que a simplicidade do modelo está diretamente relacionada ao esforço computacional envolvido sendo, portanto, um fator fundamental para uma implementação em tempo-real. Na prática, o modelo escolhido é, em geral, o mais simples possível capaz de atender aos requisitos operacionais estabelecendo um compromisso entre capacidade de aproximação x simplicidade de representação (Santos, 1998; Ljung, 1999; Pearson, 2003).

A Figura 3.2 apresenta um diagrama que pode ser usado como uma ferramenta na seleção de um modelo a ser empregado na representação de um processo não-linear. Conforme o conhecimento prévio das características do processo é possível determinar a partir de um teste de não-linearidade a possibilidade de representação linear ou a necessidade de emprego de um modelo não-linear. No caso de um modelo linear informações em relação à dinâmica, complexidade, estabilidade em malha aberta e conhecimento prévio da estrutura são utilizadas para a definição de um modelo paramétrico ou não-paramétrico. Quando o modelo escolhido é não-linear, o conhecimento do tipo de não-linearidade possibilita a seleção de modelos de Wiener ou Hammerstein (NL estática) ou Bilinear e Volterra (NL dinâmica). O diagrama permite, ainda, decidir a respeito da forma de representação da não-linearidade estática conforme o conhecimento da sua estrutura, representação via expansão polinomial ou mesmo através de modelos semi-paramétricos (neural e/ou nebuloso).

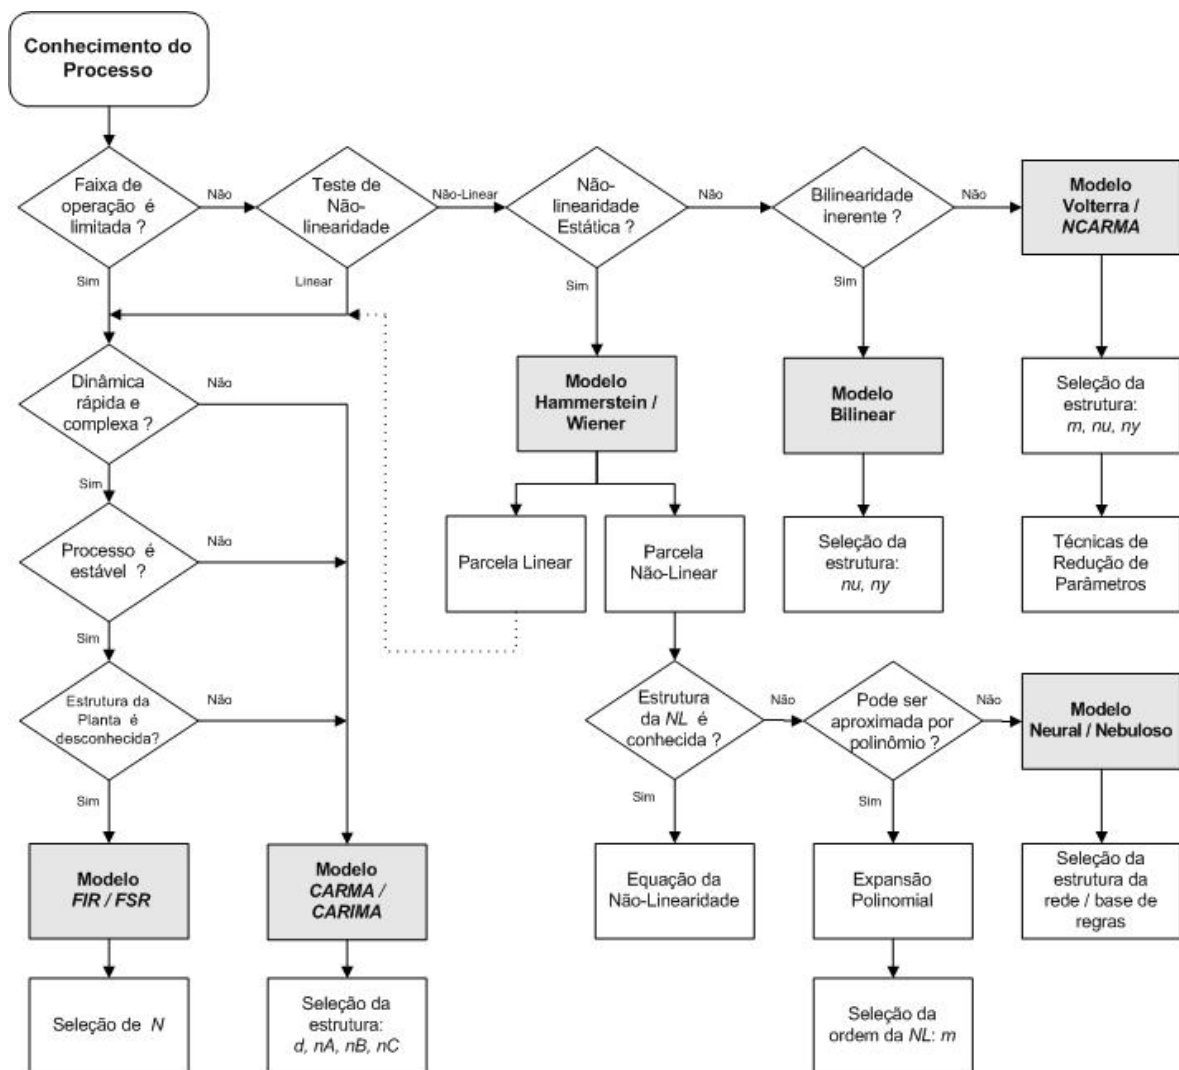


Figura 3.2 – Diagrama para Seleção de Modelo.

3.2.1 Detecção de Não-Linearidade

Uma etapa fundamental na determinação da necessidade de uso de um modelo não-linear na representação da planta é a detecção da não-linearidade (*NL*) do processo. Um sistema não-linear apresenta uma não-linearidade que pode ser classificada como **fraca**, **média** ou **forte** e um dos seguintes tipos de comportamento apresentados na Tabela 3.1 (Pearson, 2003).

Tabela 3.1 – Comportamento Não-Linear.

Tipo de <i>NL</i>	Comportamento	Descrição
Fraca	Resposta Assimétrica	Característica da resposta dependente da entrada violando o Princípio da Superposição dos Efeitos.
	Geração de Harmônicas	O sistema sujeito a uma entrada senoidal produz uma saída não senoidal de mesma frequência.
	Multiplicidade de Entrada	Uma saída corresponde a mais de uma entrada em regime permanente.
Média	Estabilidade Dependente da Entrada	A estabilidade do sistema depende da amplitude da entrada aplicada.
Forte	Multiplicidade de Saída	Uma entrada leva a mais de uma saída em regime permanente.
	Geração de Sub-harmônicas	O sistema sujeito a uma entrada senoidal produz uma saída não senoidal de frequência menor que a entrada.
	Comportamento Caótico	O sistema apresenta respostas altamente irregulares para entradas simples.

Alguns testes comuns permitem a observação de um comportamento não-linear auxiliando, portanto, na decisão de optar-se por este tipo de representação na seleção de um modelo.

Simetria e Dependência de Amplitude da Entrada

Estes testes permitem confrontar os comportamentos linear x não-linear cobrindo a maioria dos processos não-lineares.

- **Teste de Simetria** – representa o mais comum dos testes de não-linearidade, consiste na aplicação de entradas simétricas ao sistema e a conseqüente observação da saída.

Exemplo 3.1 - O comportamento do sistema representado pela equação (3.1) é ilustrado pela Figura 3.3 com a aplicação de degraus de entrada com valores $u(t) = +3; +1; -1$ e -3 .

$$y(t) = 0.8y(t-1) - 0.3y(t-1)\text{sen}(y(t-1)) + u(t-1) \quad (3.1)$$




Figura 3.3 – Teste de Simetria.

O comportamento do sistema, ilustrado na Figura 3.3, apresenta-se bastante assimétrico em relação às entradas aplicadas caracterizando, de forma bastante acentuada, este tipo de não-linearidade. Embora seja um teste bastante popular a característica de simetria é uma condição apenas necessária para indicar a linearidade de um sistema, ou seja, mesmo um sistema não-linear pode apresentar um comportamento simétrico dentro de uma faixa de operação restrita e, neste caso, outros testes se fazem necessários.

- **Teste de Dependência de Amplitude** – consiste na aplicação de entradas em degraus de amplitudes crescentes e a observação da saída. Características dinâmicas e até de estabilidade de um sistema não-linear podem ser dependentes da amplitude da entrada aplicada.

Exemplo 3.2 -A Figura 3.4 ilustra o comportamento de um sistema representado pela equação (3.2) sujeita à aplicação de degraus de entrada com valores $u(t) = 4.2k$, $k = 1$ a 5.

$$y(t) = -0.8y(t-1) + 0.2y^2(t-1) + 0.2u(t-1) \quad (3.2)$$




Figura 3.4 – Teste de Dependência de Amplitude da Entrada.

Observa-se que o comportamento dinâmico do sistema varia em função da amplitude do sinal de entrada e, a partir da entrada $u(t) = 21$, torna-se instável.

Entradas Periódicas

Pela análise do comportamento do sistema sujeito a uma entrada periódica é possível observar comportamentos não-lineares do tipo geração de harmônicas ou sub-harmônicas.

Exemplo 3.3 -A equação (3.3) representa um sistema com uma não-linearidade do tipo seno na entrada

$$y(t) = 0.9y(t-1) + 0.1\text{sen}(2\pi u(t-1)) \quad (3.3)$$

e a Figura 3.5 representa a relação entrada x saída para este sistema onde a entrada é um sinal senoidal e a saída é um sinal não-senoidal de mesma frequência que a entrada caracterizando um comportamento não-linear com geração de harmônicas.




Figura 3.5 – Teste de Entradas Periódicas.

O modelo de Hammerstein mostra-se adequado na representação das não-linearidades descritas como fracas na Tabela 3.1, pois é capaz de reproduzir os comportamentos característicos deste tipo de não-linearidade.

Embora a análise do comportamento do processo indique a necessidade de utilização de um modelo não-linear, restrições do ponto de vista da aplicação em tempo-real podem conduzir o usuário para outras soluções como, por exemplo, o emprego de múltiplos modelos lineares levando em conta faixas de operação mais restritas (Marchi, 1999) ou, ainda, o uso de um único modelo linear pode ser suficiente para aplicações em controle de processos quando é empregado algum tipo de estratégia adaptativa (Åström e Wittenmark, 1995).

3.3 SELEÇÃO DE ESTRUTURA

Existem diversos critérios para a seleção de ordem de modelos lineares monovariáveis como aqueles baseados na razão entre determinantes, critério de informação de Akaike (*AIC – Akaike's Information Criterion*) e critério do erro de predição final (*FPE*

– *Final Prediction Criterion*). No entanto, quando o sistema é não-linear são poucas as ferramentas para auxiliar nesta etapa. Aguirre (2000) propõe a aplicação da taxa de redução do erro, *ERR* (*Error Reduction Ratio*), aplicadas a modelos *NCARMA*. Esta estratégia permite a detecção de quais parcelas do modelo são mais relevantes para serem incluídas e quais podem ser consideradas desprezíveis.

O caso particular do modelo de Hammerstein permite a aplicação de uma extensão do método da razão entre determinantes, *DR* (*Determinant Ratio*).

3.3.1 Razão entre Determinantes para o Modelo de Hammerstein

Esta proposta apresentada como contribuição da tese, assim como no caso linear, este método baseia-se na singularidade da matriz de informação cujos elementos possuem dados sobre a correlação entre os sinais de entrada e saída do sistema em diferentes instantes de tempo. A ordem da matriz de informação é função da ordem do modelo a ser obtido por identificação. Quando a ordem do modelo é selecionada maior que o sistema real, a matriz de informação torna-se redundante, ou seja, apresenta colunas linearmente dependentes que levam à singularidade.

Para o modelo de Hammerstein, onde a não-linearidade é aproximada por um polinômio de ordem m e cuja parcela linear é representada por um modelo do tipo *CARMA*, tem-se que

$$A(q^{-1})y(t) = q^{-d}B(q^{-1})x(t) + \varepsilon(t) \quad (3.4)$$

onde

$$A(q^{-1}) = 1 + a_1q^{-1} + \dots + a_{n_a}q^{-n_a}$$

$$B(q^{-1}) = b_0 + b_1q^{-1} + \dots + b_{n_b}q^{-n_b}$$

e $\varepsilon(t)$ representa erros de modelagem e/ou ruídos de medição, a pseudo-saída $x(t)$ pode ser representada por

$$x(t) = \gamma_1u(t) + \gamma_2u^2(t) + \dots + \gamma_mu^m(t) \quad (3.5)$$

a representação da parcela linear por equação a diferenças é

$$y(t) = -a_1y(t-1) - a_2y(t-2) - \dots - a_ny(t-na) + b_0x(t-d) + \dots + b_nbx(t-d-nb) + \varepsilon(t) \quad (3.6)$$

que pode ser reescrita como

$$y(t) = \varphi^T(t)\theta(t) + \varepsilon(t) \quad (3.7)$$

onde o vetor de medidas é formado como se estivesse tratando de um sistema *MISO* (*Multiple Input Single Output*) na forma (Eskinat, *et al.*, 1991)

$$\varphi^T(t) = [-y(t-1) \dots -y(t-na) \quad u(t-d) \dots u(t-d-nb) \quad u^2(t-d) \dots u^2(t-d-nb) \dots u^m(t-d-nb)] \quad (3.8)$$

com dimensão $[(na + (nb + 1)m) \times 1]$ e o vetor de parâmetros pode ser expresso na forma

$$\theta = [a_1 \ a_2 \ \dots \ a_{na}; b_0\gamma_1 \ b_1\gamma_1 \ \dots \ b_{nb}\gamma_1; b_0\gamma_2 \ b_1\gamma_2 \ \dots \ b_{nb}\gamma_2; \dots ; b_0\gamma_m \ b_1\gamma_m \ \dots \ b_{nb}\gamma_m]^T$$

Define-se, então, a matriz de informação (Aguirre, 2007) pela equação

$$Q^*(t, n, m) = \Xi \left[\varphi(t, n, m) \varphi^T(t, n, m) \right] \quad (3.9)$$

que, para um grande número de medidas N , pode ser representada, aproximadamente, por

$$Q(\varphi, n, m) = \frac{1}{N} \sum_{t=1}^N \varphi(t, n, m) \varphi^T(t, n, m) \quad (3.10)$$

Considerando que a ordem da parcela linear do sistema real seja n_0 , quando é utilizado um modelo com ordem imediatamente superior, n_0+1 , as últimas medidas de entrada e saída são uma combinação linear das anteriores e, portanto, a matriz Q torna-se singular, $\det Q(\varphi, n_0+1, m) \rightarrow 0$.

A seleção da ordem do modelo é feita pelo cálculo do determinante da matriz de informação e sua comparação com o de ordem imediatamente superior ($n+1$). Quando a razão entre os determinantes, DR , apresenta um aumento significativo admite-se, então, como n a ordem mais adequada para o modelo.

$$DR = \left| \frac{\det Q(\varphi, n, m)}{\det Q(\varphi, n+1, m)} \right| \quad (3.11)$$

Embora, geralmente, não seja muito significativa no cálculo do determinante da matriz Q , é desejável que a seleção da ordem do polinômio da não-linearidade, m , seja determinada antes do cálculo da DR . Isto pode ser feito por meio da determinação da característica estática do processo e do ajuste de um polinômio para sua representação. A ordem escolhida é a menor capaz de representar a não-linearidade estática na faixa de operação de interesse.

Exemplo 3.4 - Considera-se um processo cujo comportamento pode ser expresso por

$$y(t) = -a_1 y(t-1) - a_2 y(t-2) + b_0 x(t-1) + b_1 x(t-2) \quad (3.12)$$

onde $x(t) = \text{sen}(u(t))$, $a_1 = -0.7358$, $a_2 = 0.1353$, $b_0 = 0.2642$ e $b_1 = 0.1353$.

Embora seja possível determinar a característica estática do processo, Figura 3.6, aplicando uma entrada de sucessivos degraus com valores crescentes por tempo suficiente para que este alcance o regime permanente, optou-se pela determinação de ordem da função de transferência da parcela linear admitindo-se o desconhecimento da ordem da não-linearidade (m).




Figura 3.6 – Representação da NL do Exemplo 3.4.

O teste é realizado comparando as ordens da parcela linear $n = 1; 2; 3$ e 4 para a grau do polinômio que representa a não-linearidade valendo $m = 1; 2; 3$ e 4 conforme ilustrado na Figura 3.7.




Figura 3.7 – Teste DR para o Exemplo 3.4.

Em todos os casos representados na Figura 3.7, exceto pela diferença de escala, o comportamento é semelhante, indicando que um modelo de terceira ordem provoca um grande crescimento na DR apontando, portanto, como mais apropriado, o modelo de segunda ordem ($n = 2$).

A seleção da ordem do polinômio para a representação da não-linearidade estática (NL) do processo pode ser feita pela aproximação dos polinômios identificados em relação à característica estática do processo. Neste caso, apenas pela inspeção da Figura 3.6 é possível concluir que um polinômio com $m = 3$ é suficiente para uma representação da NL embora critérios numéricos possam ser empregados na seleção de m .

Exemplo 3.5 - Dado um processo cuja parcela dinâmica linear também pode ser expressa pela equação (3.12) mas que a não-linearidade é $x(t) = u(t) - 2u^2(t)$, o teste é realizado comparando as ordens da parcela linear $n = 1; 2; 3$ e 4 para a ordem do polinômio que representa a não-linearidade $m = 1; 2; 3$ e 4 conforme ilustrado na Figura 3.8.

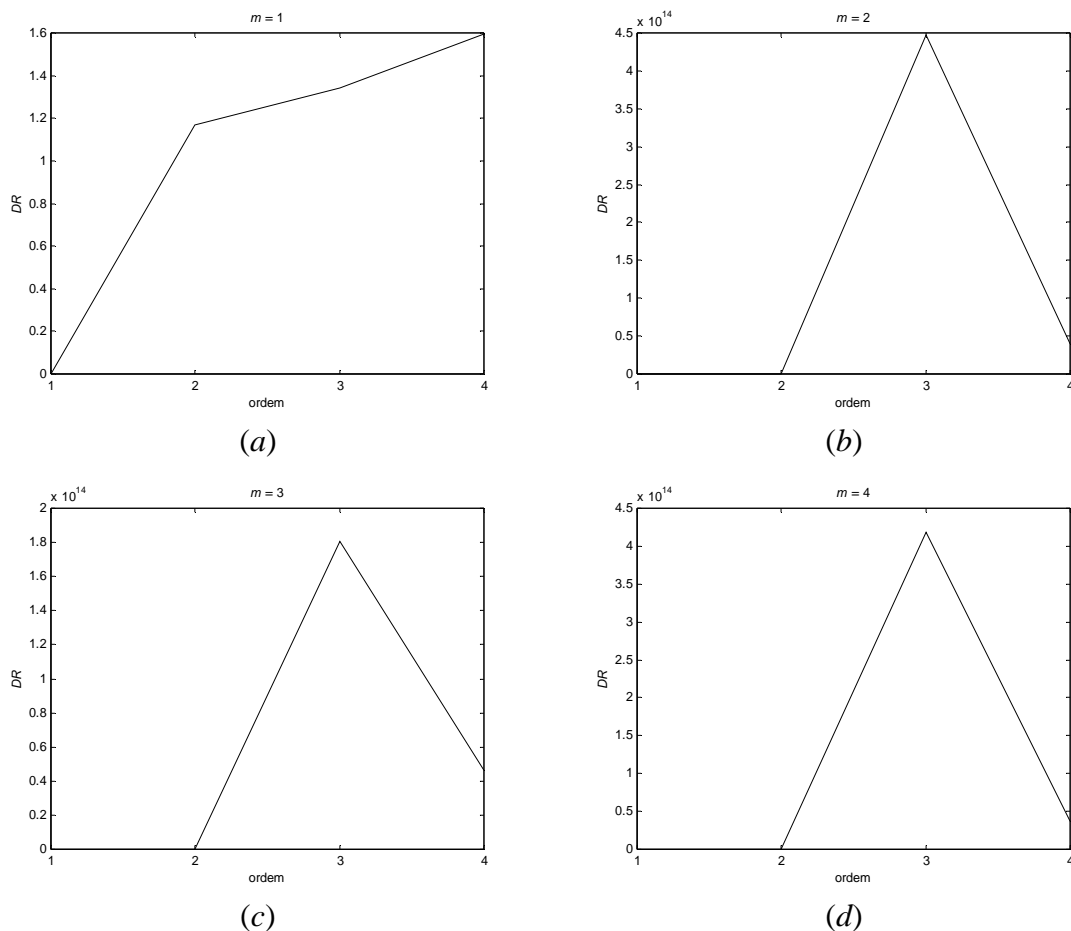


Figura 3.8 – Teste *DR* para o Exemplo 3.5.

A Figura 3.8 ilustra um caso onde o comportamento do *DR* é diferente para as simulações onde o grau de não-linearidade (m) é selecionado menor que o real, neste caso $m = 2$, destacando a importância da seleção prévia deste parâmetro. Pela observação da Figura 3.8 (b), (c) e (d) é possível determinar que a ordem mais adequada para o modelo é realmente $n = 2$. Esta diferença de comportamento considerando-se o desconhecimento do grau de não-linearidade pode ser ainda maior na presença de ruído. Neste sentido, possíveis soluções passam pelo uso de filtragem ou, ainda, técnicas que apresentam menor sensibilidade ao ruído como a razão entre determinantes instrumental e suas variações (Santos, 1998), além de técnicas baseadas em algoritmos genéticos (Hachino e Takata, 2005).

3.4 ESTIMAÇÃO DE PARÂMETROS

Nesta seção são apresentadas algumas estratégias de estimação de parâmetros para sistemas *SISO* não-lineares representados pelo modelo de Hammerstein baseadas nas medidas de entrada e saída do sistema. Para a formalização das técnicas optou-se por um modelo cuja parcela linear é representada por um modelo do tipo *CARMA*, equação (3.4), sendo possível a aplicação destas a outros tipos de modelo.

3.4.1 Método dos Mínimos Quadrados

Definindo-se o vetor de medidas, $\varphi(t)$, com dimensão $[(na + nb + 1) \times 1]$, para o caso linear

$$\varphi^T(t) = [-y(t-1) -y(t-2) \dots -y(t-na) u(t-d) u(t-d-1) \dots u(t-d-nb)] \quad (3.13)$$

e o vetor de parâmetros, $\theta(t)$, com dimensão $[(na + nb + 1) \times 1]$

$$\theta^T(t) = [a_1 a_2 \dots a_{na} b_0 b_1 \dots b_{nb}] \quad (3.14)$$

pode-se reescrever a equação (3.6) como

$$y(t) = \varphi^T(t)\theta(t) + \varepsilon(t) \quad (3.15)$$

que é denominado **modelo de regressão linear** (Wellstead e Zarrop, 1991; Ljung, 1996; Coelho e Coelho, 2004).

Admitindo-se que a realização de N medidas são suficientes para determinar os parâmetros θ , então tem-se que

$$\begin{bmatrix} y(0) \\ y(1) \\ \dots \\ y(N-1) \end{bmatrix} = \begin{bmatrix} \varphi^T(0) \\ \varphi^T(1) \\ \dots \\ \varphi^T(N-1) \end{bmatrix} \theta + \begin{bmatrix} \varepsilon(0) \\ \varepsilon(1) \\ \dots \\ \varepsilon(N-1) \end{bmatrix} \quad (3.16)$$

A representação matricial da equação (3.16) é

$$Y = \Phi\theta + \varepsilon \quad (3.17)$$

onde a matriz de observação é

$$\Phi = \begin{bmatrix} -y(-1) & -y(-2) & \dots & -y(-na) & u(-d) & u(-d-1) & \dots & u(-d-nb) \\ -y(0) & -y(-1) & \dots & -y(1-na) & u(1-d) & u(-d) & \dots & u(1-d-nb) \\ -y(1) & -y(0) & \dots & -y(2-na) & u(2-d) & u(1-d) & \dots & u(2-d-nb) \\ \dots & \dots & \dots & \dots & \dots & \dots & \dots & \dots \\ -y(N-2) & -y(N-3) & \dots & -y(N-na-1) & u(N-d-1) & u(N-d-2) & \dots & u(N-nb-d-1) \end{bmatrix}$$

e o vetor de saída é dado por $Y^T = [y(0) \ y(1) \ y(2) \ \dots \ y(N-1)]$

A estimativa do vetor de parâmetros, $\hat{\theta}$, pode ser obtida pelo procedimento dos mínimos quadrados (*least squares approach*). Utilizando a estimativa $\hat{\theta}$, a melhor predição da saída do sistema, \hat{y} , é calculada por

$$\hat{Y} = \Phi\hat{\theta} \quad (3.18)$$

e o erro de predição, e , é avaliado de acordo com

$$e = Y - \hat{Y} = Y - \Phi\hat{\theta} \quad (3.19)$$

O estimador dos mínimos quadrados é obtido minimizando o seguinte critério:

$$J = [Y - \Phi\hat{\theta}]^T W [Y - \Phi\hat{\theta}] \quad (3.20)$$

onde a matriz W é diagonal, na forma

$$W = \begin{bmatrix} w(1) & 0 & \dots & 0 \\ 0 & w(2) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & w(N) \end{bmatrix}$$

onde $w(i)$ é a ponderação em cada componente do erro cujo valor é diretamente proporcional à precisão da medida.

Minimizando a função custo da equação (3.20) em relação a $\hat{\theta}$ tem-se que

$$\frac{\partial J}{\partial \hat{\theta}} = -2(Y^T W \Phi)^T + 2\Phi^T W \Phi \hat{\theta} = 0$$

Assim, o estimador clássico dos mínimos quadrados ponderado é calculado por

$$\hat{\theta} = [\Phi^T W \Phi]^{-1} \Phi^T W Y \quad (3.21)$$

e isto conduz ao mínimo desde que

$$\frac{\partial^2 J}{\partial \hat{\theta}^2} = 2\Phi^T W \Phi > 0$$

condição esta garantida se a matriz $(\Phi^T W \Phi)$ é definida positiva (condição de excitação persistente).

O estimador dos mínimos quadrados não-ponderado é obtido admitindo-se que $W = \sigma^2 I_N$, isto é, a mesma ponderação aplicada em todos os erros de medida (considerando a mesma confiança a todas as medidas). Logo, a equação (3.21) torna-se

$$\hat{\theta} = [\Phi^T \Phi]^{-1} \Phi^T Y \quad (3.22)$$

sendo denominado estimador dos mínimos quadrados não-recursivo.

► Mínimos Quadrados para o Modelo de Hammerstein

Neste caso, o vetor de medidas é formado como se estivesse tratando de um sistema *MISO* na forma (Eskinat, *et al.*, 1991)

$$\phi^T(t) = [-y(t-1) \dots -y(t-na) \ u(t-d) \dots u(t-d-nb) \ u^2(t-d) \dots u^2(t-d-nb) \dots u^m(t-d-nb)] \quad (3.23)$$

com dimensão $[na + (nb + 1)m \times 1]$ e o vetor de parâmetros:

$$\hat{\theta} = [a_1 \ a_2 \ \dots \ a_{na}; b_0\gamma_1 \ b_1\gamma_1 \ \dots \ b_{nb}\gamma_1; b_0\gamma_2 \ b_1\gamma_2 \ \dots \ b_{nb}\gamma_2; \dots ; b_0\gamma_m \ b_1\gamma_m \ \dots \ b_{nb}\gamma_m]^T$$

considerando $\gamma_1 = 1$ pode-se obter diretamente os parâmetros da parcela linear do modelo e, em princípio, também os parâmetros da parcela não-linear, pela relação

$$\gamma_i = \frac{b_0\gamma_i}{b_0} = \frac{b_1\gamma_i}{b_1} = \dots = \frac{b_{nb}\gamma_i}{b_{nb}} \quad (3.24)$$

A presença de ruído de medição provoca, no entanto, incoerências nos resultados obrigando a adoção de outras medidas para solucionar este problema de redundância de parâmetros como, por exemplo, uma média aritmética, equação (3.25).

$$\gamma_i = \frac{1}{(nb+1)} \sum_{j=0}^{nb} \left(\frac{b_j\gamma_i}{b_j} \right) \quad (3.25)$$

► Mínimos Quadrados com Restrições

Esta proposta apresentada como contribuição da tese aparece como uma possível solução ao problema de redundância dos parâmetros observado. Consiste em se aplicar uma minimização numérica da função custo da equação (3.20) em relação à estimativa de θ considerando como restrições a garantia de coerência nos parâmetros obtidos na equação (3.24)

$$\left| \frac{\theta_i}{\theta_{nA+1}} \right| = \left| \frac{\theta_{i+1}}{\theta_{nA+2}} \right| = \dots = \left| \frac{\theta_{i+nB}}{\theta_{nA+nB}} \right| \quad (3.26)$$

com o valor de i igual a (n_A+n_B+1) , (n_A+2n_B+1) , ..., (n_A+mn_B+1) .

Para viabilizar a aplicação deste método as $m-1$ restrições de igualdade são transformadas em restrições de desigualdade na forma

$$\left| \frac{\theta_i}{\theta_{nA+1}} - \frac{\theta_{i+1}}{\theta_{nA+2}} \right| < \varepsilon \quad \dots \quad \left| \frac{\theta_{i+nB-1}}{\theta_{nA+nB-1}} - \frac{\theta_{i+nB}}{\theta_{nA+nB}} \right| < \varepsilon \quad (3.27)$$

onde ε corresponde a uma medida de tolerância, podendo ser alterado conforme a necessidade de precisão. Valores menores de ε levam a uma maior precisão aumentando, no entanto, a carga computacional do método.

3.4.2 Método do Erro de Predição

Esta estratégia permite a obtenção dos parâmetros do modelo diretamente na forma

$$\theta = [a_1, a_2, \dots, a_{na}, b_0, b_1, \dots, b_{nb}, \gamma_1, \gamma_2, \dots, \gamma_m]^T \quad (3.28)$$

através da minimização numérica do critério dos mínimos quadrados

$$V(\theta) = \frac{1}{N} \sum_{t=1}^N e^2(t, \theta) \quad (3.29)$$

onde $e(t, \theta) = y(t) - \hat{y}(t, \theta)$ é o erro de predição.

Como a derivada da função custo não é uma função linear em relação aos parâmetros não há solução analítica para este problema de minimização tornando-se necessário o uso de um método iterativo no qual o vetor de parâmetros é determinado por

$$\theta_{k+1} = \theta_k + \delta H(\theta_k)^{-1} g(\theta_k) \quad (3.30)$$

onde δ representa o passo, $H(\theta_k)$ é a Hessiana de $V(\theta_k)$ e $g(\theta_k)$ é o gradiente de $V(\theta_k)$.

Em função da dificuldade da determinação da Hessiana esta é aproximada pelo método de Levenberg-Marquardt

$$H(\theta_k) \approx \frac{1}{N} \sum_{t=1}^N \frac{\partial e(t, \theta)}{\partial \theta} \frac{\partial e(t, \theta)^T}{\partial \theta} + \mu I \quad (3.31)$$

onde μ é um parâmetro ajustável que garante a positividade da Hessiana e deve ser inicializado num valor pequeno, em torno de 10^{-4} . As derivadas do erro de predição podem ser determinadas por

$$\frac{\partial e(t, \theta)}{\partial a_i} = \frac{1}{A(q^{-1})} \sum_{j=1}^N \gamma_j \frac{B(q^{-1})}{A(q^{-1})} u^j(t-i)$$

$$\frac{\partial e(t, \theta)}{\partial b_i} = \frac{1}{A(q^{-1})} \sum_{j=1}^N \gamma_j u^j(t-i)$$

$$\frac{\partial e(t, \theta)}{\partial \gamma_j} = \frac{B(q^{-1})}{A(q^{-1})} u^j(t)$$

As iterações devem ser realizadas até que a norma do gradiente $g(\theta_k)$ atinja um limite pré-estabelecido ou que o número máximo de iterações seja alcançado (Ljung, 1999; Eskinat *et al.*, 1991).

Algoritmo do Erro de Predição

1. Inicializa θ (p. ex. estimando por MQ);
2. Calcula $V(\theta)$ e seleciona μ (pequeno, 10^{-4});
3. Calcula o gradiente $g(\theta)$ e a Hessiana $H(\theta)$;
4. Atualiza $\theta_k = \theta_{k-1} + \delta H(\theta_{k-1})^{-1} g(\theta_{k-1})$ e calcula $V(\theta_k)$;
5. Se $V(\theta_k) < V(\theta_{k-1})$, atualiza θ_k , decrementa μ e vai para o passo 2;
6. Se $V(\theta_k) > V(\theta_{k-1})$, incrementa μ e vai para o passo 3.

Condição de Parada: $\|g(\theta_{k-1})\| < g_{min}$ ou alcançando limite de iterações.

3.4.3 Método de Narendra – Gallman

Este método propõe a obtenção dos parâmetros do modelo de Hammerstein pela separação do problema de estimação da parcela linear e da parcela estática não-linear. Os parâmetros da parte linear são inicialmente arbitrados ou estimados empregando uma técnica linear e a função custo, equação (3.29)(3.13), reescrita na forma

$$V(\theta) = \frac{1}{N} \sum_{t=1}^N \left[y(t) - \frac{B(q^{-1})}{A(q^{-1})} U^T(t) \hat{\theta}_\gamma \right]^2 \quad (3.32)$$

onde $U^T(t) = [u(t) \dots u(t-nb) \ u^2(t) \dots u^2(t-nb) \dots u^m(t) \dots u^m(t-nb)]$ e $\theta_\gamma = [\gamma_1 \ \gamma_2 \ \dots \ \gamma_m]^T$, é minimizada em relação aos parâmetros da parte não-linear, θ_γ , isto é,

$$\frac{\partial V(\theta)}{\partial \theta_\gamma} = \frac{2}{N} \sum_{t=1}^N \frac{B(q^{-1})}{A(q^{-1})} U(t) \left[y(t) - \frac{B(q^{-1})}{A(q^{-1})} U^T(t) \theta_\gamma \right] \quad (3.33)$$

obtendo os parâmetros da não-linearidade

$$\theta_\gamma = \left[\sum_{t=1}^N \frac{B(q^{-1})}{A(q^{-1})} U(t) \frac{B(q^{-1})}{A(q^{-1})} U^T(t) \right]^{-1} \left[\frac{B(q^{-1})}{A(q^{-1})} U(t) y(t) \right] \quad (3.34)$$

e, desta forma, a pseudo-saída $x(t)$ pode ser calculada, equação (3.5). A partir do valor de $x(t)$ a parcela linear é determinada novamente e este procedimento é repetido até haver convergência (Narendra e Gallman, 1966; Eskinat *et al.*, 1991).

Algoritmo de Narendra-Gallman

1. Inicializa a parte linear $[a_1, a_2, \dots, a_{na}, b_1, b_2, \dots, b_{nb}]$;
2. Minimiza $V(\theta)$ em relação à parte não-linear e estimação de $[\gamma_1, \gamma_2, \dots, \gamma_m]$;
3. Calcula a pseudo-saída: $x(t) = \gamma_1 u(t) + \gamma_2 u^2(t) + \dots + \gamma_m u^m(t)$;
4. Estima os parâmetros da parte linear e vai para o passo 2.

Condição de Parada: convergência dos parâmetros.

Esta estratégia pode apresentar problemas de estabilidade e convergência (Boutayeb *et al.*, 1996).

3.4.4 Método de Boutayeb

Esta proposta consiste em transformar a representação do modelo (3.4), em um modelo linear em parâmetros (Boutayeb *et al.*, 1996).

$$y(t) = \varphi^T(t) \theta \quad (3.35)$$

onde $\varphi(t)$ e θ são vetores definidos como

$$\begin{aligned} \varphi(t) &= [-y(t-1) \dots -y(t-na) \ u(t-d) \dots u(t-d-nb) \ u^2(t-d) \dots u^2(t-d-nb) \dots u^m(t-d-nb)]^T \\ \theta &= [a_1 \ a_2 \dots a_{na}; \ b_0 \ b_1 \dots b_{nb}; \ b_0 \gamma_2 \dots b_{nb} \gamma_2; \ b_0 \gamma_m \dots b_{nb} \gamma_m]^T \end{aligned}$$

considerando $\gamma_1 = 1$.

O estimador dos mínimos quadrados leva a seguinte estimação de parâmetros

$$\hat{\theta} = (\Phi^T \Phi)^{-1} \Phi^T Y \quad (3.36)$$

onde $\Phi = [\varphi(t) \ \varphi(t+1) \ \dots \ \varphi(t+N)]^T$ e $Y = [y(t) \ y(t+1) \ \dots \ y(t+N)]^T$

Utilizando esta estrutura, os parâmetros da parcela linear podem ser calculados diretamente, ou seja,

$$\hat{\theta} = \begin{bmatrix} \hat{\theta}_a \\ \hat{\theta}_b \\ \hat{\theta}_{b\gamma} \end{bmatrix} \quad (3.37)$$

onde

$$\begin{aligned} \hat{\theta}_a &= [a_1 \ a_2 \ \dots \ a_{na}]^T \\ \hat{\theta}_b &= [b_0 \ b_1 \ \dots \ b_{nb}]^T \\ \hat{\theta}_{b\gamma} &= [b_0\gamma_2 \ \dots \ b_{nb}\gamma_2 \ b_0\gamma_3 \ \dots \ b_{nb}\gamma_3 \ \dots \ b_{nb}\gamma_m]^T \end{aligned}$$

O problema de redundância de parâmetros é resolvido, obtendo os parâmetros da parcela não-linear separadamente, na forma

$$\theta_\gamma = [\gamma_1 \ \gamma_2 \ \dots \ \gamma_m]^T$$

através da expressão

$$\hat{\theta}_\gamma = M \hat{\theta}_{b\gamma} \quad (3.38)$$

sendo a matriz M definida no teorema 3.1.

Teorema 3.1

O estimador consistente de θ_s é dado por

$$\hat{\theta}_s = \begin{bmatrix} \hat{\theta}_a \\ \hat{\theta}_b \\ \hat{\theta}_\gamma \end{bmatrix} = \begin{bmatrix} \Phi_a \\ \Phi_b \\ M\Phi_{b\gamma} \end{bmatrix} \Phi^T Y \quad (3.39)$$

onde

$$\begin{bmatrix} \Phi_a \\ \Phi_b \\ \Phi_{b\gamma} \end{bmatrix} = (\Phi^T \Phi)^{-1} \quad (3.40)$$

e M é uma matriz diagonal, de ordem $N^2 m$, definida como

$$M = \begin{bmatrix} \hat{\theta}_b^+ & 0 & \dots & 0 \\ \vdots & & & \vdots \\ 0 & \dots & 0 & \hat{\theta}_b^+ \end{bmatrix} \quad (3.41)$$

com $\hat{\theta}_b = \Phi_b \Phi^T Y$ e θ_b^+ sendo a pseudo-inversa de θ_b tal que $\theta_b^+ \theta_b = 1$.

Prova do Teorema 3.1:

Como $\hat{\theta}_b$ e $\hat{\theta}_{b\gamma}$ são obtidos diretamente de (3.38) na forma

$$\hat{\theta}_b = \Phi_b \Phi^T Y \quad (3.42)$$

$$\hat{\theta}_{b\gamma} = \Phi_{b\gamma} \Phi^T Y \quad (3.43)$$

e os parâmetros do vetor $\theta_{b\gamma}$ podem ser escritos como

$$\theta_{b\gamma} = \begin{bmatrix} \theta_b \gamma_2 \\ \vdots \\ \theta_b \gamma_m \end{bmatrix} = \begin{bmatrix} (\hat{\theta}_b + \varepsilon_b) \gamma_2 \\ \vdots \\ (\hat{\theta}_b + \varepsilon_b) \gamma_m \end{bmatrix} = \begin{bmatrix} \hat{\theta}_b \gamma_2 + \varepsilon_b \gamma_2 \\ \vdots \\ \hat{\theta}_b \gamma_m + \varepsilon_b \gamma_m \end{bmatrix} \quad (3.44)$$

e, por outro lado, tem-se que

$$\theta_{b\gamma} = \hat{\theta}_{b\gamma} + \varepsilon_{b\gamma} \quad (3.45)$$

Como ε_b e $\varepsilon_{b\gamma}$ são do tipo ruído branco, então, o estimador dos mínimos quadrados de θ_γ é dado por

$$\hat{\theta}_\gamma = \begin{bmatrix} \gamma_2 \\ \vdots \\ \gamma_m \end{bmatrix} = \begin{bmatrix} \hat{\theta}_b^+ & 0 & \cdots & 0 \\ \vdots & & & \vdots \\ 0 & \cdots & 0 & \hat{\theta}_b^+ \end{bmatrix} \hat{\theta}_{b\gamma} = M \hat{\theta}_{b\gamma} \quad (3.46)$$

Visto que θ_γ é um vetor coluna de posto completo e $\theta_b^+ \theta_b = 1$, pode-se verificar que (3.39) é também um estimador consistente e, portanto,

$$\Xi(\hat{\theta}_s) = \theta_s$$

onde Ξ é a esperança matemática. □

3.4.5 Método de Bai

Este método propõe a identificação de não-linearidades com estrutura conhecida. As não-linearidades são parametrizadas por uma única variável (a) identificada a partir da aplicação da estratégia dos mínimos quadrados separáveis (Bai, 2002).

Para a formalização deste método é adotada uma não-linearidade do tipo saturação (Figura 3.9), embora os resultados possam ser estendidos para os demais tipos de não-linearidade (zona-morta, histerese, relé, etc.).




Figura 3.9 – Não-Linearidade Tipo Saturação.

A saída do sistema pode ser representada por

$$y(t) = [-y(t-1) \dots -y(t-na) \ x(t-d) \dots x(t-d-nb)]\theta + \varepsilon(t) \quad (3.47)$$

onde $\theta = [a_1 \ a_2 \ \dots \ a_{na}; \ b_0 \ b_1 \ \dots \ b_{nb}]$ corresponde aos parâmetros da parcela linear e a pseudo-saída não mensurável, $x(t)$, pode ser representada como função da entrada e do parâmetro a na forma $x(t) = \mathcal{N}[u(t), a]$ cuja estimativa é

$$\hat{x}(t) = \mathcal{N}[u(t), \hat{a}] \quad (3.48)$$

O erro de estimação é, portanto,

$$e_{\hat{\theta}, \hat{a}}(t) = [-y(t-1) \dots -y(t-na) \ \hat{x}(t-d) \dots \hat{x}(t-d-nb)]\hat{\theta} \quad (3.49)$$

e a função custo a ser minimizada

$$J = \frac{1}{N} \sum_{t=1}^N e_{\hat{\theta}, \hat{a}}^2(t) \quad (3.50)$$

onde $Y = [y(1) \ y(2) \ \dots \ y(N)]^T$

$$\Phi(\hat{a}) = \begin{bmatrix} y(0) & \cdots & y(1-na) & \hat{x}(0) & \cdots & \hat{x}(1-nb) \\ y(1) & \cdots & y(2-na) & \hat{x}(1) & \cdots & \hat{x}(2-nb) \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ y(N-1) & \cdots & y(N-na) & \hat{x}(N-1) & \cdots & \hat{x}(N-nb) \end{bmatrix} \quad (3.51)$$

A função custo pode ser reescrita como

$$J = \frac{1}{N} \|Y - \Phi(\hat{a})\hat{\theta}\|^2 \quad (3.52)$$

a qual minimizada em relação a $\hat{\theta}$ resulta

$$\frac{\partial J}{\partial \hat{\theta}} = -2\Phi^T(\hat{a})Y + 2\Phi^T(\hat{a})\Phi(\hat{a})\hat{\theta} \quad (3.53)$$

Se a parcela $[\Phi^T(\hat{a})\Phi(\hat{a})]$ é inversível, a condição necessária e suficiente para $\hat{\theta}$ ser ótimo é que

$$\hat{\theta} = [\Phi^T(\hat{a})\Phi(\hat{a})]^{-1} \Phi^T(\hat{a})Y \quad (3.54)$$

Portanto, substituindo o valor ótimo de $\hat{\theta}$ da equação (3.54) na função custo da equação (3.52) tem-se a eliminação do termo $\hat{\theta}$ e a função objetivo

$$J(\hat{a}) = \frac{1}{N} \left\| \left\{ I - \Phi(\hat{a})[\Phi^T(\hat{a})\Phi(\hat{a})]^{-1} \Phi^T(\hat{a}) \right\} Y \right\|^2 \quad (3.55)$$

cuja minimização torna-se um problema cujo espaço de busca é reduzido de $(na + nb + 1)$ para 1 (um).

Uma vez obtido o valor de \hat{a} ótimo, empregando qualquer método clássico de minimização unidimensional, é possível determinar os parâmetros da parcela linear $\hat{\theta}$ ótimos, equação (3.54).

Algoritmo de Bai para NL de Estrutura Conhecida

1. Realiza a medição dos dados $[u(t) \ y(t)]$;
2. Define $Y = [y(1) \ \dots \ y(N)]^T$ e $\Phi(\hat{a})$;
3. Minimiza $J(\hat{a})$, obtendo o \hat{a} ótimo;
4. Calcula o $\hat{\theta}$ ótimo.

Esta redução da dimensão de busca pode ser conseguida para qualquer tipo de não-linearidade para a qual seja possível a parametrização por uma única variável.

3.5 VALIDAÇÃO DO MODELO

O objetivo desta etapa do processo de identificação é verificar se os modelos obtidos são válidos e qual deles é o mais adequado à aplicação particular. Uma das formas mais comuns de verificar a validade do modelo é comparar se este é capaz de reproduzir o comportamento do sistema. Para a realização deste teste é importante a utilização de um conjunto de dados diferente daquele empregado na etapa de estimação. Este segundo conjunto de dados, embora diferente, deve ser obtido segundo as mesmas condições de operação do primeiro. Esta prática, embora simples, permite observar a capacidade de generalização do modelo obtido (Ljung, 1999).

► Análise de Resíduos

Uma forma de avaliar se um modelo é adequado é pela análise do erro de estimação cujo comportamento desejável é do tipo ruído branco. Considerando que o resíduo representa a parcela dos dados não explicada pelo modelo. Se este é um ruído branco significa que não há nenhuma informação útil adicional nos dados além daquela já descrita pelo modelo estimado. Este comportamento pode ser verificado pela análise da **função de autocorrelação normalizada** que deve apresentar seu primeiro elemento unitário enquanto que os demais devem distribuir-se aleatoriamente em relação ao zero num intervalo de confiança de 95% para que o resíduo possa ser admitido como ruído branco, Figura 3.10 (Ljung, 1999; Aguirre, 2000).

$$r_{ee}(\tau) = \frac{1}{N} \sum_{t=1}^N e(t)e(t+\tau) \quad (3.56)$$

$$-\frac{1.96}{\sqrt{N}} < r_{ee}(\tau) < \frac{1.96}{\sqrt{N}}, \forall \tau \neq 0 \quad (3.57)$$




Figura 3.10 – Função de Autocorrelação de um Resíduo Ruído Branco.

Esta técnica é eficiente para indicar a escolha da ordem do modelo reduzida em relação ao processo real (sub-modelagem) ou erros na etapa de estimação, mas não fornece qualquer informação que indique a ocorrência de sobre-modelagem.

Para avaliar a capacidade do modelo em reproduzir o comportamento dinâmico do processo é importante a utilização de índices de desempenho que auxiliem nesta etapa.

► **Somatório do Erro Quadrático – SSE (Sum of Squared Error)**

$$SSE = \sum_{t=1}^N [y(t) - \hat{y}(t)]^2 \quad (3.58)$$

Este índice representa a soma dos quadrados do erro de estimação e, quanto menor é o seu valor, melhor a qualidade do modelo.

► Coeficiente de Correlação Múltipla – R^2

$$R^2 = 1 - \frac{\sum_{t=1}^N [y(t) - \hat{y}(t)]^2}{\sum_{t=1}^N [y(t) - \bar{y}(t)]^2} \quad (3.59)$$

onde \bar{y} é a média das N amostras medidas para a saída do processo.

Quando o valor de R^2 é igual à unidade (1) indica uma exata adequação do modelo para os dados medidos do processo. Um valor de R^2 entre 0.9 e 1 é considerado suficiente para aplicações práticas, em sistemas de controle (Coelho e Coelho, 2004).

Embora forneçam uma indicação importante em relação à qualidade do modelo obtido estes índices de desempenho não levam em consideração a complexidade (número de parâmetros) do modelo. A seleção do modelo mais adequado deve sempre levar em conta a relação entre capacidade de representação e simplicidade estabelecendo um compromisso entre precisão do modelo x esforço computacional, por exemplo, por meio do critério de informação de Akaike (Ljung e Glad, 1994).

► Princípio da Parcimônia

Critérios de Informação podem ser avaliados para manter a ordem do modelo estimado para o processo tão simples quanto possível. Critérios como de informação Bayesiana e de Akaike, combinam a variância residual do erro de estimação e a ordem do modelo (Coelho e Coelho, 2004).

Inicialmente, um modelo de baixa ordem é selecionado, então aumenta-se a ordem do modelo estimado e o critério é avaliado para cada incremento na ordem do modelo. Assim, a estrutura adequada do modelo estimado é a que proporciona a menor taxa de variação do critério de informação. Diversos critérios de informação podem ser utilizados na complementação da função custo básica dos mínimos quadrados, isto é,

$$J_N = \frac{1}{N} \sum_{t=1}^N [y(t) - \hat{y}(t)]^2 \quad (3.60)$$

com alguns termos extras que penalizam a complexidade do modelo matemático da planta e podem ser selecionados de acordo com um dos seguintes testes:

Crítério de Informação de Akaike (*Akaike Information Criterion*)

$$AIC = N \ln[J_N] + 2p \quad (3.61)$$

onde N é o número de medidas e p é o número de parâmetros do modelo estimado;

Crítério de Informação Bayesiana (*Bayesian Information Criterion*)

$$BIC = N \ln[J_N] + p \ln[N] \quad (3.62)$$

► **Erro de Predição**

O uso de predições k passos à frente é visto como uma forma mais eficiente de validar um modelo obtido visto que como a maioria dos algoritmos de identificação minimiza o erro de predição 1 (um) passo a frente é normal que estes modelos apresentem um bom desempenho nestas condições. Uma forma de avaliar a qualidade do modelo é a análise do índice RMSE (*root mean square error*), equação (3.63)

$$RMSE(i) = \frac{\sqrt{\sum_{t=1}^N [y(t) - \hat{y}(t)]^2}}{\sqrt{\sum_{t=1}^N [y(t) - y(t-i)]^2}} \quad (3.63)$$

onde i representa o horizonte de predição empregado. Na comparação entre modelos distintos o menor $RMSE$ denota um melhor desempenho do modelo (Aguirre, 2000).

3.6 CONCLUSÃO

Neste capítulo foi discutida a identificação de sistemas não-lineares que possam ser representados pelo modelo de Hammerstein. Técnicas de seleção do modelo e escolha de estrutura foram apresentadas com o objetivo de auxiliar na solução do compromisso entre a complexidade do modelo e a capacidade de representação do processo. Diversas técnicas

de estimação dos parâmetros do modelo de Hammerstein foram apresentadas bem como estratégias de validação dos modelos obtidos. Exemplos foram apresentados para auxiliar na compreensão das características dos modelos não-lineares estudados.

As principais contribuições deste capítulo são a aplicação da Razão entre Determinantes (*DR*) para o modelo de Hammerstein bem como a aplicação do algoritmo dos mínimos quadrados (*MQ*) sob restrições visando resolver o problema de redundância dos parâmetros de estimação observado.

A aplicação dos modelos apresentados em técnicas de controle preditivo é desenvolvida no capítulo 4, enquanto que, resultados experimentais das técnicas de identificação são ilustrados no capítulo 5.

4. CONTROLE PREDITIVO BASEADO NO MODELO DE HAMMERSTEIN

4.1 INTRODUÇÃO

O controle preditivo baseado em modelo (*MPC – Model Predictive Control*) surge atualmente como uma das mais populares e eficientes estratégias de controle na indústria de processos. Muitos dos aspectos fundamentais num projeto de controle industrial prático podem ser explorados no controle preditivo baseado em modelo, como a trajetória de referência futura, predição de perturbações e a possibilidade de inclusão de restrições, verificando-se, assim, a flexibilidade desta técnica de controle (Ogunnaike e Ray, 1994; Zambrano e Camacho, 2002).

Embora idealizado inicialmente para aplicações em sistemas de potência e na indústria petroquímica, atualmente, o controle preditivo é empregado nas mais diversas áreas não somente da indústria (regulação de tensão, controle de temperatura, pressão, nível, etc.) mas, também em outras áreas do conhecimento humano como a medicina (anestesia, controle de pressão sangüínea, concentração de glicose no sangue) mostrando a evolução prática destas estratégias e comprovando que em breve devem substituir a maioria dos controladores clássicos utilizados que muitas vezes mostram-se ineficientes em ambientes complexos (Kwok e Shah, 1994; Santos, 1998; Rawlings, 2000; Schlotthauer *et al.*, 2005).

A estrutura básica do *MPC* é apresentada na Figura 4.1 onde os principais elementos envolvidos são:

Trajectoria de Referências - representa o comportamento do sinal desejado para a saída futura. É o conhecimento prévio desta trajetória que garante ao controlador uma característica antecipativa.

Modelo - deve ser capaz de representar o seu comportamento dinâmico de forma suficientemente precisa. Conforme a necessidade este modelo pode ser linear ou não-linear

e podendo, ainda, ser atualizado através de métodos de identificação *on line* conferindo ao controlador uma característica adaptativa.

Preditor - fornece através do modelo matemático uma predição da saída futura com base na informação atual da planta.

Otimizador - minimiza a função custo a cada período de amostragem de forma a obter uma ação de controle que garanta um desempenho adequado ao sistema. A função a ser minimizada pode contemplar, além de parcelas associadas ao erro futuro e ao incremento no sinal de controle, outros termos que forneçam ao controlador propriedades que melhorem o seu desempenho frente às particularidades do processo. Quando da utilização de uma função custo quadrática, modelos lineares e na ausência de restrições o problema de otimização apresenta uma solução analítica, caso contrário, algum método de otimização numérica deve ser empregado.

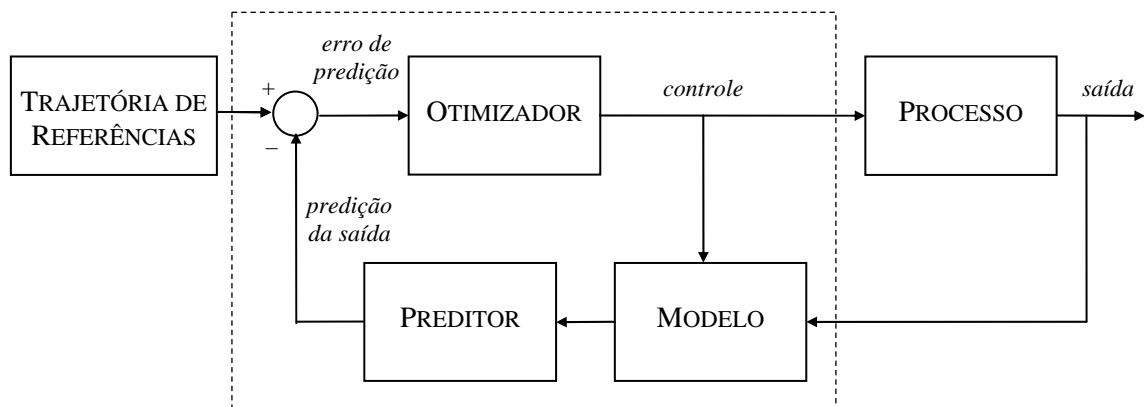


Figura 4.1 – Estrutura de um Controlador Preditivo.

O *MPC* baseia-se na predição do comportamento futuro do processo para o cálculo do sinal de controle. As predições são feitas através de um modelo matemático do processo sobre um intervalo de tempo denominado **horizonte de predição** cujo conceito é ilustrado na Figura 4.2.




Figura 4.2 – Horíontes de Predição.

O horizonte de predição final (N_2) representa o intervalo futuro onde está sendo considerado o comportamento da saída da planta, esta é calculada a cada instante de tempo utilizando o modelo do processo e a informação atual em relação às entradas e saídas do sistema. O horizonte de controle (N_u) corresponde ao número de ações de controle consideradas e, a partir das quais, a entrada do sistema é considerada constante. As ações de controle futuras são calculadas mediante a otimização de uma função objetivo de forma a levar a saída da planta ao encontro de uma trajetória de referência pré-estabelecida. Na escolha da função objetivo podem-se adotar, ainda, outros critérios como o esforço de controle. Após a aplicação da ação de controle calculada para o instante atual ($u(t)$), com base nas novas informações obtidas, o procedimento é repetido e, assim, sucessivamente, a cada instante de amostragem (Camacho e Bordons, 2004).

4.2 CONTROLE PREDITIVO BASEADO EM MODELOS LINEARES

A utilização de modelos lineares numa aplicação de controle preditivo é bastante comum pois, além da popularidade deste tipo de modelo, muitas vezes, torna-se necessário o emprego de um modelo simplificado para possibilitar que todos os cálculos envolvidos sejam realizados dentro do intervalo correspondente a um período de amostragem viabilizando, assim, o controle em tempo-real. Um modelo linear possibilita, também, uma solução analítica para o problema de minimização da função custo quando não são consideradas restrições. A opção por um modelo linear para a representação da planta deve

ser a escolha preferencial sempre que este possibilite que o controlador alcance o desempenho almejado pelo usuário (Camacho e Bordons, 2004).

Nos últimos anos houve um grande crescimento nas aplicações industriais de controle preditivo baseado em modelos lineares. A Tabela 4.1 apresenta algumas destas aplicações presentes no trabalho de Qin e Badgwell (2000; 2003).

Tabela 4.1 – Aplicações Comerciais de *MPC*.

Área	Adersa	Aspen Technology	Honeywell Hi-Spec	Invensys	SGS	Total
refinaria	1200	480	280	25	–	1985
petroquímica	450	80	–	20	–	550
química	100	20	03	21	–	144
papel	18	50	–	–	–	68
ar e gás	–	10	–	–	–	10
utilidades	–	10	–	04	–	14
metalurgia	08	06	07	16	–	37
alimentos	–	–	41	10	–	51
polímeros	17	–	–	–	–	17
fornos	–	–	42	03	–	45
aeroespacial	–	–	13	–	–	13
automotiva	–	–	07	–	–	07
outras	40	40	1045	26	450	1601
Total	1833	696	1438	125	450	4542

Este estudo vem a confirmar a indústria química e a do petróleo como principais áreas de aplicação das estratégias de controle preditivo baseado em modelo linear (*MPC*).

4.2.1 Controle por Matriz Dinâmica (*DMC*)

O controlador *DMC* (*Dynamic Matrix Control*) desenvolvido por C. R. Cutler e B. L. Ramaker foi um dos primeiros controladores preditivos baseados em modelo a apresentar disponibilidade comercial. O *DMC* para um sistema *SISO* é baseado no modelo não-paramétrico da resposta ao degrau e utiliza como função custo

$$J_{DMC} = \sum_{j=N_1}^{N_2} [\hat{y}(t+j) - y_r(t+j)]^2 + \sum_{j=1}^{N_u} \Lambda \Delta u^2(t+j-1) \quad (4.1)$$

onde considera-se $\Delta u(t+j) = 0$ para $j \geq N_u$, $y_r(t)$ é a referência, Λ é um fator de ponderação aplicado sobre o incremento no esforço de controle e $\hat{y}(t+j)$ representa as previsões da saída nos instantes de tempo $(t+j)$.

A otimização da equação (4.1) fornece N_u valores para o sinal de controle, mas somente $\Delta u(t)$ é aplicado. No período de amostragem seguinte a solução é calculada novamente e outro conjunto de N_u valores de controle é obtido (*receding horizon strategy*).

Características do controle *DMC*:

- O número de termos do modelo da resposta ao degrau (N) deve ser suficientemente grande, tal que $NT_s \geq t_s$, onde t_s (*settling time*) é o tempo de estabilização do processo;
- O processo deve ser estável em malha aberta;
- O erro de previsão deve poder ser modelado como uma perturbação do tipo degrau atuando na saída do processo.

Os parâmetros de sintonia do *DMC* permitem uma maior flexibilidade de projeto para o sistema controlado. No entanto, algumas peculiaridades devem ser levadas em conta na sua seleção (Prada *et al.*, 1994; Pike *et al.*, 1996; Brosilow e Joseph, 2002; Qin e Badgwell, 2003; Camacho e Bordons, 2004; Zou *et al.*, 2006):

Horizonte de Predição Inicial (N_1) - Normalmente é selecionado como 1 (um), mas nos casos onde o atraso de transporte é perfeitamente conhecido, pode ser ajustado com $N_1 \leq d$ fazendo com que o esforço computacional seja reduzido.

Horizonte de Predição Final (N_2) - Geralmente, é tal que este seja maior do que o tempo de subida porém não superior ao tempo de estabilização (t_s) do processo. Para a maioria dos processos estáveis em malha aberta, a dinâmica de malha fechada torna-se mais rápida com a diminuição de N_2 . O aumento de N_2 provoca um aumento da robustez do sistema quanto à presença de dinâmicas não-modeladas aumentando, porém, o esforço computacional.

Horizonte de Controle (N_u) - Valores elevados de N_u , além de aumentar o esforço computacional, aumenta a agressividade da ação de controle. Para sistemas estáveis em

malha aberta, $N_u = 1$ mostra-se, geralmente, adequado. Na prática o valor de N_u deve ser o menor possível que permita um desempenho satisfatório do sistema.

Ponderação do Controle (Λ) - A introdução desta ponderação faz com que a magnitude do sinal de controle seja levada em conta na função custo a ser minimizada. Isto provoca uma diminuição dos níveis do sinal de controle podendo causar, também, aumento na sobre-elevação da saída do sistema. A ponderação Λ com um valor diferente de zero melhora o condicionamento da matriz obtida no desenvolvimento da lei de controle, possibilitando sua inversão, além de aumentar a robustez do sistema quando sujeito a incertezas de modelagem (Banerjee e Shah, 1995).

4.2.2 Controle Preditivo Generalizado (GPC)

Com o objetivo de suprir algumas deficiências dos controladores *GMV* (*Generalized Minimum Variance*) que falham no controle de alguns processos de fase não-mínima ou quando o atraso de transporte não é perfeitamente conhecido, D. W. Clarke, C. Mohtadi e P. S. Tuffs (Clarke e Gawthrop, 1975; Clarke *et al.*, 1987a) desenvolveram uma nova estratégia de controle denominada de *GPC* (*Generalized Predictive Control*).

O controlador *GPC* utiliza um modelo paramétrico do tipo *CARIMA* e a lei de controle é obtida pela minimização do critério da equação (4.1)

Os horizontes de predição e a ponderação do controle são os principais parâmetros de sintonia do *GPC*. A partir da seleção destes parâmetros é possível obter-se diferentes tipos de controladores preditivos e ajustar o desempenho desejado para o sistema controlado (Clarke *et al.*, 1987a; De Keyser *et al.*, 1988; Bitmead *et al.*, 1991).

A utilização do *GPC* possibilita tratar processos que possuam atrasos de transporte desconhecidos ou variantes, sistemas sob restrições, não-linearidades, sistemas de fase não-mínima, bem como plantas instáveis em malha aberta. Assim como o *DMC*, na prática, somente o primeiro sinal de controle é aplicado e, a cada iteração, um novo problema de minimização é resolvido. (Clarke *et al.*, 1987b).

O controlador preditivo generalizado enquadra-se na estrutura *RST* conforme ilustra a Figura 4.3.

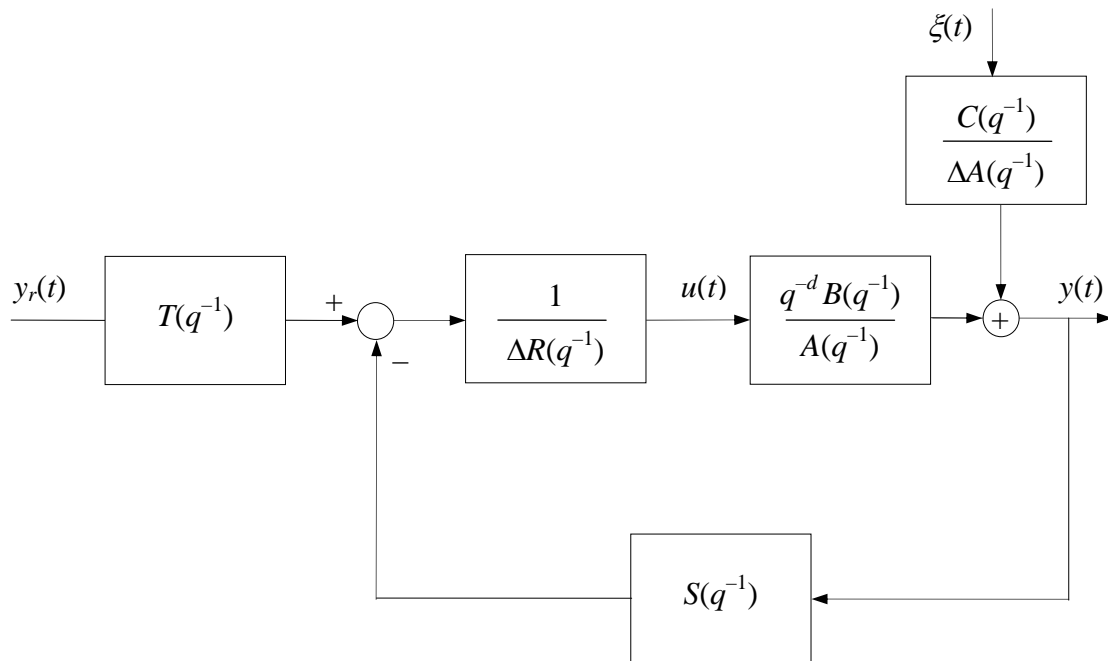


Figura 4.3 – Estrutura *RST* do Controlador *GPC*.

A lei de controle, que satisfaz a Figura 4.3, pode ser representada como

$$R(q^{-1})\Delta u(t) = T(q^{-1})y_r(t + N_2) - S(q^{-1})y(t) \quad (4.2)$$

A sintonia do controlador *GPC* pode ser feita com base nas propriedades já apresentadas aos parâmetros do controlador *DMC* podendo-se destacar, ainda, as seguintes características:

- É capaz de lidar com processos que possuam atrasos de transporte desconhecidos ou variantes, não-linearidades, sistemas de fase não-mínima, bem como plantas instáveis em malha aberta;
- Para processos instáveis em malha aberta a seleção de um N_2 elevado pode levar o sistema em malha fechada à instabilidade pois os pólos do sistema em malha fechada tendem aos de malha aberta quando $N_2 \rightarrow \infty$;
- Na presença de restrições o problema de minimização tem que ser resolvido numericamente.

4.2.3 Abordagem Mean Level Control (MLC)

Uma lei de controle preditivo generalizada simplificada pode ser obtida através do adequado manuseio dos parâmetros de projeto visando a aplicativos em tempo-real e em processos não-lineares.

Um controlador de modelo inverso em regime permanente ou controlador *Mean Level* fornece um simples degrau como ação de controle para uma variação do tipo degrau para a referência, o que leva o processo exatamente para a nova referência em regime permanente, Figura 4.4 (Clarke, 1991; Rossiter, 1994; Dormido *et al.*, 2003).

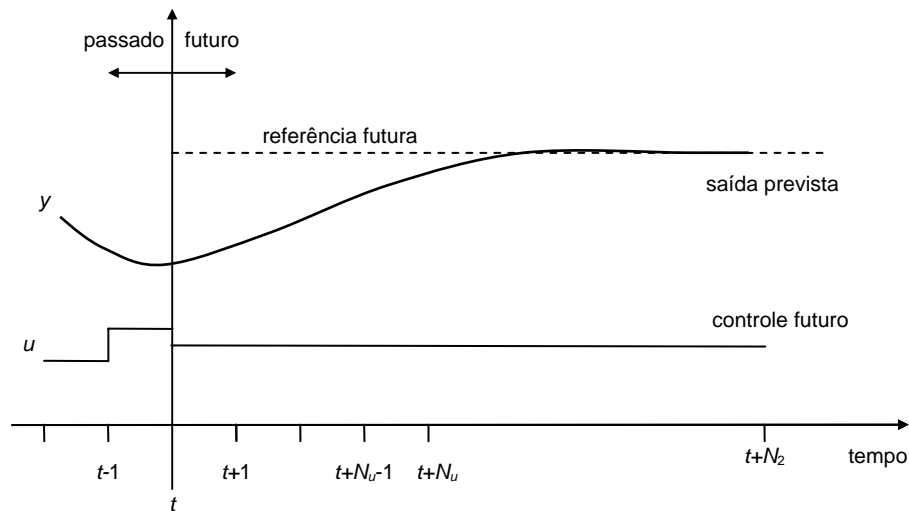


Figura 4.4 – Abordagem *Mean Level Control*.

Utilizando a forma linear geral da lei de controle do *GPC* que tende ao controlador *MLC* quando $N_2 \rightarrow \infty$ se $N_1 = d = 1$, $N_u = 1$, $\Lambda = 0$ (McIntosh *et al.*, 1991), pode-se observar que o controlador *MLC* posiciona os pólos de malha fechada na mesma posição dos pólos de malha aberta de um processo estável.

Considerando $N_1 = d = 1$, $N_u = 1$, $\Lambda = 0$ a lei de controle do *GPC* torna-se

$$\Delta u(t) = [\mathbf{G}^T \mathbf{G}]^{-1} \mathbf{G}^T (\mathbf{Y}_r - \mathbf{f}) \quad (4.3)$$

onde

$$\mathbf{G} = [g_0 \quad g_1 \quad \cdots \quad g_{N_2-1}]^T \quad \text{e} \quad \mathbf{G}^T \mathbf{G} = \sum_{i=0}^{N_2-1} g_i^2$$

Para um horizonte de saída de N_2 os elementos da primeira linha de $[\mathbf{G}^T \mathbf{G}]^{-1} \mathbf{G}^T$ são:

$$m_j = \frac{g_{j-1}}{\sum_{i=0}^{N_2-1} g_i^2} \quad j = 1, \dots, N_2 \quad (4.4)$$

Considerando a forma geral para a lei de controle

$$R(q^{-1})\Delta u(t) = T(q^{-1})y_r(t) - S(q^{-1})y(t) \quad (4.5)$$

obtem-se

$$R(q^{-1}) = 1 + q^{-1} \left[\frac{\sum_{j=1}^{N_2} g_{j-1} \bar{G}_j(q^{-1})}{\sum_{i=0}^{N_2-1} g_i^2} \right], \quad S(q^{-1}) = \left[\frac{\sum_{j=1}^{N_2} g_{j-1} F_j(q^{-1})}{\sum_{i=0}^{N_2-1} g_i^2} \right] \quad \text{e} \quad T(q^{-1}) = \left[\frac{\sum_{j=1}^{N_2} g_{j-1}}{\sum_{i=0}^{N_2-1} g_i^2} \right]$$

Pode-se escrever um conjunto similar de equações para um horizonte de saída $N_2 + 1$ e, fazendo a diferença (para um N_2 de valor elevado), têm-se

$$R(q^{-1}) = \frac{1}{g_{N_2}} \left[g_{N_2} + q^{-1} \bar{G}_{N_2+1}(q^{-1}) \right], \quad S(q^{-1}) = \left[\frac{F_{N_2+1}(q^{-1})}{g_{N_2}} \right] \quad \text{e} \quad T(q^{-1}) = \left[\frac{1}{g_{N_2}} \right]$$

O polinômio característico para o sistema em malha fechada é

$$P_{mf}(q^{-1}) = R(q^{-1})A(q^{-1})\Delta + q^{-1}B(q^{-1})S(q^{-1}) \quad (4.6)$$

Substituindo $R(q^{-1})$ e $S(q^{-1})$ o polinômio característico torna-se

$$P_{mf}(q^{-1}) = \frac{g_{N_2}A(q^{-1})\Delta + q^{-1} \left[\bar{G}_{N_2+1}A(q^{-1})\Delta + B(q^{-1})F_{N_2+1} \right]}{g_{N_2}} \quad (4.7)$$

Considerando a identidade polinomial

$$1 = E_{N_2+1}(q^{-1})A(q^{-1})\Delta + q^{-(N_2+1)}F_{N_2+1}(q^{-1}) \quad (4.8)$$

e que

$$E_j(q^{-1})B(q^{-1}) = G_j(q^{-1})C(q^{-1}) + q^{-j}\bar{G}_j(q^{-1}) \quad (4.9)$$

obtem-se pela manipulação das equações (4.8) e (4.9)

$$B(q^{-1}) = G_{N_2+1}(q^{-1})A(q^{-1})\Delta + q^{-(N_2+1)}\left[\bar{G}_{N_2+1}(q^{-1})A(q^{-1})\Delta + B(q^{-1})F_{N_2+1}(q^{-1})\right] \quad (4.10)$$

De maneira que reescrevendo a equação (4.7) obtém-se

$$P_{mf}(q^{-1}) = \frac{A(q^{-1})\Delta \left\{ g_{N_2} + q^{N_2} \left[B(q^{-1})/A(q^{-1})\Delta - G_{N_2+1} \right] \right\}}{g_{N_2}} \quad (4.11)$$

Visto que os coeficientes de $B/A\Delta$ e de

$$G_{N_2-1}(q^{-1}) = g_0 + g_1q^{-1} + \dots + g_{N_2}q^{-N_2} \quad (4.12)$$

são coeficientes de resposta ao degrau, o polinômio característico pode ser reescrito na forma

$$P_{mf}(q^{-1}) = \frac{A(q^{-1})\Delta \left[g_{N_2} + g_{N_2+1}q^{-1} + \dots \right]}{g_{N_2}} \quad (4.13)$$

Levando ao limite quando $N_2 \rightarrow \infty$ para um processo estável em malha aberta

$$P_{mf}(q^{-1}) = \lim_{N_2 \rightarrow \infty} \left\{ \frac{A(q^{-1})}{g_{N_2}} \left[g_{N_2} + (g_{N_2+1} - g_{N_2})q^{-1} + (g_{N_2+2} - g_{N_2+1})q^{-2} + \dots \right] \right\} = A(q^{-1}) \quad (4.14)$$

verifica-se que, para um controlador *MLC* atuando sobre um processo estável, os pólos de malha fechada permanecem nas mesmas posições dos pólos de malha aberta. Alguns trabalhos apontam para a sua aplicação também a processos instáveis (Rossiter, 1994; 1996; Dormido *et al.*, 2003).

4.2.4 Comparação entre Estratégias *MPC*

O controlador *GPC* pode ser visto como uma generalização de outras estratégias *MPC* estudadas, destacam-se as seguintes estratégias: *MAC* (*Model Algorithmic Control*), desenvolvido por J. Richalet *et al.* em 1976, *DMC* (*Dynamic Matrix Control*) apresentado por C. R. Cutler e B. C. Ramaker em 1980, *EPSAC* (*Extended Prediction Self-Adaptive Control*) proposto por R. M. C. De Keyser em 1982 e *EHAC* (*Extended Horizon Adaptive Control*) de B. Ydstie, derivado em 1984 (De Keyser *et al.*, 1988; Pike *et al.*, 1996). A comparação de suas funções custo e principais características são apresentadas na Tabela 4.2.

Tabela 4.2 – Comparação entre Estratégias *MPC*.

Controlador	Função Custo	Características
<i>MAC</i>	$\sum_{j=1}^{N_2} \left[(\hat{y}(t+j) - y_r(t+j))^2 + \Lambda^2 \Delta u^2(t+j-1) \right]$	<ul style="list-style-type: none"> • modelo: <i>FIR</i>; • incapaz de lidar com processos instáveis.
<i>DMC</i>	$\sum_{j=N_1}^{N_2} [\hat{y}(t+j) - y_r(t+j)]^2 + \sum_{j=1}^{N_u} \Lambda \Delta u^2(t+j-1)$	<ul style="list-style-type: none"> • modelo: <i>FSR</i>; • incapaz de lidar com processos instáveis.
<i>EPSAC</i>	$\sum_{j=1}^{N_2} \gamma \left[\hat{y}(t+j) - P(q^{-1})y_r(t+j) \right]^2$	<ul style="list-style-type: none"> • modelo: <i>CARIMA</i>; • trata processos instáveis; • função custo não penaliza o esforço de controle.
<i>EHAC</i>	$\sum_{j=1}^{N_2-N_1} [\Delta u(t+j-1)]^2$	<ul style="list-style-type: none"> • modelo: <i>CAR</i>; • possui um único parâmetro de sintonia.
<i>GPC</i>	$\sum_{j=N_1}^{N_2} [\hat{y}(t+j) - y_r(t+j)]^2 + \sum_{j=1}^{N_u} \Lambda \Delta u^2(t+j-1)$	<ul style="list-style-type: none"> • modelo: <i>CARIMA</i>; • trata processos instáveis; • trata atrasos variantes.

4.3 CONTROLE PREDITIVO BASEADO EM MODELOS NÃO-LINEARES

Quando o processo não-linear atua numa faixa de operação ampla ou a não-linearidade do processo é significativa o bastante para tornar o desempenho do controlador inadequado para atender os requisitos estabelecidos, a utilização de um modelo não-linear deve ser considerada (Rawlings, 2000).

Nos últimos anos houve um grande crescimento nas aplicações industriais do controle preditivo não-linear (*NMPC – Nonlinear Model Predictive Control*) que se apresenta como uma estratégia de controle promissora para diversas áreas da engenharia. A Tabela 4.3 ilustra algumas aplicações presentes em Qin e Badgwell (2000).

Tabela 4.3 – Aplicações Comerciais de *NMPC*.

Área	Adersa	Aspen Technology	Continental Controls	DOT Products	Pavilion Techno.	Total
ar e gás			18			18
química	02		15		05	22
alimentos					09	09
polímeros		01		05	15	21
papel					01	01
refinaria					13	13
utilidades		05	02			07
outras	01		01			02
Total	03	06	36	05	43	93

Os principais motivos deste crescimento são o fraco desempenho de controladores lineares em processos altamente não-lineares ou em plantas que trabalham numa ampla faixa de operação, a evolução de estratégias de controle baseadas em modelos não-lineares e o desenvolvimento de processadores poderosos o bastante para tornar possíveis estas implementações.

Dentre as aplicações de controle preditivo em plantas não-lineares, o emprego de controladores preditivos baseados no modelo de Hammerstein tem motivado uma série de aplicações bem sucedidas ao longo dos últimos anos (Bars e Haber, 1991; Katende e Jutan, 1996; Fruzzetti *et al.*, 1997; Chiras, 2002; Jurado, 2006; Pérez *et al.*, 2006; Zou *et al.*, 2006). Isto se deve ao fato que este modelo é capaz de representar adequadamente uma ampla faixa de não-linearidades apresentando, porém, propriedades que simplificam o projeto do controlador preditivo não-linear possibilitando, inclusive, uma solução analítica para o problema de minimização da função custo (caso sem restrições).

4.3.1 Controlador Preditivo de Bars e Haber

Consiste de um controlador preditivo do tipo *GMV* (Bars e Haber, 1991) cuja função custo é dada por

$$J_B = [y(t+d) - y_r(t+d)] + \Lambda \Delta u^2(t) \quad (4.15)$$

onde d é o atraso de transporte discreto, y_r é a referência e Λ é a ponderação do incremento do sinal de controle.

Assim, substituindo a predição da saída representada por um modelo de Hammerstein na equação (4.15), o sinal de controle obtido pela minimização irrestrita da função custo, pode ser determinado como a solução da seguinte equação

$$k_{2m-1}u^{2m-1}(t) + \dots + k_2u^2(t) + k_1u(t) + k_0 = 0 \quad (4.16)$$

onde os coeficientes k_i ($i = 0, \dots, 2m-1$) são calculados de acordo com o modelo de Hammerstein utilizado para representar o processo.

Como exemplo, seja o caso específico onde um processo de segunda ordem do tipo Hammerstein com $na = 2$, $nb = 1$ e $m = 2$, é representado pela seguinte equação a diferenças:

$$y(t) = -a_1y(t-1) - a_2y(t-2) + b_0\gamma_1u(t-1) + b_0\gamma_2u^2(t-1) + b_1\gamma_1u(t-2) + b_1\gamma_2u^2(t-2) \quad (4.17)$$

A minimização irrestrita da função custo, equação (4.15), na forma

$$\frac{\partial J_B}{\partial u(t)} = 0 \quad (4.18)$$

leva ao seguinte polinômio:

$$k_3u^3(t) + k_2u^2(t) + k_1u(t) + k_0 = 0 \quad (4.19)$$

onde $k_3 = 3b_0^2\gamma_2^2$

$$\begin{aligned}
k_2 &= 3b_0^2\gamma_1\gamma_2 \\
k_1 &= b_0\gamma_2 \left[-a_1y(t) - a_2y(t-1) + b_1\gamma_1u(t-1) + b_1\gamma_2u^2(t-1) - y_r(t+1) \right] + b_0^2\gamma_1^2 + \Lambda \\
k_0 &= b_0\gamma_1 \left[-a_1y(t) - a_2y(t-1) + b_1\gamma_1u(t-1) + b_1\gamma_2u^2(t-1) - y_r(t+1) \right] - \Lambda u(t-1)
\end{aligned}$$

cuja solução gera três possíveis sinais de controle para serem aplicados ao processo. A multiplicidade de soluções implica na aplicação de alguma técnica para selecionar, dentre os sinais candidatos, aquele mais apropriado. O critério adotado por Bars e Haber (1991) é selecionar aquele sinal de controle que mais se aproxime do sinal aplicado no instante anterior, $u(t-1)$, de forma a minimizar as variações no esforço de controle preservando, assim, a vida útil dos atuadores.

O grau ímpar do polinômio representado pela equação (4.16) garante a existência de pelo menos uma raiz real e, portanto, um valor factível para implementação do sinal de controle.

4.3.2 Controlador Preditivo Baseado num Modelo Quase-Linear

Esta estratégia é baseada na proposta de Fontes, Maitelli e Salazar (2002a) que propõe o uso de um controlador preditivo baseado num modelo quase-linear aplicado a um processo bilinear. Considerando um sistema que pode ser representado por um modelo de Hammerstein na forma

$$y(t) = H(q^{-1}) \left[\gamma_1 + \gamma_2 u(t) + \dots + \gamma_m u(t)^{m-1} \right] u(t) \quad (4.20)$$

e após algumas manipulações torna-se

$$y(t) = y(t-1) + \bar{H}(q^{-1}, u) \Delta u(t) \quad (4.21)$$

onde

$$\bar{H}(q^{-1}, u) = H(q^{-1}) \left[\gamma_1 + \gamma_2 u(t) + \dots + \gamma_m u(t)^{m-1} \right]$$

$$\bar{H}(q^{-1}, u) = H(q^{-1}) \sum_{j=1}^m \gamma_j u(t)^{j-1}$$

$$\bar{H}(q^{-1}, u) = \sum_{i=1}^N \sum_{j=1}^m h_i \gamma_j u(t)^{j-1}$$

Esta técnica de controle é formulada, empregando o modelo quase-linear da equação (4.21), a partir da função custo do *GPC*, equação (4.1), cuja otimização leva à minimização dos desvios futuros da saída em relação aos seus valores desejados ao longo de um horizonte de predição definido pelo usuário (Fontes *et al.*, 2002a; 2002b).

Em relação ao exemplo da equação (4.17) o modelo quase-linear resulta em

$$H(q^{-1}) = \frac{b_0 q^{-1} + b_1 q^{-2}}{1 + a_1 q^{-1} + a_2 q^{-2}}$$

$$\bar{H}(q^{-1}, u) = H(q^{-1})[\gamma_1 + \gamma_2 u(t)]$$

O uso de um modelo quase-linear para um processo de Hammerstein leva a uma aproximação equivalente àquela proposta por Zhu e Seborg (1994) para possibilitar uma solução analítica para a lei de controle.

4.3.3 Controlador Preditivo de Katende e Jutan

Esta estratégia (Katende e Jutan, 1996) emprega um controlador preditivo generalizado não-linear (*NGPC – Nonlinear Generalized Predictive Controller*) cuja função custo é dada por

$$J_K = \sum_{i=N_1}^{N_2} [\Psi \hat{y}(t+i) - \Psi(1)y_r(t+i)]^2 + \Lambda \sum_{i=1}^{N_u} x'^2(t+i-1) \quad (4.22)$$

onde Ψ é um polinômio mônico de maneira que

$$\Psi(1) = \sum_{j=0}^{n_{\Psi}} \Psi_j$$

e x' é função da saída do controlador $x(t)$, na forma $x'(t) = B(q^{-1})x(t)$.

A função custo, equação (4.22), que penaliza $x'(t)$ ao invés do sinal de controle $u(t)$, é minimizada, sem restrições, na forma

$$\frac{\partial J_K}{\partial x'(t)} = 0 \quad (4.23)$$

O valor ótimo para $x'(t)$ é calculado e, a partir deste, determina-se o valor ótimo de $u(t)$ através da solução do polinômio

$$x(t) = \gamma_1 u(t) + \gamma_2 u^2(t) + \dots + \gamma_m u^m(t) = \sum_{i=1}^m \gamma_i u^i(t) \quad (4.24)$$

ou diretamente de

$$x'(t) = B(q^{-1}) \sum_{i=1}^m \gamma_i u^i(t) \quad (4.25)$$

que pode ser reescrita na forma

$$\phi = \sum_{i=1}^m b_0 \gamma_i u_o^i + \sum_{i=1}^m \sum_{j=1}^{nb} b_j \gamma_i u^i(t-j) - x'(t) = 0 \quad (4.26)$$

separando o controle ótimo, $u_o = u(t)$, a ser calculado e as entradas passadas.

O gradiente da função (4.26) em relação a u_o é dado por

$$\phi' = \frac{\partial \phi}{\partial u_o} = \sum_{i=1}^m b_0 \gamma_i \frac{\partial u_o^i}{\partial u_o} \quad (4.27)$$

e o sinal de controle ótimo pode ser determinado, iterativamente, pelo método de Newton, através da equação

$$u_o(k+1) = u_o(k) - \frac{\phi}{\phi'} \quad (4.28)$$

Os valores encontrados para o controle ótimo podem apresentar multiplicidade, devendo ser descartados aqueles inadmissíveis como complexos ou que violem as restrições operacionais do processo.

4.3.4 Controlador Preditivo de Fruzzetti

Este controlador é baseado na estratégia *NMPC* (Fruzzetti *et al.*, 1997) cuja estrutura é ilustrada na Figura 4.5.

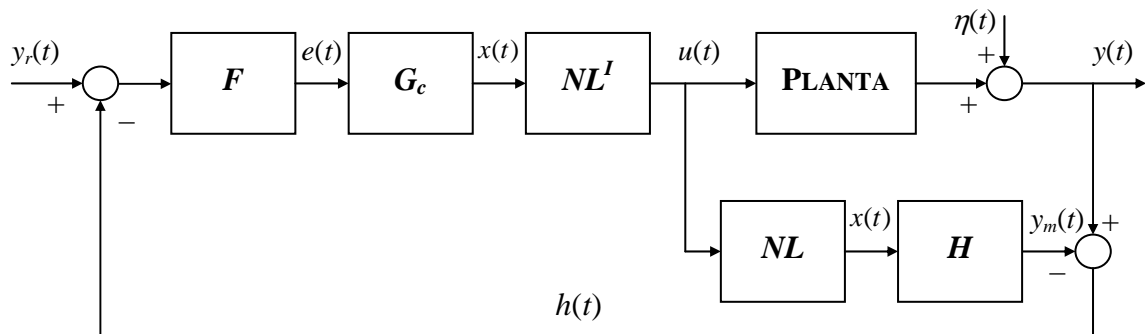


Figura 4.5 – Estrutura do Controlador de Fruzzetti.

onde F representa um filtro linear, G_c é o controlador *MPC* linear, NL é o elemento estático não-linear, NL^I é a inversa da não-linearidade NL (suas raízes), x é a saída do controlador, y_m é a saída do modelo e h é uma variável auxiliar de forma que $h = y - y_m$.

A função custo a ser minimizada é

$$J_F = \sum_{i=N_1}^{N_2} \Psi e^2(t+i) + \sum_{i=1}^{N_u} \Lambda \Delta x^2(t+i-1) \quad (4.29)$$

onde $e(t)$ é o erro, $e(t) = \hat{y}(t) - y_r(t)$; Ψ e Λ são as ponderações de $e(t)$ e $\Delta x(t)$, respectivamente.

Como a não-linearidade do sistema é representada por uma expansão polinomial finita, a inversa da não-linearidade pode ser descrita utilizando suas raízes. O projeto de controlador preditivo é linear gerando $x(t)$ que, a partir de NL^I , gera o sinal de controle a ser aplicado na planta, $u(t)$. O sinal de controle deve ser selecionado dentre as raízes válidas (valores reais que atendam às restrições) do polinômio de NL , equação (4.24), sendo recomendável que este tenha grau ímpar para garantir pelo menos uma solução real.

4.3.5 GPC com Perturbações Mensuráveis para o Modelo de Hammerstein (HGPC)

Desenvolvido como uma das contribuições desta tese, o controlador *HGPC* para um processo não-linear na presença de perturbações mensuráveis utiliza um modelo de Hammerstein cuja parcela linear é representada por um modelo *CARIMA*, equação (4.30), e cuja não-linearidade é representada pelo polinômio, equação (4.31)

$$A(q^{-1})\Delta y(t) = q^{-d}B(q^{-1})\Delta x(t) + C(q^{-1})\xi(t) + D(q^{-1})v(t) \quad (4.30)$$

$$x(t) = \gamma_1 u(t) + \gamma_2 u^2(t) + \dots + \gamma_m u^m(t) \quad (4.31)$$

onde $y(t)$ é a saída do processo, $u(t)$ é a variável manipulada, $x(t)$ é a pseudo-saída da parcela não-linear, γ_i são os termos do polinômio que representa a não-linearidade estática, d é o atraso de transporte, $\xi(t)$ representa ruído na medição, perturbações não-mensuráveis e/ou erros de modelagem e $v(t)$ representa um sinal de perturbação mensurável.

A lei de controle *HGPC* é obtida pela minimização do seguinte critério:

$$J_{HGPC} = \sum_{j=N_1}^{N_2} [y(t+j) - y_r(t+j)]^2 + \sum_{j=1}^{N_u} \Lambda \Delta x^2(t+j-1) \quad (4.32)$$

onde Λ é a ponderação do sinal de controle, N_1 e N_2 são os horizontes de predição da saída inicial e final, respectivamente, e N_u é o horizonte de controle. Os termos $y(t+j)$ e $y_r(t+j)$ representam o sinal da saída e o sinal de referência j passos a frente e, $\Delta x(t+j-1)$ é o incremento do sinal da pseudo-saída x no instante $(t+j-1)$.

Os horizontes de predição e a ponderação do controle são os principais parâmetros de sintonia do *HGPC*. A partir da seleção destes parâmetros é possível obter-se diferentes tipos de controladores preditivos e ajustar o desempenho desejado para o sistema controlado (Clarke *et al.*, 1987; De Keyser *et al.*, 1988; Bitmead *et al.*, 1991).

Seja a identidade polinomial

$$C(q^{-1}) = A(q^{-1})\Delta E_j(q^{-1}) + q^{-j}F_j(q^{-1}) \quad (4.33)$$

onde os coeficientes dos polinômios são dados por

$$\begin{aligned}
E_j(q^{-1}) &= 1 + e_1 q^{-1} + \dots + e_{n_e} q^{-n_e} \\
F_j(q^{-1}) &= f_0 + f_1 q^{-1} + \dots + f_{n_f} q^{-n_f} \\
n_e &= j - 1; \quad n_f = \max(n_a, n_c - j)
\end{aligned}$$

e determinados pelo conhecimento do intervalo de predição j e dos polinômios $A(q^{-1})$ e $C(q^{-1})$.

Pela manipulação do modelo do sistema, equação(4.30), e a equação (4.33) chega-se a seguinte representação:

$$y(t+j) = \frac{F_j(q^{-1})}{C(q^{-1})} y(t) + \frac{G_j'(q^{-1})}{C(q^{-1})} \Delta x(t+j-d) + \frac{H_j'(q^{-1})}{C(q^{-1})} \Delta v(t+j) + E_j(q^{-1}) \xi(t+j) \quad (4.34)$$

onde
$$G_j'(q^{-1}) = E_j(q^{-1})B(q^{-1})$$

$$H_j'(q^{-1}) = E_j(q^{-1})D(q^{-1})$$

Como o ruído está descorrelacionado dos sinais mensuráveis no instante t tem-se que a predição da saída no instante $(t+j)$ é

$$\hat{y}(t+j) = \frac{F_j(q^{-1})}{C(q^{-1})} y(t) + \frac{G_j'(q^{-1})}{C(q^{-1})} \Delta x(t+j-d) + \frac{H_j'(q^{-1})}{C(q^{-1})} \Delta v(t+j) \quad (4.35)$$

Utilizando as identidades polinomiais

$$G_j'(q^{-1}) = C(q^{-1})G_j(q^{-1}) + q^{-j}\bar{G}_j(q^{-1}) \quad (4.36)$$

$$H_j'(q^{-1}) = C(q^{-1})H_j(q^{-1}) + q^{-j}\bar{H}_j(q^{-1}) \quad (4.37)$$

e substituindo na equação (4.34) obtém-se

$$\hat{y}(t+j) = \frac{F_j(q^{-1})}{C(q^{-1})} y(t) + \frac{\bar{G}_j(q^{-1})}{C(q^{-1})} \Delta x(t-d) + \frac{\bar{H}_j(q^{-1})}{C(q^{-1})} \Delta v(t) + G_j(q^{-1}) \Delta x(t+j-d) + H_j(q^{-1}) \Delta v(t+j) \quad (4.38)$$

A partir da equação (4.38) retira-se a predição da resposta livre do sistema (com base na informação disponível no instante t), isto é,

$$\hat{y}(t+j/t) = \frac{F_j(q^{-1})}{C(q^{-1})} y(t) + \frac{\bar{G}_j(q^{-1})}{C(q^{-1})} \Delta x(t-d) + \frac{\bar{H}_j(q^{-1})}{C(q^{-1})} \Delta v(t) \quad (4.39)$$

Seja o vetor \mathbf{f} formado a partir das predições da resposta livre, ou seja,

$$\mathbf{f} = [\hat{y}(t+N_1/t) \quad \hat{y}(t+N_1+1/t) \quad \dots \quad \hat{y}(t+N_2/t)]^T \quad (4.40)$$

$\Delta \mathbf{X}$ o vetor do da pseudo-saída futura

$$\Delta \mathbf{X} = [\Delta x(t) \quad \Delta x(t+1) \quad \dots \quad \Delta x(t+N_u-1)]^T \quad (4.41)$$

e $\Delta \mathbf{V}$ o vetor das perturbações mensuráveis futuras

$$\Delta \mathbf{V} = [\Delta v(t+1) \quad \Delta v(t+2) \quad \dots \quad \Delta v(t+N_u)]^T \quad (4.42)$$

A equação (4.35) pode ser representada na forma vetorial

$$\hat{\mathbf{Y}} = \mathbf{G} \Delta \mathbf{U} + \mathbf{H} \Delta \mathbf{V} + \mathbf{f} \quad (4.43)$$

onde

$$\hat{\mathbf{Y}} = [\hat{y}(t+N_1) \quad \hat{y}(t+N_1+1) \quad \dots \quad \hat{y}(t+N_2)]^T$$

$$\mathbf{G} = \begin{bmatrix} g_{N_1-d} & \cdots & g_0 & 0 & 0 & \cdots & 0 \\ g_{N_1-d+1} & \cdots & g_1 & g_0 & 0 & \cdots & 0 \\ \vdots & \ddots & & & \ddots & & \vdots \\ \vdots & & \ddots & & & & g_0 \\ \vdots & \cdots & & & & & \vdots \\ g_{N_2-d} & g_{N_2-d-1} & \cdots & & & & g_{N_2-N_u-d+1} \end{bmatrix}$$

$$\mathbf{H} = \begin{bmatrix} h_{N_1} & \cdots & h_0 & 0 & 0 & \cdots & 0 \\ h_{N_1+1} & \cdots & h_1 & h_0 & 0 & \cdots & 0 \\ \vdots & \ddots & & & \ddots & & \vdots \\ \vdots & & \ddots & & & & h_0 \\ \vdots & \cdots & & & & & \vdots \\ h_{N_2} & h_{N_2-1} & \cdots & & & & h_{N_2-N_u} \end{bmatrix}$$

A matriz \mathbf{G} tem dimensões $(N_2 - N_1 + 1) \times N_u$ pois leva em conta a suposição de que $\Delta x(t+j-1) = 0, \forall j > N_u$ penalizando o controle além deste horizonte e reduzindo, portanto, o esforço computacional do algoritmo de controle.

A função custo do *HGPC* pode ser representada na forma vetorial

$$J_{HGPC} = [\hat{\mathbf{Y}} - \mathbf{Y}_r]^T [\hat{\mathbf{Y}} - \mathbf{Y}_r] + \Lambda \Delta \mathbf{X}^T \Delta \mathbf{X} \quad (4.44)$$

onde $\mathbf{Y}_r = [y_r(t+N_1) \quad y_r(t+N_1+1) \quad \cdots \quad y_r(t+N_2)]^T$

Assim, minimiza-se a função custo J_{HGPC} da função (4.44) obtendo a seguinte lei de controle:

$$\Delta \mathbf{X} = [\mathbf{G}^T \mathbf{G} + \Lambda \mathbf{I}]^{-1} \mathbf{G}^T [\mathbf{Y}_r - \mathbf{H} \Delta \mathbf{V} - \mathbf{f}] \quad (4.45)$$

Apenas a primeira posição do vetor $\Delta \mathbf{X}$ é considerada, $\Delta x(t)$, e calcula-se, portanto,

$$x(t) = x(t-1) + \Delta x(t) \quad (4.46)$$

A partir do cálculo das raízes do polinômio representado pela equação (4.31) determina-se a ação de controle que, de fato é aplicada ao processo. O sinal de controle deve ser selecionado dentre as raízes válidas, podendo surgir mais de uma possibilidade conforme o grau da não-linearidade (m).

Ao longo do capítulo 5 a aplicação experimental do controlador *HGPC* é apresentada a uma planta de climatização baseada em energia solar que pode ser representada por um modelo de Hammerstein com perturbações mensuráveis.

4.3.6 Multiplicidade de Soluções para a Lei de Controle

As estratégias de controle preditivo de Bars e Haber, Katende e Jutan, Fruzzetti e o *HGPC* resultam em multiplicidade de soluções para o problema de controle. Isto ocorre porque o controlador encontra o valor ótimo para a pseudo-saída $x(t)$ a qual, através da equação (4.24) fornece diversas soluções. Além disso, as estratégias de Katende e Jutan, e Fruzzetti necessitam que o polinômio que representa a não-linearidade estática tenha grau ímpar para que possam garantir pelo menos um valor factível para o sinal de controle, ou seja, pelo menos uma raiz real na solução do polinômio da equação (4.24). Estes problemas podem ser resolvidos através de uma segunda operação de otimização, por exemplo, através de um método iterativo de busca (Zhu *et al.*, 1991; Isermann *et al.*, 1992), ou, ainda, empregando algum tipo de aproximação.

• Busca Iterativa

Um possível método de busca das raízes pode ser representado pelo seguinte algoritmo:

Algoritmo de Busca do Controle Ótimo

1. Minimiza a função custo analiticamente, obtendo o valor ótimo para a pseudo-saída, $x_o \left(\frac{\partial J}{\partial x} = 0 \right)$;
2. Obtém as raízes do polinômio: $x_o = \gamma_1 u + \gamma_2 u^2 + \dots + \gamma_m u^m$;
3. Descarta as raízes que violem restrições ou sejam complexas;
4. Seleciona para u_o aquela que minimiza $|u(t) - u(t-1)|$;
5. Não havendo solução que atenda estes critérios, u_o será um valor pré-determinado.

Havendo mais de um sinal de controle que atenda os critério é selecionado aquele que mais próximo do valor anterior que foi aplicado à planta.

- **Aproximação de Zhu e Seborg**

Esta aproximação além de fornecer uma única solução para o controle, dispensa a obrigatoriedade de um modelo com não-linearidade de grau ímpar que pode ser restritivo, apresenta resultados adequados quando a entrada varia lentamente mas, tem algumas limitações de aplicabilidade quando o sinal de controle sofre variações muito bruscas podendo, inclusive, comprometer a estabilidade do sistema (Zhu e Seborg, 1994; Pearson e Ogunnaike, 1997).

$$u(t) \approx \frac{1}{\gamma_1} \left[x(t) - \gamma_2 u^2(t-1) - \dots - \gamma_m u^m(t-1) \right] \quad (4.47)$$

Para o exemplo da equação (4.17) esta aproximação torna-se

$$u(t) \approx \frac{1}{\gamma_1} \left[x(t) - \gamma_2 u^2(t-1) \right]$$

- **Aproximação por Série de Taylor**

Apresenta as mesmas vantagens da aproximação de Zhu e Seborg além de uma maior robustez em relação à estabilidade do sistema para grandes variações no sinal de controle. Sua desvantagem é a necessidade de substituir todo termo do sinal de controle com expoente maior que um tornando-se trabalhosa quando o grau da não-linearidade é elevado (Santos *et al.*, 2004).

Considerando que $f = u^m$, a aplicação de uma linearização em torno de um ponto u_0 leva a

$$\bar{f} = f_0 + \left. \frac{\partial f}{\partial u} \right|_{u=u_0} (u - u_0) = u_0^m + m u_0^{m-1} (u - u_0)$$

e considerando que o ponto $u_0 = u(t-1)$,

$$\bar{f} = u^m(t-1) + m u^{m-1}(t-1) [u(t) - u(t-1)] = m u^{m-1}(t-1) u(t) - (m-1) u^m(t-1)$$

e, desta forma, a não-linearidade do sistema

$$x(t) = \gamma_1 u(t) + \gamma_2 u^2(t) + \cdots + \gamma_m u^m(t) = \sum_{i=1}^m \gamma_i u^i(t) \quad (4.48)$$

pode ser representada, aproximadamente por

$$x(t) \simeq \gamma_1 u(t) + \gamma_2 \bar{u}^2(t) + \cdots + \gamma_m \bar{u}^m(t) = \gamma_1 u(t) + \sum_{i=2}^m \gamma_i \bar{u}^i(t)$$

ou, ainda,

$$x(t) \simeq \left[\sum_{i=1}^m i \gamma_i u^{i-1}(t-1) \right] u(t) - \sum_{i=2}^m (i-1) \gamma_i u^i(t-1) \quad (4.49)$$

O sinal de controle torna-se único e determinado pela equação

$$u(t) \simeq \frac{x(t) + \sum_{i=2}^m (i-1) \gamma_i u^i(t-1)}{\left[\sum_{i=1}^m i \gamma_i u^{i-1}(t-1) \right]} \quad (4.50)$$

Para o exemplo da equação (4.17) a aproximação resulta

$$u(t) \simeq \frac{x(t) + \gamma_2 u^2(t-1)}{\gamma_1 + 2\gamma_2 u(t-1)}$$

Mesmo quando se utilizam aproximações para evitar a aplicação de um método numérico, pode ocorrer que o sinal de controle calculado não atenda às restrições do sistema e, neste caso, é necessário definir um valor de controle a ser aplicado que pode ser o sinal aplicado no instante anterior, $u(t-1)$, ou mesmo o valor da entrada em regime permanente, conforme o conhecimento prévio do processo.

A Figura 4.6 ilustra uma proposta de procedimento de tomada de decisão na seleção de uma estratégia para a determinação do sinal de controle a ser aplicado na planta. Baseado nas informações de restrições de tempo (período de amostragem) pode-se optar pela busca de raízes do polinômio que representa a NL ou pelo uso de uma das aproximações. Utilizando uma solução aproximada deve-se levar em conta ainda a possibilidade de variações bruscas do sinal de controle o que torna a aproximação empregando série de Taylor mais recomendável.

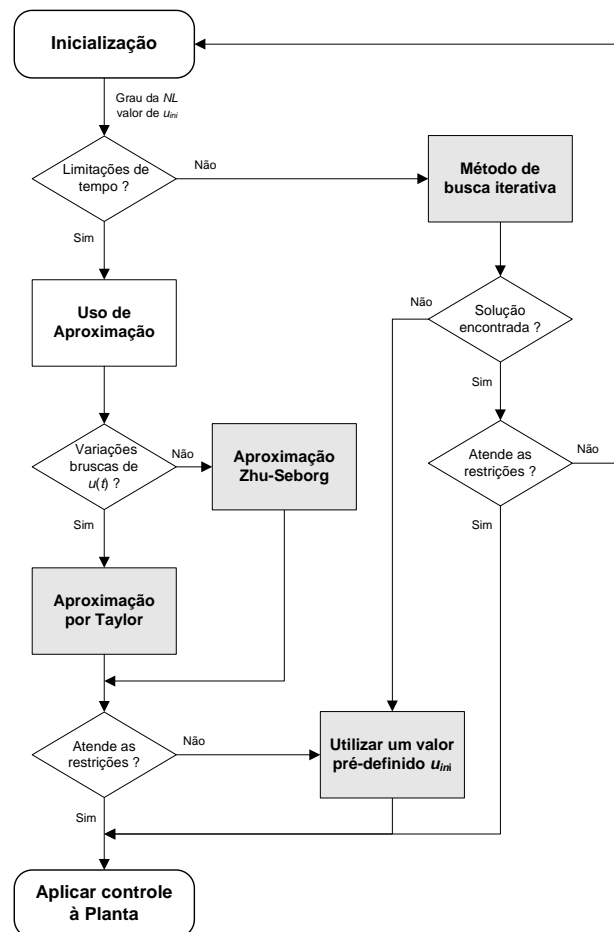


Figura 4.6 – Seleção do Sinal de Controle.

4.4 PREDITORES DE HAMMERSTEIN BASEADOS EM MODELOS NÃO-LINEARES

O preditor fornece, através do modelo matemático da planta, uma predição da saída futura com base na informação atual do sistema. É baseado nesta predição do comportamento futuro do processo que o controlador preditivo calcula o sinal de controle (Favier e Dubois, 1990; Haber *et al.*, 2003).

Mesmo para processos com características não-lineares complexas, através do uso de um preditor adequado, pode-se obter uma lei de controle preditivo generalizado simplificada, possibilitando sua implementação em sistemas onde o tempo de resposta é considerado crítico.

Neste sentido, apresenta-se um estudo de preditores onde se mostra que, com o conhecimento a priori do *mean level control*, os preditores baseados nos modelos bilinear e Volterra convergem para o preditor de Hammerstein. Esta idéia é interessante visando tanto a aplicação com a implementação (redução do esforço computacional) de controle preditivo para tratar sistemas *NCARMA*.

4.4.1 Preditor para o Modelo Linear

Considere um modelo discreto linear de primeira ordem representado na equação (4.51)

$$y(t) = -a_1 y(t-1) + b_0 u(t-1) \quad (4.51)$$

A predição da saída um passo à frente resulta

$$\hat{y}(t+1) = -a_1 y(t) + b_0 u(t)$$

Da mesma forma para dois passos à frente

$$\hat{y}(t+2) = -a_1 y(t+1) + b_0 u(t+1)$$

que pode ser reescrita na forma

$$\hat{y}(t+2) = -a_1 [-a_1 y(t) + b_0 u(t)] + b_0 u(t+1)$$

$$\hat{y}(t+2) = a_1^2 y(t) - a_1 b_0 u(t) + b_0 u(t+1)$$

Para três passos à frente

$$\hat{y}(t+3) = -a_1 y(t+2) + b_0 u(t+2)$$

$$\hat{y}(t+3) = -a_1 (a_1^2 y(t) - a_1 b_0 u(t) + b_0 u(t+1)) + b_0 u(t+2)$$

$$\hat{y}(t+3) = -a_1^3 y(t) + a_1^2 b_0 u(t) - a_1 b_0 u(t+1) + b_0 u(t+2)$$

Generalizando tem-se

$$\hat{y}(t+i) = (-a_1)^i y(t) + \sum_{j=1}^i (-a_1)^{i-j} b_0 u(t+j) \quad (4.52)$$

No instante atual, somente as informações anteriores de entrada e saída são conhecidas, $y(t-i+1)$ e $u(t-i)$ para $i>0$ e utilização no cálculo de $\hat{y}(t+i)$.

Na aplicação do *GPC* clássico a informação referente ao controle futuro (resposta forçada) é separada da baseada na informação atual (resposta livre) e o otimizador atua de forma a determinar o controle futuro que minimiza a função custo determinada. Numa abordagem *Mean Level Control*, onde $N_2 \rightarrow \infty$ se $N_1 = d = 1$, $N_u = 1$, $\Lambda = 0$ a ação de controle futura é considerada constante e, portanto, $u(t+i) = \bar{u}(t), \forall i \geq 0$ tornando a equação (4.52)

$$\hat{y}(t+i) = (-a_1)^i y(t) + \left[\sum_{j=1}^i (-a_1)^{j-1} \right] b_0 \bar{u}(t) \quad (4.53)$$

4.4.2 Preditor para o Modelo de Hammerstein

Considerando um modelo discreto de Hammerstein, com parcela linear de primeira ordem e com não-linearidade $m = 1$, representado na equação (4.54)

$$y(t) = -a_1 y(t-1) + b_0 u(t-1) + c_0 u^2(t-1) \quad (4.54)$$

Segundo a abordagem *MLC*, a predição da saída um passo à frente resulta

$$y(t+1) = -a_1 y(t) + b_0 u(t) + c_0 u^2(t) \quad u(t+i) = \bar{u}(t), \quad \forall i \geq 0$$

$$y(t+1) = -a_1 y(t) + b_0 \bar{u}(t) + c_0 \bar{u}^2(t)$$

Para dois passos a frente

$$y(t+2) = -a_1 y(t+1) + b_0 u(t+1) + c_0 u^2(t+1)$$

$$y(t+2) = -a_1 \left(-a_1 y(t) + b_0 \bar{u}(t) + c_0 \bar{u}^2(t) \right) + b_0 \bar{u}(t) + c_0 \bar{u}^2(t)$$

$$y(t+2) = a_1^2 y(t) + b_0 (1-a_1) \bar{u}(t) + c_0 (1-a_1) \bar{u}^2(t)$$

Considerando três passos

$$y(t+3) = -a_1 y(t+2) + b_0 u(t+2) + c_0 u^2(t+2)$$

$$y(t+3) = -a_1 \left(a_1^2 y(t) + b_0 (1-a_1) \bar{u}(t) + c_0 (1-a_1) \bar{u}^2(t) \right) + b_0 \bar{u}(t) + c_0 \bar{u}^2(t)$$

$$y(t+3) = -a_1^3 y(t) + b_0 (1-a_1+a_1^2) \bar{u}(t) + c_0 (1-a_1+a_1^2) \bar{u}^2(t)$$

Generalizando,

$$y(t+i) = (-a_1)^i y(t) + \left[\sum_{j=1}^i (-a_1)^{j-1} \right] b_0 \bar{u}(t) + \left[\sum_{j=1}^i (-a_1)^{j-1} \right] c_0 \bar{u}^2(t) \quad (4.55)$$

4.4.3 Preditor para o Modelo Bilinear

Considerando um modelo discreto bilinear com $n_y = 1$ e $n_u = 0$, representado na equação (4.56)

$$y(t) = -a_1 y(t-1) + b_0 u(t-1) + c_0 y(t-1) u(t-1) \quad (4.56)$$

Considerando a abordagem *MLC*, a predição da saída um passo à frente resulta

$$y(t+1) = -a_1 y(t) + b_0 u(t) + c_0 y(t) u(t) \quad u(t+i) = \bar{u}(t), \quad \forall i \geq 0$$

$$y(t+1) = -a_1 y(t) + (b_0 + c_0 y(t)) \bar{u}(t)$$

A predição dois passos à frente torna-se

$$y(t+2) = -a_1 y(t+1) + b_0 u(t+1) + c_0 y(t+1) u(t+1)$$

$$y(t+2) = -a_1 \left[-a_1 y(t) + (b_0 + c_0 y(t)) \bar{u}(t) \right] + b_0 \bar{u}(t) + c_0 \left[-a_1 y(t) + (b_0 + c_0 y(t)) \bar{u}(t) \right] \bar{u}(t)$$

$$y(t+2) = a_1^2 y(t) + (b_0(1-a_1) - 2c_0 a_1 y(t)) \bar{u}(t) + c_0 (b_0 + c_0 y(t)) \bar{u}^2(t)$$

Para três passos à frente tem-se

$$y(t+3) = -a_1 y(t+2) + b_0 u(t+2) + c_0 y(t+2) u(t+2)$$

$$y(t+3) = -a_1 \left[a_1^2 y(t) + (b_0(1-a_1) - 2c_0 a_1 y(t)) \bar{u}(t) + c_0 (b_0 + c_0 y(t)) \bar{u}^2(t) \right] + b_0 \bar{u}(t) + c_0 \left[a_1^2 y(t) + (b_0(1-a_1) - 2c_0 a_1 y(t)) \bar{u}(t) + c_0 (b_0 + c_0 y(t)) \bar{u}^2(t) \right] \bar{u}(t)$$

$$y(t+3) = -a_1^3 y(t) + (b_0(1-a_1+a_1^2) + 3c_0 a_1^2 y(t)) \bar{u}(t) + c_0 (b_0(1-a_1) - 3c_0 a_1 y(t)) \bar{u}^2(t) + c_0^2 (b_0 + c_0 y(t)) \bar{u}^3(t)$$

Generalizando, obtém-se a equação (4.57).

$$y(t+i) = (-a_1)^i y(t) + \left[c_0 (-a_1)^{i-1} u(t-1) + b_0 \sum_{j=1}^i (-a_1)^{j-1} \right] \bar{u}(t) + \left[\sum_{j=1}^{i-1} (-a_1)^{j-1} \right] c_0 \bar{u}^2(t) \quad (4.57)$$

Observa-se através da equação (4.57) que o preditor para modelo bilinear estudado, numa abordagem *MLC*, apresenta-se com a mesma representação do modelo de Hammerstein, onde a única não-linearidade manifesta-se na entrada futura $\bar{u}(t)$.

4.4.4 Preditor para o Modelo de Volterra

Considerando um modelo discreto do tipo *AR-Volterra*, representado pela equação (4.58), onde $na = 1$ e $nb = 0$ e $m = 2$

$$y(t) = -a_1 y(t-1) + b_0 u(t-1) + c_0 u(t-1)u(t-2) \quad (4.58)$$

Empregando a abordagem *MLC*, a predição da saída um passo à frente é

$$y(t+1) = -a_1 y(t) + b_0 u(t) + c_0 u(t)u(t-1) \quad u(t+i) = \bar{u}(t), \quad \forall i \geq 0$$

$$y(t+1) = -a_1 y(t) + (b_0 + c_0 u(t-1)) \bar{u}(t)$$

Para dois passos à frente a predição torna-se

$$y(t+2) = -a_1 y(t+1) + b_0 u(t+1) + c_0 u(t+1)u(t)$$

$$y(t+2) = -a_1 \left[-a_1 y(t) + (b_0 + c_0 u(t-1)) \bar{u}(t) \right] + b_0 \bar{u}(t) + c_0 \bar{u}^2(t)$$

$$y(t+2) = a_1^2 y(t) + (b_0(1-a_1) - c_0 a_1 u(t-1)) \bar{u}(t) + c_0 \bar{u}^2(t)$$

Considerando três passos a predição é

$$y(t+3) = -a_1 y(t+2) + b_0 u(t+2) + c_0 u(t+2)u(t+1)$$

$$y(t+3) = -a_1 \left[a_1^2 y(t) + (b_0(1-a_1) - c_0 a_1 u(t-1)) \bar{u}(t) + c_0 \bar{u}^2(t) \right] + b_0 \bar{u}(t) + c_0 \bar{u}^2(t)$$

$$y(t+3) = -a_1^3 y(t) + (b_0(1-a_1+a_1^2) + c_0 a_1^2 u(t-1)) \bar{u}(t) + c_0(1-a_1) \bar{u}^2(t)$$

Generalizando,

$$y(t+i) = (-a_1)^i y(t) + \left[c_0 (-a_1)^{i-1} u(t-1) + b_0 \sum_{j=1}^i (-a_1)^{j-1} \right] \bar{u}(t) + \left[\sum_{j=1}^{i-1} (-a_1)^{j-1} \right] c_0 \bar{u}^2(t) \quad (4.59)$$

Nota-se através da equação (4.59) que o preditor para modelo de Volterra da equação (4.58), numa abordagem *MLC*, apresenta-se com a mesma estrutura do modelo de Hammerstein, onde a não-linearidade manifesta-se na entrada futura $\bar{u}(t)$.

Pode-se obter, portanto, uma lei de controle preditivo generalizado simplificada, para aplicações em tempo-real em processos não-lineares, baseada num preditor para os modelos de Volterra, Hammerstein e Bilinear sob a estratégia do *Mean Level Control* uma vez que os preditores convergem para uma estrutura do tipo Hammerstein.

4.5 CONCLUSÃO

Neste capítulo foram apresentadas estratégias de controle preditivo sendo enfatizadas aquelas baseadas em modelos não-lineares de Hammerstein. Destacou-se a importância do modelo de Hammerstein que possibilita a implementação de estratégias com solução analítica no caso irrestrito.

O caso de multiplicidade no sinal de controle ótimo foi apresentado e uma solução baseada em aproximação por série de Taylor foi proposta de maneira a garantir uma solução analítica para a lei de controle no caso irrestrito.

Um estudo de preditores baseados em modelos não-lineares foi apresentado onde foi observada que utilizando os modelos de Volterra, Hammerstein e Bilinear sob uma abordagem *MLC* há uma convergência para a estrutura do modelo de Hammerstein.

As principais contribuições deste capítulo são o controlador preditivo com perturbações mensuráveis baseado no modelo de Hammerstein (*HGPC*), a solução proposta para o problema da multiplicidade do sinal de controle ótimo utilizando uma aproximação por série de Taylor e o estudo de preditores baseados em modelos não-lineares sob a estratégia *MLC*.

Resultados experimentais e de simulação das estratégias de identificação do modelo de Hammerstein apresentados no capítulo 3 e as técnicas de controle preditivo apresentadas neste capítulo são ilustrados no capítulo 5.

5. RESULTADOS DE SIMULAÇÃO

5.1 INTRODUÇÃO

Toda vez que a experimentação num processo real apresenta restrições de ordem operacional, econômico-financeira ou de segurança, a realização de estudos de simulação a partir de um modelo do processo é fundamental, seja com o objetivo de treinamento, projeto ou predição de resultados (Brosilow e Joseph, 2002).

Com o objetivo de destacar as principais características das técnicas de modelagem, identificação e controle apresentadas nos capítulos anteriores realizam-se diversos estudos de simulação utilizando o ambiente MatLabTM/Simulink.

Além da parte de simulação numérica, uma implementação experimental numa planta real de climatização baseada em energia solar é apresentada sob os aspectos de modelagem, identificação e do controle preditivo não-linear.

5.2 APLICATIVO DE IDENTIFICAÇÃO EM UM PROCESSO HAMMERSTEIN

O processo apresenta uma não-linearidade do tipo saturação na entrada, Figura 5.1, e o comportamento está descrito pela função de transferência

$$G(s) = \frac{1}{s^2 + 2s + 1} \quad (5.1)$$

sendo a não-linearidade representada por

$$x(t) = \frac{1 + \operatorname{sgn}(a - |u(t)|)}{2} u(t) + \frac{1 + \operatorname{sgn}(|u(t)| - a)}{2} a \cdot \operatorname{sgn}(u(t)) \quad (5.2)$$

onde o parâmetro a vale 2.




Figura 5.1 – Processo com Saturação na Entrada.

Para proceder a identificação do processo, utilizando um intervalo de amostragem de um segundo, é realizada uma simulação ao longo de 300 segundos a partir de um sinal de entrada variando aleatoriamente entre -5 e $+5$ com a saída do processo contaminada por um ruído branco com 0.01 de variância.




Figura 5.2 – Ensaio em Malha Aberta para Identificação.

Considerando-se um polinômio de grau $m = 3$ adequado para representar a saturação, aplica-se o teste *DR*, Figura 5.3. Baseado neste teste um modelo *FIR* com 6 (seis) termos contem informação suficiente para representar o processo uma vez que sua dinâmica é suficientemente rápida para isto.






Figura 5.3 – Teste *DR* para um Processo com Saturação na Entrada.


Empregando-se os primeiros 100 pontos para a identificação e os demais para a validação obtém-se os seguintes resultados:




(a) Narendra – Galman.



(b) Mínimos Quadrados com Restrições.



(c) Boutayeb.



(d) Bai.

Figura 5.4 – Comparação Saída Real x Estimada.

Pela Figura 5.4 e os resultados da Tabela 5.1 é possível observar que todos os modelos estimados convergem para os valores corretos. Para ensaios realizados na ausência de ruído os resultados obtidos pelas três técnicas se equivalem.

Tabela 5.1 – Comparação entre os Resultados de Identificação.

Parâmetros	$H(q^{-1})$	γ	SSE	R^2
Narendra - Gallman	$0.2703q^{-1} + 0.3259q^{-2} + 0.2049q^{-3} +$	1.0000	0.0120	0.9944
	$0.1067q^{-4} + 0.0514q^{-5} + 0.0139q^{-6}$	-0.0147 -0.0295		
MQ com Restrições	$0.2658q^{-1} + 0.4280q^{-2} + 0.0888q^{-3}$	1.0000	0.0273	0.9872
	$-0.0209q^{-4} + 0.2618q^{-5} - 0.0615q^{-6}$	-0.0055 -0.0560		
Boutayeb	$0.2532q^{-1} + 0.3146q^{-2} + 0.2075q^{-3} +$	1.0000	0.0221	0.9895
	$0.1111q^{-4} + 0.0553q^{-5} + 0.01266q^{-6}$	-0.0044 -0.0282		
Bai	$0.2571q^{-1} + 0.3364q^{-2} + 0.1948q^{-3} +$ $0.1016q^{-4} + 0.0613q^{-5} + 0.0343q^{-6}$	2.0091	0.0266	0.9875

Embora todas as estratégias tenham apresentado desempenhos semelhantes, a técnica de Boutayeb tem, ainda, a vantagem de apresentar solução analítica para o problema de estimação ao contrário dos Mínimos Quadrados com Restrições, Bai e Narendra-Gallman que são métodos iterativos. A Figura 5.5 compara a não-linearidade estimada pela técnica de Boutayeb com a saturação do processo e a Figura 5.6 apresenta a validação do modelo com outro conjunto de dados obtendo $SSE = 0.06718$ e $R^2 = 0.9676$.




Figura 5.5 – NL estimada e Saturação do Processo.




Figura 5.6 – Validação do Modelo Obtido (Boutayeb).

5.3 AVALIAÇÃO DA MULTIPLICIDADE DE SOLUÇÕES PARA A LEI DE CONTROLE

Este estudo de simulação tem o objetivo de comparar o desempenho de um controlador preditivo não-linear (Katende-Jutan) implementado através da busca de raízes para o polinômio da não-linearidade ou empregando as aproximações apresentadas no capítulo 4.

Considere o sistema que representa um trocador de calor, conforme descrito no trabalho de H. Al-Duwaish e Wasif Naeem (2001), que consiste de uma parcela linear representada pela equação (5.3), e uma não-linearidade estática representada pela equação (5.4). A entrada do processo corresponde à variação da vazão do fluido na entrada do processo enquanto que a saída equivale à variação da temperatura de saída do fluido considerando uma vazão de vapor constante (Figura 5.7).

$$y(t) = 1.608y(t-1) - 0.6385y(t-2) - 6.5306x(t-1) + 5.5652x(t-2) \quad (5.3)$$

$$x(t) = u(t) - 1.3228u^2(t) + 0.7671u^3(t) - 2.1755u^4(t) \quad (5.4)$$






Figura 5.7 – Representação de um Trocador de Calor Casco-Tubo.

Considerando o perfeito conhecimento dos parâmetros do processo, realizaram-se ensaios empregando um controlador *NMPC* (estratégia Katende-Jutan). Este estudo de simulação tem o objetivo de comparar o desempenho do controlador implementado através da busca de raízes para o polinômio da não-linearidade ou usando as aproximações apresentadas.


No experimento de seguimento de referência, Figura 5.8, o valor desejado para a saída apresenta uma variação entre 5 e 30 ao longo da simulação com 400 amostras. São aplicados os três casos com a mesma sintonia para facilitar a comparação. A ponderação do esforço de controle (Λ) apresenta um valor elevado para garantir a estabilidade do sistema para o caso da aproximação de Zhu-Seborg.



(a) Busca de Raízes.



(b) Aproximação Zhu-Seborg.




(c) Aproximação de Taylor.


Figura 5.8 – Controladores Preditivos com Sintonia: $N_2 = 5$; $N_u = 2$; $\lambda = 200$.

Nesta simulação a aproximação de Zhu-Seborg proporciona um comportamento oscilatório na saída causado por sua sensibilidade às variações bruscas da ação de controle, enquanto que, para as demais se observa um comportamento adequado.


Para o experimento de rejeição de perturbação, Figura 5.9, é aplicada, na saída, uma perturbação de 10% no instante $t = 150$ e retirada em $t = 250$. A referência é mantida constante em 15 ao longo das 400 amostras.



(a) Busca de Raízes.



(b) Aproximação Zhu-Seborg.



(c) Aproximação de Taylor.

Figura 5.9 – Controladores Preditivos com Sintonia: $N_2 = 5$; $N_u = 1$; $\lambda = 2000$.

Mais uma vez o controlador empregando a aproximação de Zhu-Seborg apresenta desempenho oscilatório com problemas de estabilidade para valores maiores do horizonte de controle (N_u) ou menores para a ponderação do esforço de controle (λ).

Para facilitar a comparação entre os controladores é necessário mensurar o desempenho através de parâmetros que levem em conta o erro de rastreamento da referência e o esforço de controle aplicado. Isto pode ser feito, por exemplo, através dos seguintes índices de desempenho:

$$Je = \sum_{t=1}^N [y_r(t) - y(t)]^2 \quad (5.5)$$

$$Ju = \sum_{t=2}^N [u(t) - u(t-1)]^2 \quad (5.6)$$

Tabela 5.2 – Desempenho das Técnicas de Seleção de Raízes.

Técnica	Ensaio	Je	Ju
Busca de Raízes	servo	2.3509	0.0005
	regulação	2.4711	0.0002
Zhu-Seborg	servo	3.9987	0.0526
	regulação	4.7127	0.0215
Taylor	servo	1.9915	0.0011
	regulação	2.2198	0.0003

O uso de aproximações, embora permitam a redução do esforço computacional que é vital em aplicações de tempo-real, pode provocar problemas de estabilidade dificultando, assim, a sintonia do controlador. Portanto sua aplicação é recomendável apenas nos casos onde o tempo é crítico (cumprimento do período de amostragem). Neste sentido a aproximação por série de Taylor, proposta no capítulo 4, mostra resultados similares ao método de busca exaustiva de raízes e bem superior à aproximação de Zhu-Seborg principalmente em relação à questão de estabilidade do sistema.

5.4 APLICATIVO DE IDENTIFICAÇÃO E CONTROLE DE UM REATOR *CSTR*

Os processos químicos sempre se mostraram desafiadores do ponto de vista de controle, apresentando complexidades que nem sempre são tratadas por controladores

lineares adequadamente (Bequette, 1991; Sistu e Bequette, 1991; Aguirre *et al.*, 2005). Nesta seção é tratado o caso de um reator *CSTR* (*Continuous Stirred Tank Reactor*) cuja modelagem e parâmetros, para uma reação irreversível, exotérmica, $A \rightarrow B$, são baseados no trabalho de Michael Henson e Dale Seborg (Henson e Seborg, 1997; Santos *et al.*, 2001).

O objetivo de controle em relação ao reator *CSTR* (Figura 5.10) é controlar a temperatura (T) através da manipulação da temperatura do fluido refrigerante (T_c).




Figura 5.10 – Representação Esquemática de um reator *CSTR*.

Tabela 5.3 – Notação para o Reator *CSTR*.

Símbolo	Significado [Unidade]
C_A	concentração de A no reator [mol/L]
T	temperatura do reator – variável de saída [K]
T_c	temperatura do fluido refrigerante - variável manipulada [K]
q	vazão [L/min]
V	volume do reator [m^3]
C_{Af}	concentração de A na alimentação [mol/L]
T_f	temperatura de alimentação [K]
ρ	massa específica da mistura [g/L]
C_p	capacidade calorífica da mistura [$J/g.K$]

ΔH	calor de reação [J/mol]
E	energia de ativação [J/mol]
R	constante universal dos gases [$J/mol.K$]
k_0	taxa de reação específica [min^{-1}]
U	coeficiente global de troca térmica [$J/min.K.m^2$]
A	área de troca térmica [m^2]

Assumindo volume constante, o seguinte modelo pode ser considerado para o reator em questão:


$$\dot{C}_A = \frac{q}{V}(C_{Af} - C_A) - k_0 e^{\left(\frac{E}{RT}\right)} C_A \quad (5.7)$$

$$\dot{T} = \frac{q}{V}(T_f - T) - \frac{(-\Delta H)}{\rho C_p} k_0 e^{\left(\frac{E}{RT}\right)} C_A + \frac{UA}{V\rho C_p}(T_c - T) \quad (5.8)$$

Considerando as seguintes condições nominais de operação:

$q = 100 \text{ L/min}$	$C_p = 0.239 \text{ J/g.K}$	$UA = 5 \cdot 10^4 \text{ J/min.K}$
$C_{Af} = 1 \text{ mol/L}$	$\Delta H = -5 \cdot 10^4 \text{ J/mol}$	$T_c = 300 \text{ K}$
$T_f = 350 \text{ K}$	$E/R = 8750 \text{ K}$	$C_A = 0.5 \text{ mol/L}$
$V = 100 \text{ L}$	$k_0 = 7.2 \cdot 10^{10} \text{ min}^{-1}$	$T = 350 \text{ K}$
$\rho = 1000 \text{ g/L}$		

Através de um ensaio em malha aberta é possível observar o comportamento altamente não-linear do processo nestas condições de operação, Figura 5.11.

(a) Degrau Positivo $T_c = 300 \rightarrow 305 K$.(b) Degrau Negativo $T_c = 300 \rightarrow 295 K$.Figura 5.11 – Resposta do *CSTR* a Aplicação de um Degrau.

5.4.1 Etapa de Identificação

A partir da aplicação de um sinal do tipo *PRBS*, Figura 5.12 e Figura 5.13, onde os extremos correspondem a $T_c = 290K$ e $360K$, num ensaio de 50 minutos e empregando-se o método de Boutayeb foi realizada a identificação de um modelo não-linear do tipo Hammerstein.




Figura 5.12 – Dados de Entrada-Saída do Processo para Estimação.




Figura 5.13 – Comparação Resposta da Planta x Modelo Estimado.

O modelo apresenta $SSE = 99.1676$ e $R^2 = 0.9350$ e os parâmetros estimados são

$$y(t) = y(t-1) + 0.9711\Delta y(t-1) - 0.0382\Delta x(t-1) - 0.0183\Delta x(t-2) \quad (5.9)$$

$$x(t) = u(t) - 0.0057u^2(t) \quad (5.10)$$

Para a validação do modelo estimado foi realizada uma nova simulação de mesmo período, porém, outra seqüência de dados, Figura 5.14. A comparação entre a saída real da planta e a estimativa indica que o modelo apresenta algumas limitações na capacidade de representação ($SSE = 441.6851$ e $R^2 = 0.7414$).




Figura 5.14 – Comparação das Respostas para Validação.

5.4.2 Etapa do Controle Preditivo Não-Linear

Para possibilitar um estudo do comportamento do sistema de controle preditivo não-linear em relação ao reator aplica-se o controlador de Katende e Jutan baseado no modelo de Hammerstein identificado, equações (5.9) e (5.10).

A simulação do processo para a avaliação do seguimento de referência, com 20 minutos de duração, apresenta duas variações no valor de referência entre 350K e 375K. Para este ensaio a sintonia empregada para o controlador *PI* é $K_c = 12$ e $K_i = 1$, enquanto que, o controlador preditivo utiliza $N_1 = 1$; $N_2 = 8$; $N_u = 1$; $\Lambda = 0.000001$.




Figura 5.15 – Análise de Comportamento Servo para o *CSTR*.

A escolha deste ponto de operação para o processo torna a sintonia dos controladores um procedimento complexo, visto o comportamento altamente não-linear apresentado. O controlador Katende-Jutan apresenta um desempenho satisfatório tanto no aspecto de rastreamento da referência como no esforço de controle empregado nesta tarefa.

O ensaio para avaliação do comportamento regulatório é realizado pela aplicação de uma perturbação no tempo $t = 5$ min e retirada em $t = 10$ min, num ensaio de 20 min, com a referência mantida em 350K. A perturbação consiste de uma redução na energia de ativação de 1.7%, de forma que a parcela (E/R) é reduzida em 150K. A sintonia do controlador foi mantida em relação ao ensaio de seguimento de referência ($Je = 71.2884$ e $Ju = 7.0690$).




Figura 5.16 – Análise de Comportamento Regulatório para o *CSTR*.

Pela análise da Figura 5.16 observa-se novamente que, embora o resultado não tenha se mostrado plenamente satisfatório devido à presença de uma sobre-elevação, o controlador preditivo não-linear consegue eliminar a perturbação de carga num tempo adequado ($Je = 122.4790$ e $Ju = 6.5928$).

Logo, o efeito dos parâmetros empregados na sintonia do controle preditivo (ponderações, horizontes de predição, filtros) sobre o desempenho de um sistema não-linear ainda não é totalmente conhecido, pois varia em função das características da não-linearidade, presença de atraso de transporte ou ruído de medição. Além disso, fica claro que o modelo de Hammerstein possui limitações em relação a sua capacidade de representar não-linearidades de processos complexos quando da presença de não-linearidades fortes.

5.5 PLANTA SOLAR DE CLIMATIZAÇÃO

O uso de energias limpas e renováveis apresenta um forte apelo atualmente em função da preocupação em relação aos combustíveis fósseis e seu conseqüente impacto ambiental. Embora somente uma parte da radiação solar atinja a superfície terrestre, devido à reflexão e absorção dos raios solares pela atmosfera, estima-se que esta parcela seja da ordem de 10 mil vezes o consumo energético mundial. O uso da energia solar fotovoltaica ou mesmo sua aplicação em aquecimento já é bastante comum, no entanto, sua aplicação para a produção de frio ainda não possui uma grande popularidade. Seu aproveitamento, porém, apresenta um grande potencial visto que nas

regiões onde há maior disponibilidade de radiação solar são justamente aquelas que apresentam maior necessidade de climatização (Gamboa, 2004).

A operação de um sistema desta complexidade apresenta características muito interessantes do ponto de vista do controle de processos: a fonte primária de energia (radiação solar) não pode ser manipulada; existem grandes perturbações no sistema (variação nas condições ambientais); existem fortes restrições de amplitude e velocidade nas variáveis manipulada e controlada; existe atraso de transporte associado ao movimento de fluidos que dependem das condições de operação; a demanda de refrigeração é bastante variável pois depende das condições de ocupação do ambiente (Normey-Rico, 1999; Scheffer-Dutra *et al.*, 2002; Zambrano e Camacho, 2002; Núñez-Reyes *et al.*, 2005).

5.5.1 Descrição da Planta Solar

A instalação solar de refrigeração da *Escuela Superior de Ingenieros da Universidad de Sevilla* (Sevilla, Espanha) consta de uma máquina de absorção com uma potência frigorífica nominal de 35kW, juntamente com um sistema de obtenção de energia térmica necessária para o funcionamento do ciclo de absorção e um sistema de retirada de calor. A Figura 5.17 representa o esquema da planta solar de refrigeração onde é possível observar seus componentes: **o sistema de captação**, formado por um conjunto de painéis solares; **o acumulador solar**, composto por dois tanques encarregados de armazenar o fluido proveniente dos painéis; **o sistema auxiliar de energia**, composto por uma caldeira de gás natural encarregada de suprir energia quando a radiação solar não é suficiente; **a máquina de absorção** encarregada da produção de frio; além de um **simulador de carga**, composto por um trocador e uma bomba de calor que permitem a realização de ensaios.

As partes fundamentais da instalação são o equipamento de absorção, com uma potência frigorífica nominal de 35 kW, junto com o sistema de captação solar, formada por um conjunto de coletores solares térmicos. Em condições nominais a energia fornecida pelos painéis solares é de 50 kW. Como complemento do sistema de captação, existe uma caldeira de gás natural que fornece a energia auxiliar necessária. Esta caldeira, com uma potência nominal de 60 kW, é utilizada quando o fornecimento de radiação solar é insuficiente. Além disso, a instalação possui um sistema de acumulação de água, de tal forma que se possa utilizar a energia excedente nos momentos de déficit.

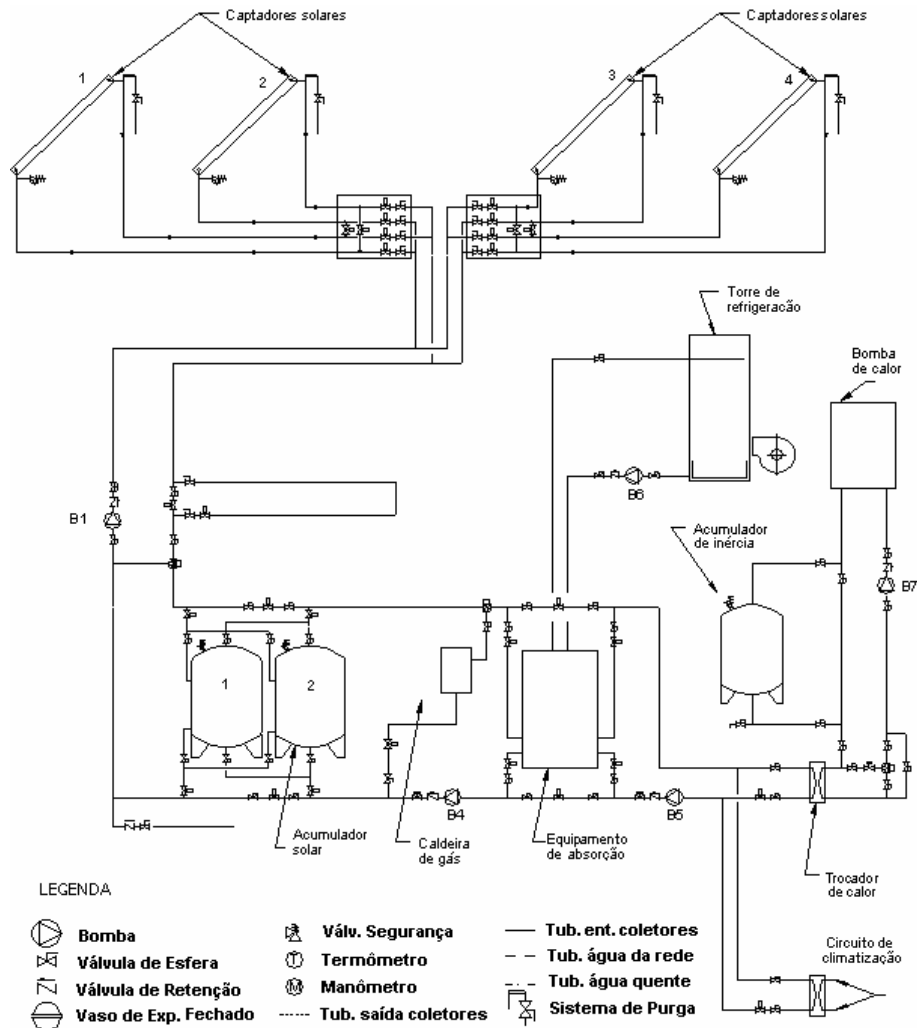


Figura 5.17 – Esquema da Planta Solar de Refrigeração.

5.5.2 Constituição

As instalações da Planta Solar de Climatização são constituídas de um sistema de captação de energia solar, um sistema de acumulação da água aquecida, um sistema de energia auxiliar, uma torre de resfriamento, um simulador de carga e uma máquina de absorção, além de diversos outros acessórios.

• Sistema de Captação

Os coletores solares, constituídos por placas de mais de 150 m², são os encarregados de fornecer a energia necessária para o processo de climatização. O sistema de captação é formado por quatro campos de coletores solares, orientados ao sul e com

uma inclinação de 30° em relação à horizontal. Desta forma maximiza-se o rendimento nos meses de verão, quando é maior a demanda energética da instalação.



Figura 5.18 – Coletores Solares.

- **Sistema de Acumulação**

Para acumular a energia excedente, para sua posterior utilização em momentos de menor incidência de energia solar, dispõem-se de dois depósitos de 2.500 litros, dotados de isolamento térmico.



Figura 5.19 – Acumuladores de Água.

- **Sistema de Energia Auxiliar**

Quando a energia fornecida pelos coletores solares é insuficiente, a instalação conta com um fornecimento complementar de energia, que consiste numa caldeira de gás natural de 60 kW de potência nominal. Esta caldeira conta em seu interior com um controle de temperatura por termostato.



Figura 5.20 – Caldeira de Gás.

- **Torre de Resfriamento**

Consiste num trocador de calor contra-corrente de água-ar, conseguindo-se a eliminação de calor mediante a evaporação da água em contato com o ar do exterior. Devido a esta evaporação, é necessário repor a água de forma a manter a vazão constante.



Figura 5.21 – Torre de Resfriamento.

- **Simulador de Carga**

Responsável pela simulação dos modos de funcionamento, permitindo o controle da demanda de energia. Formado por uma bomba de calor, a qual proporciona frio ou calor dependendo da modalidade de condicionamento de ar a simular. A bomba de calor tem uma potência nominal de 54 kW para a produção de calor e 48 kW para o frio. Apresenta, ainda, um depósito acumulador de inércia de 1000 litros.



Figura 5.22 – Bomba de Calor.

- **Máquina de Absorção**

Encarregada da produção de frio, apresenta uma potência frigorífica nominal de 35 kW. Funciona com fornecimento de uma vazão de 2,38 L/s de água quente a uma temperatura entre 75 e 100 °C ao gerador de vapor, obtendo-se uma vazão de 1,67 L/s de água fria entre 7 e 12 °C. Utiliza água como fluido refrigerante e uma solução aquosa de brometo de lítio como fluido absorvente.



Figura 5.23 – Máquina de Absorção.

5.5.3 Funcionamento

A água que foi aquecida pelo sistema de captação é bombeada para os acumuladores e, juntamente com a água proveniente da caldeira chega à máquina de absorção. O sistema de absorção funciona baseado em quatro ciclos: **Geração:** a água quente provoca a ebulição da solução de brometo de lítio gerando vapor d'água (fluido refrigerante) e solução concentrada do fluido absorvente (LiBr-H₂O). **Condensação:** o vapor d'água dirige-se ao condensador onde é condensado pela ação da água proveniente da torre de resfriamento perdendo, portanto, calor latente de condensação. **Evaporação:** a água condensada volta a vaporizar-se ao passar por uma válvula de expansão chegando ao evaporador extraíndo do ambiente calor latente de vaporização. **Absorção:** a solução concentrada de brometo de lítio absorve, então, o vapor baixando sua pressão, o calor latente de condensação é cedido à água de resfriamento que passa por serpentinas, fechando, assim, o ciclo ilustrado na Figura 5.24.




Figura 5.24 – Sistema de Refrigeração por Absorção.

O calor absorvido pelo evaporador é proveniente do ambiente que se deseja climatizar (sala *ARPA* da *Escuela Superior de Ingenieros*) ou do simulador de carga quando se deseja realizar ensaios com grandes variações de condições ambientais sem causar desconforto nos usuários.

5.5.4 Operação

O funcionamento da instalação é mantido por um duplo sistema de controle, um constituído por elementos convencionais num painel elétrico que possibilita seu acionamento manual e outro mediante o *SCADA* (*Supervisory Control And Data Acquisition*) CUBE da Siemens, instalado num computador padrão IBM-PC do laboratório do *Departamento de Ingeniería de Sistemas e Automática*. Este sistema é constituído por uma rede ARC-NET à que estão conectados a estação de trabalho e o *PMC* (*Programmable Multi-Function Controller*) PC16. O sistema se completa com uma rede REMOTA I/O que conecta o *PMC* com os *racks* de E/S situados em campo, como ilustrado na Figura 5.25.




Figura 5.25 – Esquema do Sistema de Controle.

O *PMC CP16* é o centro de controle automático da instalação. É o módulo encarregado do controle do processo, é capaz de resolver de maneira coordenada todos os problemas integrados na regulação e manipulação da instalação, aquisição e tratamento dos sinais analógicos, seqüenciamento, cálculo matemático, etc.

Além de todos os equipamentos relacionados, a planta conta ainda com farta instrumentação (medição de vazão, temperatura, pressão, radiação, etc.) estabelecida para possibilitar uma adequada monitoração da instalação. Conta, ainda, com elementos atuadores como válvulas solenóide, válvulas proporcionais, e bombas acionadas através de conversores de frequência.

A operação da Planta Solar de Climatização, além do acionamentos dos diversos equipamentos, tem como particular importância o controle da temperatura de saída dos coletores solares que possibilita uma redução no consumo de gás da caldeira e do controle da temperatura de entrada do gerador de vapor que permite a otimização do funcionamento da máquina de absorção mantendo a temperatura dentro da faixa aceitável de operação deste equipamento (75-100°C).

Controle da temperatura de saída dos coletores solares

Este é realizado pela ação sobre a válvula de três vias VM1 (uma entrada e duas saídas) responsável pela recirculação de água pelos coletores. VM1 estando totalmente fechada, toda a água recircula pelos coletores, o que faz com que sua temperatura aumente, enquanto que, VM1 totalmente aberta faz com que toda a água vá para os acumuladores. Conforme a posição de VM1 a água que passa pelos coletores é uma mistura entre a água que está nos acumuladores e aquela que vem dos próprios coletores solares.

Controle da temperatura de entrada do gerador de vapor

Efetuada através da válvula de três vias VM3 (duas entradas e uma saída) que promove uma mistura entre a água que vem dos coletores com aquela que vem da caldeira. VM3 estando totalmente fechada, toda a água da caldeira vai para o gerador de vapor, enquanto que, VM3 totalmente aberta faz com que toda a água dos coletores vá para a entrada do gerador de vapor (Nuñez-Reyes e Payseo, 2003).

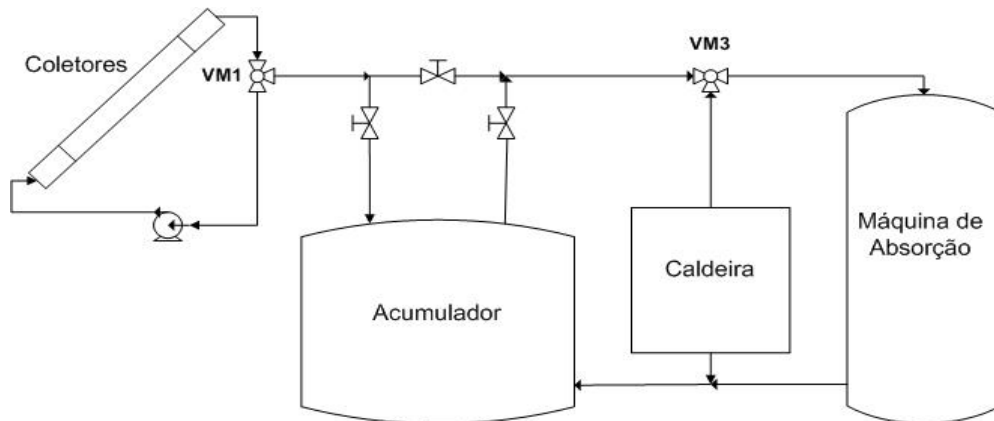


Figura 5.26 – Esquema Simplificado das Malhas de Controle.

A Figura 5.27 mostra uma tela do SCADA que permite acompanhar a evolução das variáveis mais importantes que afetam ao processo. Pode-se, também, acessar outras telas onde é possível programar ensaios utilizando diversos tipos de controladores.




Figura 5.27 – Tela do Supervisório da Planta Solar.

Para simplificar o acesso à Planta Solar de Climatização na realização de ensaios de identificação e controle foi desenvolvido o sistema *NEOxITE* (*Next Generation Open Control System Internet Ready*) uma comunicação via padrão *OPC* (*OLE for Process Control; OLE - Object Linking and Embedding*). Este sistema, ilustrado na Figura 5.28, permite a implementação de estratégias de controle sem a necessidade de utilização do software de programação do supervisor CUBE, possibilitando diretamente o uso de MatLab™/Simulink.

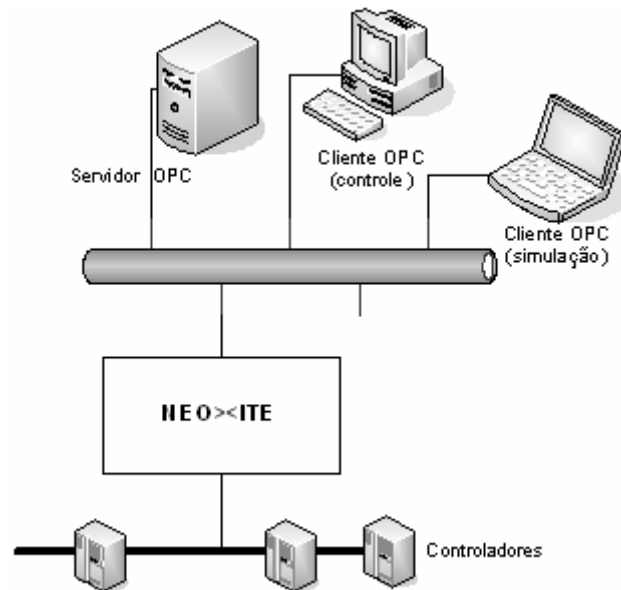


Figura 5.28 – Sistema de Controle via *OPC*.

5.5.5 Resultados Experimentais

Apesar da literatura apresentar algumas aplicações bem sucedidas de controle preditivo baseado em modelos lineares para a Planta Solar de Climatização (Scheffer-Dutra *et al.*, 2002; Pareja, 2003; Núñez-Reyes *et al.*, 2005) procurou-se, neste trabalho, a obtenção de um modelo *SISO* não-linear baseado no modelo de Hammerstein, etapa até então não explorada, com o objetivo de representar melhor as características da planta e, assim, viabilizar melhores resultados do ponto de vista de controle das variáveis envolvidas.

Devido a dificuldades operacionais foram obtidos resultados experimentais somente relacionados ao sistema de controle da temperatura de saída dos coletores solares. Nesta malha o objetivo de controle é posicionar a válvula de três vias VM1 de forma a manter a temperatura da água na saída dos coletores solares num valor desejado.

Pela observação da planta e estudo de trabalhos anteriores pode-se notar que a temperatura de saída dos coletores sofre influência de diversas variáveis: vazão da bomba, condições ambientais (temperatura, umidade, ventos), temperatura da água armazenada nos acumuladores, posição da válvula VM1 e a radiação solar incidentes nos coletores. Baseado em pesquisas anteriores foi adotado um intervalo de amostragem de 10 segundos para a realização dos ensaios de identificação e controle.

A Figura 5.29 permite observar a influência da posição da válvula VM1 na temperatura de saída dos coletores solares, conforme a válvula é fechada e a água recircula, sua temperatura aumenta. A abertura da válvula provoca o comportamento inverso visto que da água nos acumuladores encontra-se a uma temperatura mais baixa que aquela nos coletores.

Por ser a fonte primária de energia da instalação, a influência da radiação solar na temperatura de saída dos coletores solares é mais evidente, quanto maior a incidência de radiação solar, maior a temperatura da água, Figura 5.30. Na ausência de nebulosidade a hora do dia torna-se o único parâmetro de influência nesta variável tornando-a perfeitamente previsível.




Figura 5.29 – Temperatura na Saída dos Coletores X Posição de VM1.




Figura 5.30 – Temperatura X Radiação num Dia de Céu Limpo.

Na presença de nuvens, no entanto, a radiação solar apresenta um comportamento irregular conforme ilustrado na Figura 5.31.




Figura 5.31 – Temperatura X Radiação num Dia de Céu Nebuloso.

Outra observação importante realizada a partir destes ensaios preliminares é em relação ao relevante atraso de transporte tanto em relação ao posicionamento da válvula como da radiação solar em relação à temperatura de saída dos coletores.

Como o objetivo de obter um modelo *SISO* simplificado optou-se por desprezar a influência da temperatura ambiente e utilizar vazão constante (plena carga) da bomba. Inicialmente, os efeitos da temperatura da água contida nos acumuladores e da variação da radiação solar também foram desconsiderados por apresentarem variação lenta.

A partir do ensaio ilustrado pela Figura 5.32 e, baseado na análise do teste DR ilustrado na Figura 5.33, optou-se por utilizar um modelo de primeira ordem. Uma não-linearidade de ordem $m = 3$ foi escolhida por tentativas, visto a dificuldade em se obter a curva estática da planta. Uma parcela dos dados foi utilizada para realizar a estimação dos parâmetros ($SSE = 0.0002116$ e $R^2 = 0.9989$) enquanto que outra parcela para a sua validação ($SSE = 0.0001349$ e $R^2 = 0.9979$).




Figura 5.32 – Dados do Ensaio para Identificação.

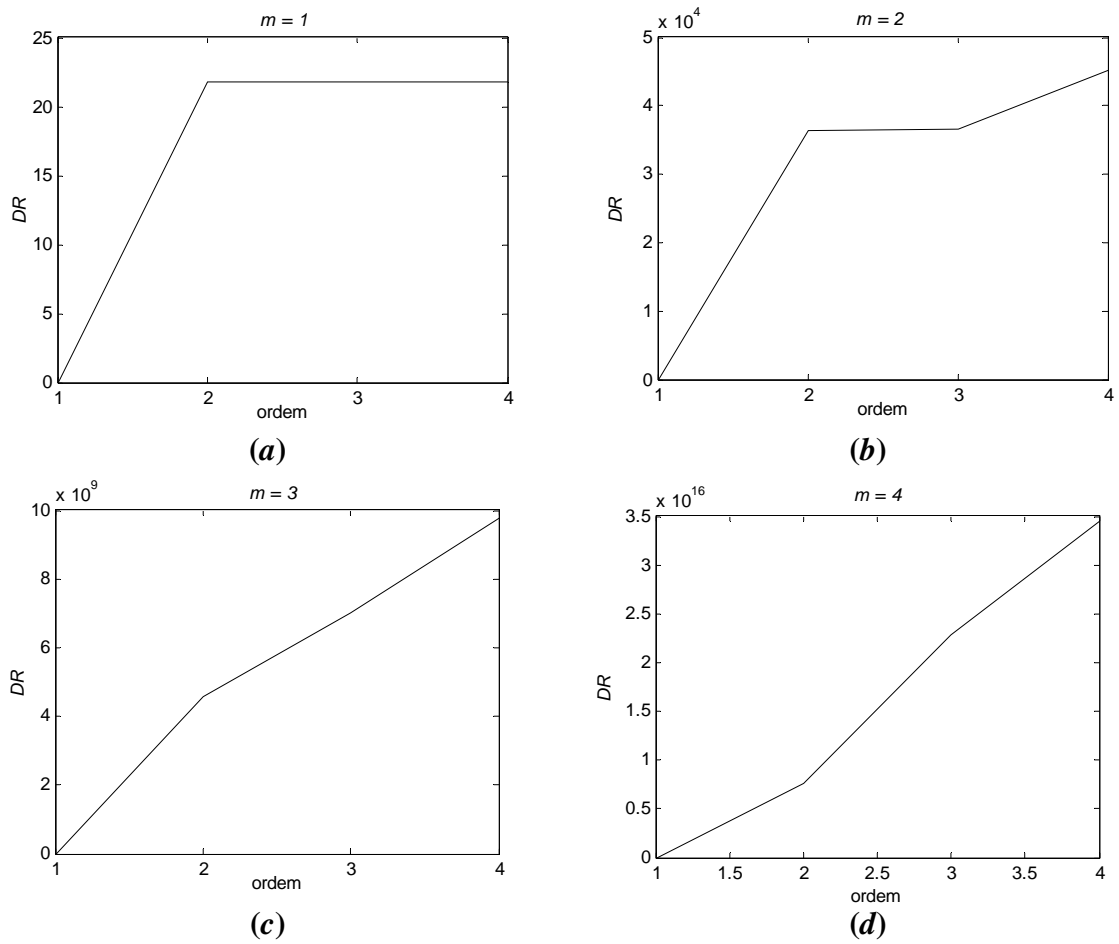


Figura 5.33 – Teste DR para a Planta Solar.

A Figura 5.34 apresenta os sinais medidos e estimados praticamente coincidentes levando a crer que o modelo obtido representa bem a planta em estudo.




Figura 5.34 – Identificação e Validação do Modelo de Hammerstein.

Portanto, neste primeiro experimento visando identificação, o modelo de Hammerstein, obtido através do Método de Boutayeb descrito no capítulo 3, para a representação da temperatura de saída dos acumuladores em relação à abertura da válvula VM1 foi

$$y(t) = 0.9795y(t-1) + 0.02565x(t-18) \quad (5.11)$$

$$x(t) = u(t) - 0.1592u^2(t) - 0.01163u^3(t) \quad (5.12)$$

onde $y(t)$ é a temperatura de saída dos coletores solares em $^{\circ}\text{C}$, $u(t)$ é a abertura da válvula VM1 (0 a 100%) e $x(t)$ é uma pseudo-saída não mensurável. Destaca-se para o modelo obtido a existência de um atraso de transporte de 18 períodos de amostragem (três minutos) considerando os ensaios com a bomba operando à plena carga.

Dando início aos experimentos de controle preditivo, os maus resultados obtidos apontaram a possibilidade do modelo não ser representativo da planta sendo necessária à obtenção de um segundo modelo. Dada a importância da radiação solar, por ser a fonte

primária de energia do processo, decidiu-se por sua inclusão no modelo na forma de uma perturbação mensurável.




Figura 5.35 – Influência da Radiação Solar na Temperatura.

O ensaio ilustrado na Figura 5.35 foi realizado posicionando a válvula de três vias VM1 em 50% e mantendo-a fixa ao longo do tempo de maneira a obter a influência apenas da variação da radiação solar sobre a temperatura de saída dos coletores. Para representar esta relação utilizou-se um modelo linear de primeira ordem, por simplicidade. Desta maneira, o novo modelo está representado pela equação (5.13) pela superposição dos efeitos da abertura da válvula VM1 e da incidência de radiação solar.

$$y(t) = 0.9795y(t-1) + 0.02565x(t-18) + 0.00026562v(t-4) \quad (5.13)$$

onde $v(t)$ representa a radiação solar em W/m^2 , incluída no modelo como uma perturbação mensurável.

Pode-se observar que o atraso que se manifesta da variação da radiação solar em relação à temperatura de saída dos coletores é de 4 períodos de amostragem (40 segundos).

Nos primeiros ensaios de controle realizados foi utilizado o controlador preditivo generalizado baseado no modelo de Hammerstein (*HGPC*) embora ainda sem considerar a

presença de perturbações mensuráveis. Depois de diversas tentativas a sintonia escolhida foi horizonte de saída $N_2 = 20$, horizonte de controle $N_u = 3$ ponderação do esforço de controle $\Lambda = 0.01$. O ensaio ilustrado na Figura 5.36 mostra o comportamento do sistema com diversas variações de *setpoint*. A saída apresenta um comportamento oscilatório embora sempre indo ao encontro da referência definida. Ao final do ensaio com a passagem de uma nuvem e, em seguida, pela redução da radiação solar função do horário, torna-se impossível manter a temperatura, ocasião na qual a válvula VM1 encontra-se totalmente fechada.

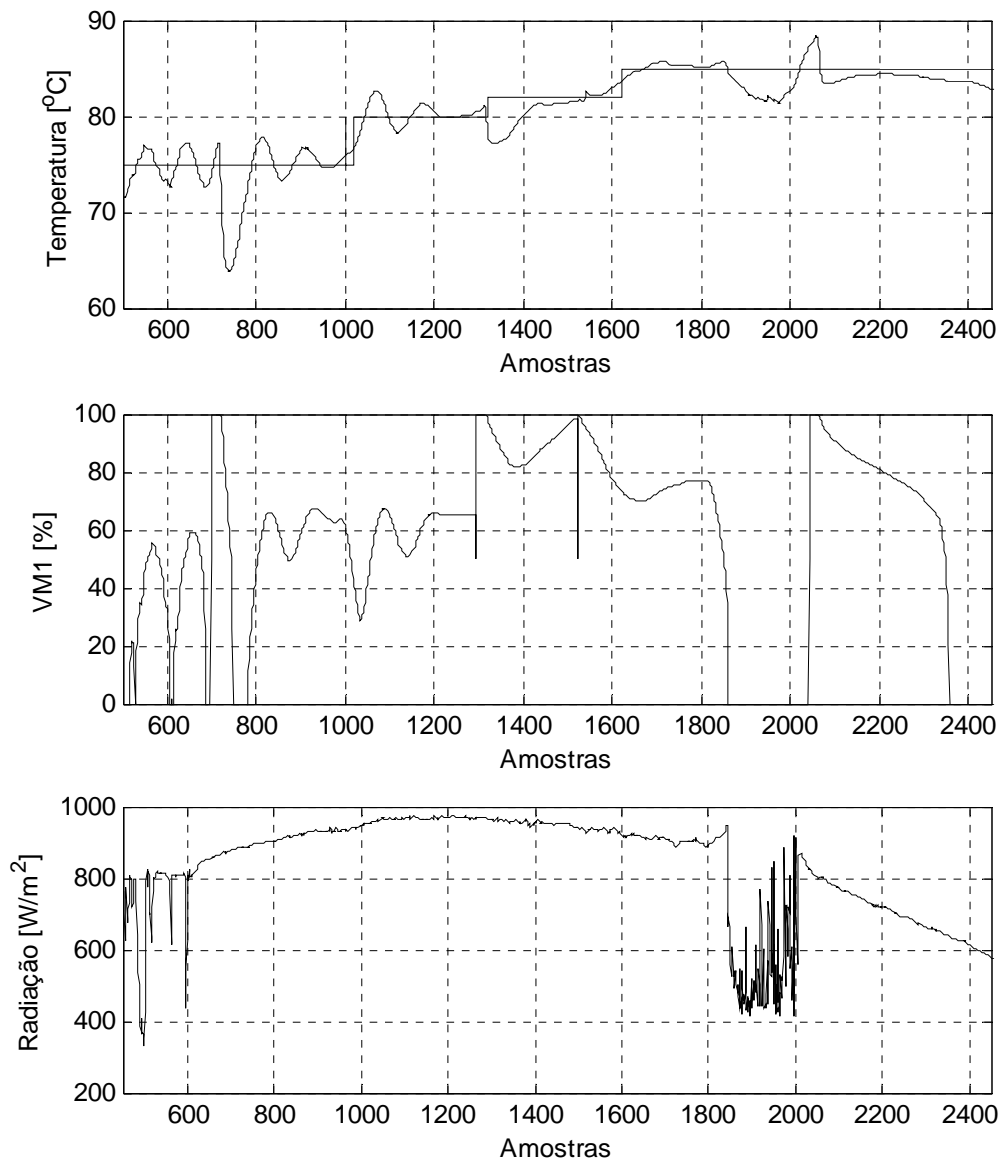


Figura 5.36 – Ensaio com o *HGPC* (nebulosidade, $N_2 = 20$; $N_u = 3$; $\Lambda = 0.01$).

Nos ensaios de controle subsequentes foi utilizado o controlador preditivo generalizado baseado no modelo de Hammerstein (*HGPC*) considerando a presença da radiação solar como uma perturbação mensurável.

Na tentativa de obter uma predição da radiação solar foi estabelecido um modelo da mesma em função da hora do dia. A equação representa um polinômio que foi ajustado à curva que representa a radiação solar num dia de céu claro de verão, válido para o período entre 10h e 18h.

$$Rad_{calc}(t) = 291.8 + 0.8t - 0.0002t^2 - 0,2.10^{-8}t^3 \quad (5.14)$$

onde Rad_{calc} é o valor calculado para a radiação solar e t é instante de tempo em número de amostras considerando o ensaio iniciado as 10h.




Figura 5.37 – Estimação da Radiação Solar.

Para contemplar os dias onde as nuvens estão presentes foi adotado como valor estimado para a radiação solar o valor calculado através do polinômio da equação (5.14) e o último valor medido ponderados por um filtro na forma

$$Rad_{est}(t+k) = f.Rad_{calc}(t+k) + (1-f).Rad_{med}(t) \quad (5.15)$$

onde Rad_{est} é o valor estimado para a radiação solar, Rad_{med} é o valor medido, f é um fator de filtro que faz a ponderação entre o valor calculado e o último valor medido.

Esta estimativa para a radiação solar pode ser observada para um dia típico com nuvens e uma predição de 25 passos à frente e um fator de filtro de 0.10 na Figura 5.38.




Figura 5.38 – Predição da Radiação Solar.

A Figura 5.38 permite observar a proximidade entre os valores do preditor e a evolução real da radiação solar mesmo quando esta apresenta variações causadas pela nebulosidade tornando, assim, o modelo da planta mais confiável.

Para o ensaio ilustrado na Figura 5.39 a sintonia empregada foi horizonte de saída $N_2 = 20$, horizonte de controle $N_u = 3$ ponderação do esforço de controle $\Lambda = 0.02$ com o *setpoint* assumindo os valores $85^\circ C$ e $90^\circ C$. O comportamento da saída indica a necessidade de melhorar a sintonia do controlador.

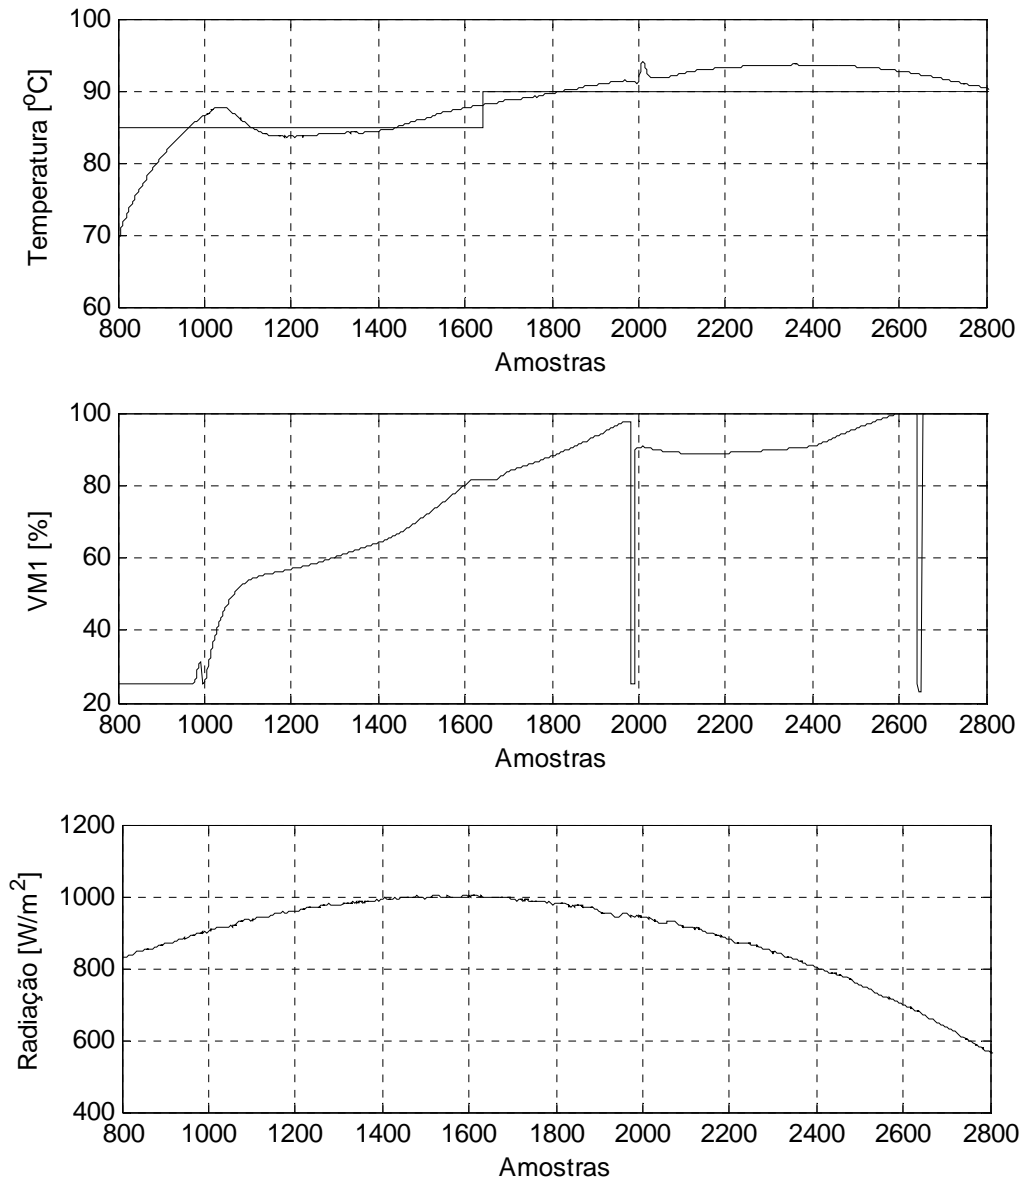


Figura 5.39 – Ensaio com o *HGPC* (céu claro, $N_2 = 20$; $N_u = 3$; $\Lambda = 0.02$).

O ensaio ilustrado na Figura 5.40 utilizou horizonte de saída $N_2 = 25$, horizonte de controle $N_u = 2$ ponderação do esforço de controle $\Lambda = 0.015$ com o *setpoint* assumindo os valores 84°C, 88°C e 90°C. O sistema apresentou um bom desempenho com a referência sendo adequadamente rastreada pela saída, embora, após o instante $t = 2400$ a radiação solar mostra-se insuficiente para manter a temperatura em 90°C.

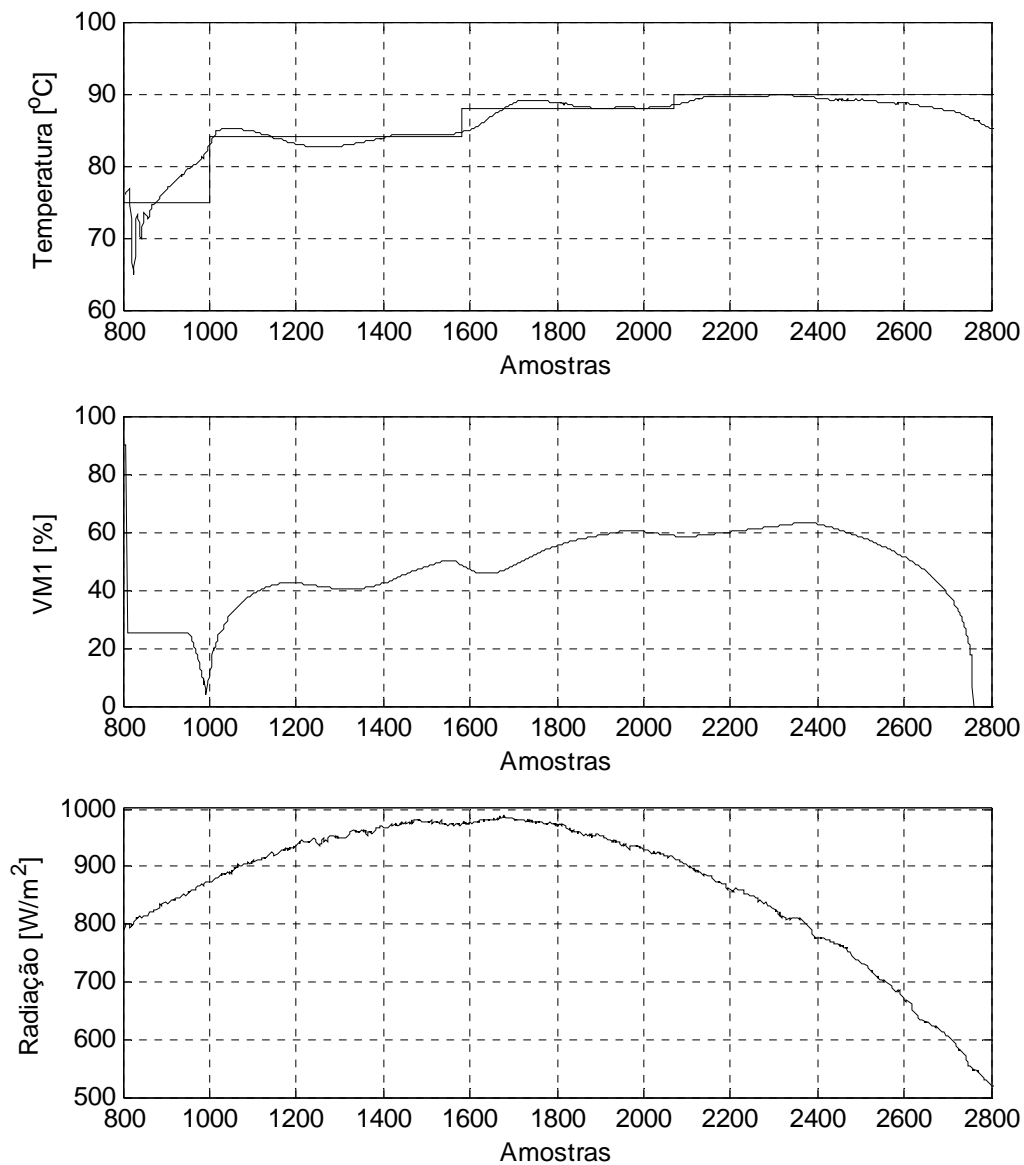


Figura 5.40 – Ensaio com o *HGPC* (céu claro, $N_2 = 25$; $N_u = 2$; $\Lambda = 0.015$).

A sintonia para o ensaio representado pela Figura 5.41 foi horizonte de saída $N_2 = 25$, horizonte de controle $N_u = 2$ ponderação do esforço de controle $\Lambda = 0.015$. O ensaio ilustrado na Figura 5.41 apresenta o comportamento do sistema para o *setpoint* assumindo os valores 83°C, 85°C e 87°C. Embora tenha sido mantida a sintonia do ensaio anterior, a partir do instante $t = 1600$ a presença de nuvens (radiação solar abaixo de 800 W/m²) inviabiliza o bom desempenho do sistema, tornando-o oscilatório.

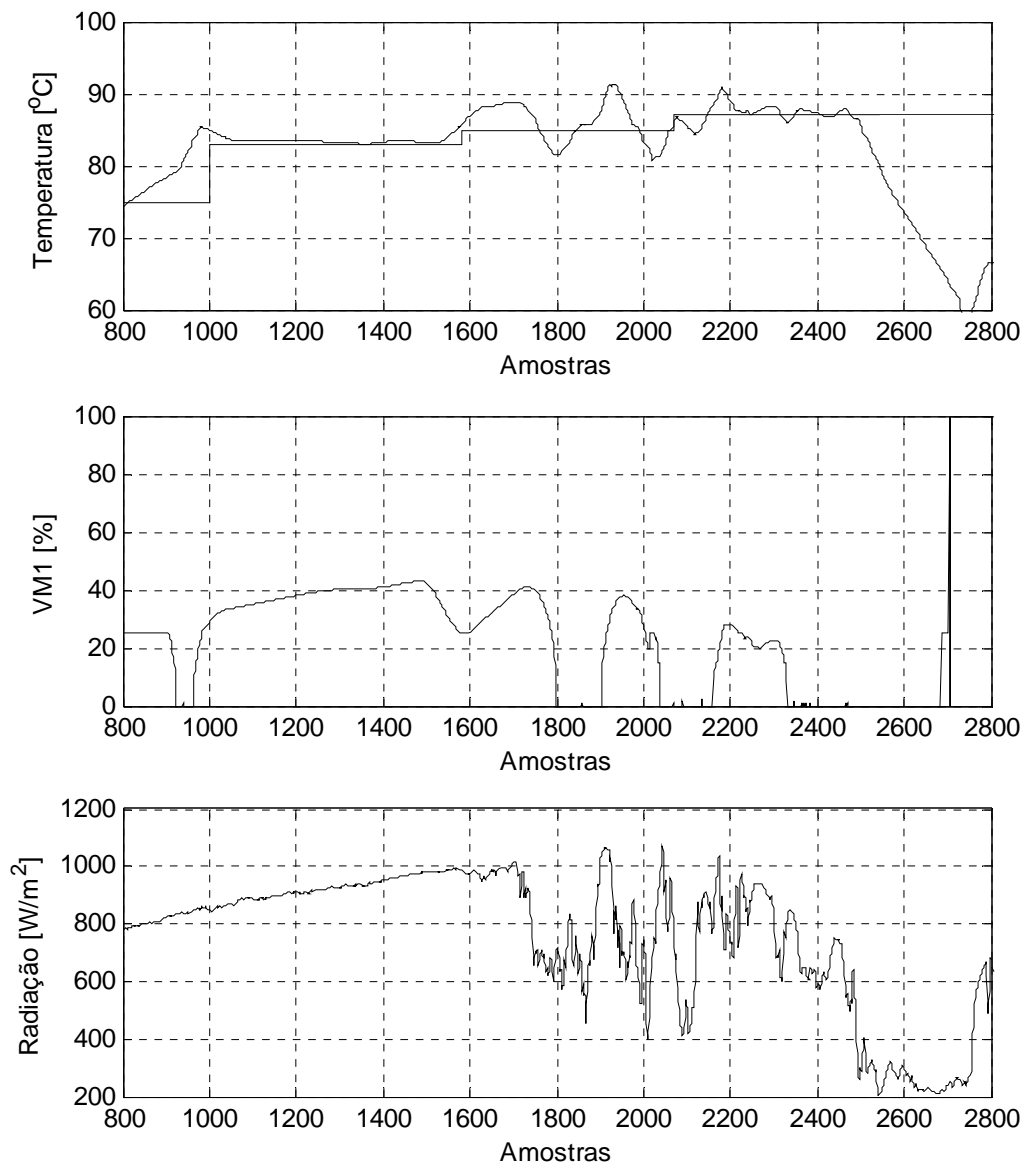


Figura 5.41 – Ensaio com o *HGPC* (nebulosidade, $N_2 = 25$; $N_u = 2$; $\Lambda = 0.015$).

Os resultados obtidos apontam um bom desempenho do controlador *HGPC* aplicado à Planta Solar de Climatização, embora a malha de controle de estudo apresente algumas limitações de ordem operacional das quais se destacam: a incapacidade de compensar grandes perturbações na radiação solar; limitações quanto à faixa de operação função da temperatura da água que se encontra nos acumuladores; a variação dos parâmetros da planta em função das condições climáticas.

5.6 CONCLUSÃO

Este capítulo apresentou diversos exemplos de simulação contemplando aplicações de estratégia de modelagem, identificação e controle baseados no modelo de Hammerstein.

A aplicação de algumas das técnicas de identificação foi realizada sobre um processo com saturação na entrada, apresentando desempenho adequado.

Estratégias para resolver o problema da multiplicidade do sinal de controle ótimo para controladores preditivos baseados no modelo de Hammerstein foram aplicadas sobre o modelo de um trocador de calor e seu desempenho foi comparado. A técnica proposta, baseada em uma aproximação por série de Taylor, apresentou desempenho adequado, comparável àquelas encontradas na literatura.

Outro estudo de simulação foi feito em relação a um reator *CSTR* em identificação e controle preditivo onde ficou claro que o modelo de Hammerstein possui limitações em relação a sua capacidade de representar não-linearidades de processos complexos.

A implementação prática na planta solar de climatização da *Escuela Superior de Ingenieros da Universidad de Sevilla* (Sevilla, Espanha) foi desenvolvida no estágio realizado no período de outubro de 2003 a setembro de 2004. Esta atividade mostrou-se bastante desafiadora por sua complexidade de operação e suas características peculiares: grandes perturbações no sistema; fortes restrições de amplitude e velocidade nas variáveis envolvidas; atraso de transporte. Apesar das dificuldades encontradas o desempenho do sistema de controle foi satisfatório e os modelos obtidos mostraram-se representativos.

As principais contribuições deste capítulo são: *i*) a demonstração através de estudos de simulação da eficácia das técnicas de seleção de ordem dos modelos de Hammerstein na representação de processos não-lineares; *ii*) demonstração das técnicas de identificação para o modelo de Hammerstein e comprovação que a técnica dos Mínimos Quadrados com Restrições apresenta desempenho similar àquelas estudadas; *iii*) levantamento de um modelo de Hammerstein na representação da Planta Solar de Climatização estudada, sua validação e *iv*) sua aplicação na estratégia de controle preditivo baseado com perturbações mensuráveis (*HGPC*) cujo desenvolvimento foi motivado pelas dificuldades encontradas na aplicação de outras estratégias de controle.

O capítulo 6 apresenta as conclusões deste trabalho, suas principais contribuições, publicações geradas, bem como, as possibilidades de trabalhos futuros.

6. CONCLUSÃO

No capítulo dois foram discutidos os aspectos da modelagem de processos lineares e não-lineares. Os principais tipos de modelos discretos para sistemas *SISO* foram apresentados e suas características fundamentais foram destacadas de forma a permitir a seleção do modelo mais adequado a uma determinada aplicação. Exemplos foram apresentados para caracterizar a forma de representação de cada modelo discreto sendo dada ênfase ao modelo de Hammerstein.

No capítulo três foi discutida a identificação de sistemas não-lineares que possam ser representados pelo modelo de Hammerstein. Técnicas de seleção do modelo e escolha de estrutura foram apresentadas com o objetivo de auxiliar na solução do compromisso entre a complexidade do modelo e a capacidade de representação do processo. Uma extensão do método *DR* foi apresentada para o modelo de Hammerstein. Diversas técnicas de estimação dos parâmetros do modelo de Hammerstein foram apresentadas e uma estratégia baseada no estimador dos mínimos quadrados foi proposta. Algumas estratégias de validação dos modelos obtidos foram discutidas. Exemplos foram apresentados para auxiliar na compreensão das características dos modelos não-lineares estudados.

No capítulo quatro foram apresentadas estratégias de controle preditivo linear e não-linear, mais uma vez sendo enfatizadas aquelas baseadas em modelos não-lineares de Hammerstein. Destacou-se a importância do modelo de Hammerstein que possibilita a implementação de estratégias com solução analítica no caso irrestrito. O caso de multiplicidade no sinal de controle ótimo foi apresentado e uma solução baseada em aproximação por série de Taylor foi proposta. Um estudo de preditores baseados em modelos não-lineares foi apresentado onde, sob uma abordagem *MLC*, foi observada que ocorre uma convergência para a estrutura do modelo de Hammerstein.

No capítulo cinco, diversos exemplos de simulação contemplando aplicações de estratégia de modelagem, identificação e controle baseados no modelo de Hammerstein

foram apresentados. A aplicação de algumas das técnicas de identificação foi realizada sobre um processo com saturação na entrada, apresentando desempenho adequado. Estratégias para resolver o problema da multiplicidade do sinal de controle ótimo para controladores preditivos baseados no modelo de Hammerstein foram aplicadas sobre o modelo de um trocador de calor e seu desempenho foi comparado. A técnica proposta baseada em uma aproximação por série de Taylor apresentou desempenho adequado. Outro estudo de simulação foi feito em relação a um reator *CSTR* de identificação e controle preditivo onde ficou claro que o modelo de Hammerstein possui limitações em relação à capacidade de representar não-linearidades de processos complexos.

A implementação prática realizada numa planta solar de climatização mostrou-se desafiadora pela complexidade de operação e características peculiares: grandes perturbações no sistema; fortes restrições de amplitude e velocidade nas variáveis envolvidas; atraso de transporte. Foram identificados e validados modelos baseados na estrutura de Hammerstein e a estratégia de controle *HGPC* foi implementada visando controlar uma das malhas da planta solar. Apesar das dificuldades encontradas o desempenho do sistema de controle foi satisfatório e os modelos obtidos mostraram-se representativos.

6.1 CONTRIBUIÇÕES

No **capítulo dois** a principal contribuição foi a generalização dos modelos apresentados e a comparação de sua complexidade visando sua aplicação em modelagem, predição ou controle.

No **capítulo três** as principais contribuições foram a extensão da técnica da Razão entre Determinantes (*DR*) visando a seleção da estrutura para o modelo de Hammerstein bem como a aplicação do algoritmo dos mínimos quadrados (*MQ*) sob restrições visando resolver o problema de redundância dos parâmetros de estimação observado.

No **capítulo quatro** as contribuições foram: o desenvolvimento de um controlador preditivo com perturbações mensuráveis baseado no modelo de Hammerstein (*HGPC*); uma solução proposta para o problema da multiplicidade do sinal de controle ótimo e o estudo de preditores baseados em modelos não-lineares de Volterra, Bilinear e Hammerstein sob a estratégia *MLC*.

No **capítulo cinco** as principais contribuições foram a demonstração através de estudos de simulação da eficácia das técnicas de seleção de ordem dos modelos de

Hammerstein, proposta no capítulo 3, na representação de processos não-lineares; a demonstração das técnicas de identificação para o modelo de Hammerstein e comprovação que a técnica dos Mínimos Quadrados com Restrições apresenta desempenho similar às demais; o levantamento de um modelo de Hammerstein na representação da Planta Solar de Climatização estudada, sua validação e sua aplicação na estratégia de controle preditivo com perturbações mensuráveis (*HGPC*).

6.1.1 Publicações Geradas

Os estudos realizados a partir deste trabalho foram responsáveis direta ou indiretamente pela geração das seguintes publicações:

Capítulo de Livro:

- [1] CALLAI, T.C.; SANTOS, J.E.S.; SUMAR, R.R. e COELHO, A.A.R. “Applying the Potentiality of Using Fuzzy Logic in PID Control Design” em: HOFFMANN, F.; KÖPPEN, M.; KLAWONN, F. e ROY, R. *Soft Computing: Methodologies and Applications*, Berlin, Springer, v. 32, p. 193-204, 2005.

Artigos em Congressos Internacionais:

- [1] CALLAI, T.C.; SANTOS, J.E.S.; SUMAR, R.R. e COELHO, A.A.R. “Applying the Potentiality of Using Fuzzy Logic in PID Control Design”, *8th Online World Conference on Soft Computing in Industrial Applications*, Dortmund, Alemanha, 2003.
- [2] COELHO, A.A.R.; ALMEIDA, O.M.; SUMAR, R.R. e SANTOS, J.E.S. “Evaluation of Three PID Control Conceptions in a Nonlinear Plant”, *IX Reunión de Trabajo em Procesamiento de la Información y Control*, Santa Fe, Argentina, p. 294-299, 2001.
- [3] COELHO, A.A.R.; ALMEIDA, O.M.; SUMAR, R.R. e SANTOS, J.E.S. “Learning Lab for Understanding Control Theory of Signal and Linear Systems”, *40th IEEE Conference on Decision and Control*, Orlando, EUA, p. 3218-3223, 2001.

Artigos em Congressos Nacionais:

- [1] SANTOS, J.E.S.; SUMAR, R.R. e COELHO, A.A.R. “Uma Solução para a Multiplicidade da Lei de Controle Preditivo para o Modelo de Hammerstein”, *XV Congresso Brasileiro de Automática*, Gramado, RS, 2004.
- [2] COELHO, A.A.R.; SUMAR, R.R. e SANTOS, J.E.S. “Experimental Evaluation of Two Fuzzy Variable Structure Control Algorithms”, *VI Simpósio Brasileiro de Automação Inteligente*, Bauru, SP, p. 911-916, 2003.
- [3] COELHO, A.A.R. e SANTOS, J.E.S. “Identificação e Controle Preditivo para o Modelo de Hammerstein: Abordagem Não-Paramétrica”, *XIV Congresso Brasileiro de Automática*, Natal, RN, p. 2810-2815, 2002.
- [4] SUMAR, R.R.; COELHO, A.A.R.; ALMEIDA, O.M. e SANTOS, J.E.S. “PID Dead-Time Control Conceptions”, *XIV Congresso Brasileiro de Automática*, Natal, RN, p. 2945-2950, 2002. [5] ALMEIDA, O.M.; SANTOS, J.E.S.; SUMAR, R.R. e COELHO, A.A.R. “Controle PID Avançado: Técnicas Preditiva e Nebulosa”, *XIV Congresso Brasileiro de Automática*, Natal, RN, p. 2999-3004, 2002.
- [6] COELHO, A.A.R.; SUMAR, R.R.; SANTOS, J.E.S. e ALMEIDA, O.M. “An Experimental Comparative Study of PID Control Methods”, *V INDUSCON - Conferência de Aplicações Industriais*, Salvador, BA, p. 293-298, 2002.
- [7] ALMEIDA, O.M.; COELHO, A.A.R.; SANTOS, J.E.S. e SUMAR, R.R. “Predictive Fuzzy PID Control: SISO and MIMO Conceptions”. *V INDUSCON - Conferência de Aplicações Industriais*, Salvador, BA, p. 334-339, 2002.
- [8] COELHO, A.A.R.; SANTOS, J.E.S.; ALMEIDA, O.M.; SUMAR, R.R. e CALLAI, T.C. “Identification and Predictive Control for the Hammerstein Model: Nonparametric Approach”, *V INDUSCON - Conferência de Aplicações Industriais*, Salvador, BA, p. 370-374, 2002.
- [9] COELHO, A.A.R.; ALMEIDA, O.M.; SUMAR, R.R. e SANTOS, J.E.S. “Auto-Sintonia de Controladores PID Multivariáveis com Especificações de Margens de Fase e de Ganho”, *V Seminário de Automação de Processos*, Belo Horizonte, MG, p. 59-70, 2001.

6.2 PERSPECTIVAS E TRABALHOS FUTUROS

O desenvolvimento de um trabalho de doutorado ao invés de fornecer todas as respostas, acaba por suscitar novas e instigantes perguntas. Ao invés de terminar, acaba por dar início a um processo contínuo de busca por novos resultados. Sendo assim, o presente trabalho destaca algumas possibilidades de continuidade da pesquisa:

6.2.1 Identificação de Modelos Não-Lineares

- Estender as técnicas de identificação não-linear baseadas no modelo de Hammerstein para outros modelos mais abrangentes como, por exemplo, o de Volterra;
- Utilizar série de funções ortonormais na identificação de modelos de Volterra e Hammerstein.

6.2.2 Controle Preditivo Baseado em Modelos Não-Lineares

- Estender as técnicas de controle preditivo não-linear baseadas no modelo de Hammerstein para outros modelos mais abrangentes como Volterra;
- Implementar na prática as estratégias de identificação e controle preditivo não-linear baseado no modelo de Hammerstein em outras classes de processos visando analisar de dificuldades e propor aperfeiçoamentos nas estratégias existentes;
- Estudar os preditores não-lineares para os modelos de Volterra, Bilinear e Hammerstein visando explorar a característica observada de convergência à estrutura de Hammerstein sob a abordagem *Mean Level Control*;
- Avaliar a robustez em relação às incertezas de modelagem na aplicação de controladores preditivos não-lineares.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABONYI, J.; BABUSKA, R.; AYALA BOTTO, M.; SZEIFERT, F. e NAGY, L. “Identification and Control of Nonlinear Systems Using Fuzzy Hammerstein Models”, *Industrial Engineering Chemical Research*, vol. 39, n. 11, p. 4302-4314, 2000.
- AGUIRRE, L.A. *Introdução à Identificação de Sistemas: Técnicas Lineares e Não-Lineares Aplicadas a Sistemas Reais*, 3ª ed., Editora da UFMG, Belo Horizonte, MG, 2007.
- AGUIRRE, L.A.; COELHO, M.C.S. e CORRÊA, M.V. “On the interpretation and practice of dynamical differences between Hammerstein and Wiener models”, *IEE Proceedings - Control Theory Applications*, vol. 152, n. 4, p. 349-356, 2005.
- AGUIRRE, L.A.; RODRIGUES, G.G. e JÁCOME, C.R.F. “Identificação de Sistemas Não-Lineares Utilizando Modelos NARMAX Polinomiais – Uma Revisão e Novos Resultados”, *SBA Controle & Automação*, vol. 9, n. 2, p. 90-106, 1998.
- AL-DUWAISH, H. e NAEEM, W. “Nonlinear Model Predictive Control of Hammerstein and Wiener Models Using Genetic Algorithms”, *Proc. IEEE Conference on Control Applications*, México, p. 465-469, 2001.
- AL-DUWAISH, H. e KARIM, M.N. “A New Method for the Identification of Hammerstein Model”, *Automatica*, vol. 33, n. 10, p. 1871-1875, 1997.
- AL-SEYAB, R.K. e CAO Y.. “Nonlinear model predictive control for the ALSTOM gasifier”, *Journal of Process Control*, vol. 16, n. 8, p. 795-808, 2006.
- ÅSTRÖM, K.J. e WITTENMARK, B. “*Adaptive Control*”, Addison-Wesley, New York, 1995.
- ÅSTRÖM, K.J. e WITTENMARK, B. “On Self Regulators”, *Automatica*, vol. 9, n. 2, p. 185-199, 1973.

- AUSLANDER, D.M.; TAKAHASHI, Y. e TOMIZUKA, M. “Direct Digital Process Control: Practice and Algorithms for Microprocessor Application”, *Proceedings of the IEEE*, vol. 66, n. 2, p. 199-208, 1978.
- BAI, E.-W. “Identification of Linear Systems with Hard Input Nonlinearities of Known Structure”, *Automatica*, vol. 38, n. 5, p. 853-860, 2002.
- BANERJEE, P. e SHAH, S.L. “The Role of Signal Processing Methods in the Robust Design of Predictive Control”, *Automatica*, vol. 31, n. 5, p. 681-695, 1995.
- BARS, R. e HABER, R. “Weighted One-step-ahead Adaptive Predictive Control of Nonlinear Processes”, *IMACS Symposium Modelling and Control of Technological Processes*, Lille, France, vol. 1, p. 16-21, 1991.
- BAUER, D. e NINNESS, B. “Asymptotic Properties of Hammerstein Model Estimates”, *Proceedings of 39th Conference on Decision and Control*, Sydney, Austrália, p. 2855-2860, 2000.
- BEQUETTE, B.W. “Nonlinear Control of Chemical Processes”, *Industrial Engineering Chemical Research*, vol. 30, n. 7, p. 1391-1413, 1991.
- BITMEAD, R. R.; GEVERS, M. e WERT, V. *Adaptive Optimal Control - The Thinking Man's GPC*, Prentice-Hall, Englewood Cliffs, NJ, 1991.
- BOUTAYEB, M.; RAFARALAHY, H. e DAROUACH, M. “A Robust and Recursive Identification Method for the Hammerstein Model”, *Proc. 13th IFAC Triennial World Congress*, San Francisco, EUA, p.447-452, 1996.
- BROSILOW, C. e JOSEPH, B. *Techniques of Model-Based Control*, Prentice-Hall, Upper Saddle River, NJ, 2002.
- CAMACHO, E. F. e BORDONS, C. “Control Predictivo: Pasado, Presente y Futuro”, *Revista Iberoamericana de Automática e Informática Industrial*, vol. 1, n. 3, p. 5-28, 2004.
- CAMACHO, E.F. e BORDONS, C. *Model Predictive Control*, Springer-Verlag, Londres, 1999.
- CHIRAS, N. *Linear and Nonlinear Modelling of Gas Turbine Engines*, Tese de Doutorado, University of Glamorgan, Pontypridd, Reino Unido, 2002.
- CLARKE, D.W. “Designing Robustness into Predictive Control”, *IEE Colloquium on Industrial Applications of Model Based Predictive Control*, p. 6/1-6/4, 1991.

- CLARKE, D.W. e GAWTHROP, P.J. “Self-Tuning Controller”, *IEE Proceedings*, vol.122, n. 9, p. 929-934, 1975.
- CLARKE, D.W.; MOHTADI, C. e TUFFS, P.S. “Generalized Predictive Control - Part I. The Basic Algorithm”, *Automatica*, vol. 23, n. 2, p. 137-148, 1987a.
- CLARKE, D.W.; MOHTADI, C. e TUFFS, P.S. “Generalized Predictive Control - Part II. Extensions and Interpretations”, *Automatica*, vol. 23, n. 2, p. 149-160, 1987b.
- CLARKE, D.W. e MOHTADI, C. “Properties of Generalized Predictive Control”, *Automatica*, vol. 25, n. 6, p. 859-875, 1989.
- CLARKE, D.W. e ZHANG, L. “Long-Range Predictive Control Using Weighting-Sequence Models”, *IEE Proceedings Part D*, vol. 134, n. 3, p. 187-195, 1987.
- COELHO, A.A.R. e COELHO, L.S. *Identificação de Sistemas Dinâmicos Lineares*, Editora da UFSC, Florianópolis, SC, 2004.
- COELHO, A.A.R. e SANTOS, J.E.S. “Identificação e Controle Preditivo para o Modelo de Hammerstein: Abordagem Não-Paramétrica”, *XIV Congresso Brasileiro de Automática*, Natal, RN, p. 2810-2815, 2002.
- COELHO, A.A.R.; SANTOS, J.E.S.; ALMEIDA, O.M.; SUMAR, R.R. e CALLAI, T.C. “Identification and Predictive Control for the Hammerstein Model: Nonparametric Approach”, *V INDUSCON – Conferência de Aplicações Industriais*, Salvador, BA, p. 370-374, 2002.
- COELHO, L.S. *Identificação e Controle de Processos Multivariáveis Via Metodologias Avançadas e Inteligência Computacional*, Tese de Doutorado, PGEEL / UFSC, Florianópolis, SC, 2000.
- DE KEYSER, R.M.C.; VAN DE VELDE, G.A. e DUMORTIER, F.A.G. “A Comparative Study of Self-adaptive Long-range Predictive Control Methods”, *Automatica*, vol. 24, n. 2, p. 149-163, 1988.
- DORADO, F. e BORDONS, C. “Non-linear control of a gypsum kiln using Volterra models”, *Proc. IEEE Conference on Emerging Technologies and Factory Automation*, vol. 1, p. 470-474, 2003.

- DORMIDO, S.; BERENGUEL, M.; DORMIDO-CANTO, S.; RODRÍGUEZ, F. “Interactive Learning of Introductory Constrained Generalized Predictive Control”, *Proc. 6th IFAC Symposium on Advances in Control Education*, Oulu, Finlândia, p. 201-206, 2003.
- DOYLE III, F.J.; PEARSON, R.K. e OGUNNAIKE, B.A. *Identification and Control Using Volterra Models*, Springer-Verlag, Londres, 2001.
- ESKINAT, E.; JOHNSON, S.H. e LUYBEN, W.L. “Use of Hammerstein Models in Identification of Nonlinear Systems”, *AIChE Journal*, vol. 37, n. 2, p. 255-268, 1991.
- FAVIER, G. e DUBOIS, D. “A Review of k-Step-Ahead Predictors” *Automatica*, vol. 26, n. 1, p. 75-84, 1990.
- FAVIER, G.; KIBANGOU, A.Y. e KHOUAJA, A. “Nonlinear system modelling by means of Volterra models. Approaches for parametric complexity reduction”, *Symposium Techniques Avancées et Stratégies Innovantes en Modélisation et Commande robuste de Processus Industriels*, Martigues, França, 2004.
- FINK, A. e NELLES, O. “Nonlinear Internal Model Control Based on Local Linear Neural Network”, *Proc. IEEE International Conference on Systems, Man and Cybernetics, Tucson*, EUA, vol. 1, p. 117-122, 2001.
- FONTES, A.B., MAITELLI, A.L. e SALAZAR, A.O. “A New Bilinear Generalized Predictive Control Approach: Algorithm and Results”, *Proc. 15th IFAC Triennial World Congress*, Barcelona, Espanha, p. 1390-1395, 2002a.
- FONTES, A.B., MAITELLI, A.L. e SALAZAR, A.O. “Controlador Preditivo Bilinear Aplicado a uma Coluna de Destilação: Algoritmo e Resultados”, *XIV Congresso Brasileiro de Automática*, Natal, RN, p. 2792-2797, 2002b.
- FRUZZETI, K.P.; PALAZOGLU, A. e McDONALD, K.A. “Nonlinear Model Predictive Control Using Hammerstein Models”, *Journal of Process Control*, vol. 7, n. 1, p. 31-41, 1997.
- GAMBOA, J.M. *Aplicación del Controlador OPTIMAX a Una Planta de Producción de Frío Mediante Energía Solar*, Projeto de Fim de Curso, Escuela Superior de Ingenieros Industriales, Universidad de Sevilla, 2004.
- GERKSIC, S.; JURICIC, D.; STRMCNIK, S. e MATKO, D. “Wiener Model Based Nonlinear Predictive Control”, *International Journal of Systems Science*, vol. 31, n. 2, p. 189-202, 2000.

- GIANNAKIS, G.B. e SERPEDIN, E. “A Bibliography on Nonlinear System Identification”, *IEEE Transactions Signal Processing*, vol. 81, n. 3, p. 533-580, 2001.
- GÓMEZ, J.C. e BAEYENS, E. “Hammerstein and Wiener Model Identification using Rational Orthonormal Bases”, *IX RPIC*, Santa Fe, Argentina, p. 19-24, 2001.
- HABER, R. “Predictive Control of Nonlinear Dynamic Processes”, *Applied Mathematics and Computation*, vol. 70, n. 2-3, p. 169-184, 1995.
- HABER, R.; BARS, R. e LENGYEL, O. “Nonlinear Predictive Control Algorithms with Different Input Sequence Parameterizations Applied for the Quadratic Hammerstein and Volterra Models” em ZHENG, A. e ALLGÖWER, F. *Nonlinear Model Predictive Control*, Birkhäuser, Boston, 2000.
- HABER, R.; SCHMITZ, U. e BARS R. “Long-range optimal multi-step-ahead prediction identification for predictive control”, *13th IFAC Symposium on System Identification*, Rotterdam, Holanda, p. 501-506, 2003.
- HACHINO, T. e TAKATA, H. “Structure Selection and Identification of Hammerstein Type Nonlinear System Using Automatic Choosing Function Model and Genetic Algorithm”, *IEICE Transactions on Fundamentals of Electronics*, vol. E88-A, n. 10, p. 254-2547, 2005.
- HAGENBLAD, A. *Aspects of the Identification of Wiener Models*, Thesis, Division of Automatic Control, Department of Electrical Engineering, Linköpings Universitet, Suécia, 1999.
- HAPOGLU, H.; KARACAN, S.; ERTEN KOCA, Z. S. e ALPBAZ, M.. “Parametric and Nonparametric Model Based Control of a Packed Distillation Column”, *Chemical Engineering and Processing*, vol. 40, n. 6, p. 537-544, 2001.
- HENSON, M.A. e SEBORG, D.E. *Nonlinear Process Control*, Prentice-Hall, Upper Saddle River, NJ, 1997.
- HWANG, C.L. e HSU, J.C. “Nonlinear Control Design for a Hammerstein Model System”, *IEE Proceedings - Control Theory Applications*, vol. 142, n. 4, p. 277-285, 1995.
- IORDANOV, P.; RINGWOOD, J. e DOHERTY, S., “Nonlinear Control Design for a Plasma Process”, *Proceedings of 44th Conference on Decision and Control and European Control Conference*, Sevilla, Espanha, p. 2380-2385, 2005.

- ISERMANN, R.; LACHMANN, K.-H. e MATKO, D. *Adaptive Control Systems*, Prentice-Hall, Upper Saddle River, NJ, 1992.
- JOHANSSON, R. *System Modeling & Identification*, Prentice-Hall, Englewood Cliffs, NJ, 1993.
- JUDITSKY, A.; HJALMARSSON, H.; BENVENISTE, A.; DELYON, B.; LJUNG, L.; SJÖBERG, J. e ZHANG, Q. “Nonlinear Black-Box Models in System Identification: Mathematical Foundations”, *Automatica*, vol. 31, n. 12, p. 1725-1750, 1995.
- JURADO, F. “Predictive control of solid oxide fuel cells using fuzzy Hammerstein models” *Journal of Power Sources*, vol. 158, n. 1, p. 245-253, 2006.
- KARA, T. e EKER, İ. “Nonlinear modeling and identification of a DC motor for bidirectional operation with real time experiments”, *International Journal of Energy Conversion and Management*, vol. 45, n. 7-8, p. 1087-1106, 2004.
- KATENDE, E. e JUTAN, A. “Nonlinear Predictive Control of Complex Processes”, *Industrial Engineering Chemical Research*, vol. 35, n. 10, p. 3539-3546, 1996.
- KATENDE, E.; JUTAN, A. e CORLESS, R. “Quadratic Nonlinear Predictive Control”, *Industrial Engineering Chemical Research*, vol. 37, n. 7, p. 2721-2728, 1998.
- KWOK, K.-Y. e SHAH, S.L. “Long-Range Predictive Control with a Terminal Matching Condition”, *Chemical Engineering Science*, vol. 49, n. 9, p. 1287-1300, 1994.
- LJUNG, L. “System Identification” em LEVINE, W.S. *The Control Handbook*, CRC Press & IEEE Press, p. 1033-1054, 1996.
- LJUNG, L. *System Identification – Theory for the User*, 2nd ed., Prentice-Hall, Englewood Cliffs, NJ, 1999.
- LJUNG, L. e GLAD, T. *Modeling of Dynamic Systems*, Prentice-Hall, Englewood Cliffs, NJ, 1994.
- MAHFOUF, M. e LINKENS, D.A. *Generalised Predictive Control and Bioengineering*, Taylor & Francis, Londres, 1998.
- MANER, B.R.; DOYLE III, F.J.; OGUNNAIKE, B.A. e PEARSON, R.K. “A Nonlinear Model Predictive Control Scheme Using Second Order Volterra Models”, *Proc. American Control Conference*, Baltimore, EUA, p. 3253-3257, 1994.

- MARCHI, P.A. *Abordagem Não-Linear para Modelagem e Controle Preditivo: Estudo de Caso*, Dissertação de Mestrado, PGEEL / UFSC, Florianópolis, SC, 1999.
- MAYNE, D. “Nonlinear Model Predictive Control: Challenges and Opportunities” em ZHENG, A. e ALLGÖWER, F. *Nonlinear Model Predictive Control*, Birkhäuser, Boston, 2000.
- MCCANNON, T.E.; GALLAGHER, N.C.; MINOO-HAMEDANI, D. e WISE, G.L. “On the Design of Nonlinear Discrete-Time Predictors”, *IEEE Transactions on Information Theory*, vol. 28, n. 2, p. 366-371, 1982.
- MCINTOSH, A.R., SHAH, S.L. e FISHER, D.G. “Analysis and Tuning of Adaptive Generalized Predictive Control”, *The Canadian Journal of Chemical Engineering*, vol. 69, n. 1, p. 97-110, 1991.
- MENOLD, P.H.; ALLGÖWER, F. e PEARSON, R.K. “Nonlinear Structure Identification of Chemical Process”, *Computers Chemical Engineering*, vol. 21, sup. 1, p. S137-S142, 1997.
- NARENDRA, K.S. e GALLMAN, P.G. “An Iterative Method for the Identification of Nonlinear Systems Using a Hammerstein Model,” *IEEE Transactions Automatic Control*, vol. 11, n. 3, p. 546-550, 1966.
- NINNESS, B. e GIBSON, S. “Quantifying the Accuracy of Hammerstein Model Estimation” *Automatica*, vol. 38, n. 12, p. 2037-2051, 2002.
- NORMEY-RICO, J.E. *Predicción para Control*, Tese de Doutorado, Escuela Superior de Ingenieros, Universidad de Sevilla, Sevilla, Espanha, 1999.
- NORQUAY, S.J.; PALAZOGLU, A. e ROMAGNOLI J.A. “Model Predictive Control Based on Wiener Models”, *Chemical Engineering Science*, vol. 53, n. 1, p. 75-84, 1998.
- NÚÑEZ-REYES, A.; NORMEY-RICO, J.E.; BORDONS, C. e CAMACHO, E.F. “A Smith Predictive Based MPC in a Solar Air Conditioning Plant”, *Journal of Process Control*, vol. 15, n. 1, p. 1-10, 2005.
- NÚÑEZ-REYES A. e PAYSEO, R. “Desarrollo e Integración de Herramientas de Simulación y Control Vía OPC”, *XXIV Jornadas de Automática*, León, Espanha, 2003.
- NÚÑEZ-REYES A.; SCHEFFER-DUTRA, C.B. e BORDONS, C. “Comparison of Different Predictive Controllers with Multi-objective Optimization, Application to an Olive Oil

- Mill”, *Proc. IEEE Conference on Control Applications*, Glasgow, Escócia. p. 1242-1247, 2002.
- OGUNNAIKE, B.A. e RAY, W.H. “*Process Dynamic, Modeling and Control*”, Oxford University Press, New York, 1994.
- PAREJA, F.J. *Control Predictivo de Planta Solar de Climatización*, Projeto de Fim de Curso, Escuela Superior de Ingenieros Industriales, Universidad de Sevilla, 2003.
- PEARSON, R.K. “Selecting Nonlinear Model Structures for Computer Control”, *Journal of Process Control*, vol. 13, n. 1, p. 1-26, 2003.
- PEARSON, R.K. e OGUNNAIKE, B.A. “Nonlinear Process Identification” em HENSON, M.A. e SEBORG, D.E. *Nonlinear Process Control*, Prentice-Hall, Upper Saddle River, NJ, 1997.
- PEARSON, R. K. e POTTMANN, M. “Gray-Box Identification of Block-Oriented Nonlinear Models”, *Journal of Process Control*, vol. 10, n. 4, p. 301-315, 2000.
- PÉREZ, E.; BLASCO, X.; GARCÍA-NIETO, S. e SANCHIS, J. “Diesel Engine Identification and Predictive Control using Wiener and Hammerstein Models”, *Proc. IEEE International Conference on Control Applications*, Munich, Alemanha, p. 2417-2423, 2006.
- PIKE, A.W.; GRIMBLE, M.J.; JOHNSON, M.A., ORDYS, A.W. e SHAKOOR, S. “Predictive Control” em LEVINE, W.S., *The Control Handbook*, CRC Press & IEEE Press, p. 805-814, 1996.
- PRADA, C.; SERRANO, J.; VEGA, P. e PIERA, M.A. “A Comparative Study of DMC and GPC Controllers” em CLARKE, D. W. *Advances in Model-Based Predictive Control*, Oxford Sci. Publication, New York, 1994.
- QIN, S.J. e BADGWELL, T.A. “An Overview of Nonlinear Model Predictive Control Applications” em ZHENG, A. e ALLGÖWER, F. *Nonlinear Model Predictive Control*, Birkhäuser, Boston, 2000.
- QIN, S.J. e BADGWELL, T.A. “A Survey of Industrial Model Predictive Control Technology”, *Control Engineering Practice*, vol. 11, n. 7, p. 733-764, 2003.
- RAWLINGS, J.B. “Tutorial Overview of Model Predictive Control”, *IEEE Control Systems Magazine*, vol. 20, n. 3, p. 38-52, 2000.

- ROSSITER, J.A. “GPC controllers with guaranteed stability and mean-level control of unstable plant”, *34th IEEE Conference on Decision and Control*, Lake Buena Vista, EUA, p. 3579-3580, 1994.
- ROSSITER, J.A.; GOSSNER, J.R.; KOUVARITAKIS, B. “Infinite horizon stable predictive control”, *IEEE Transactions on Automatic Control*, vol. 41, n. 10, p. 1522-1527, 1996.
- ROUX, G.; DAHOU, B. e QUEINNEC, I. “Modelling and Estimation Aspects of Adaptive Predictive Control in a Fermentation Process”, *Control Engineering Practice*, vol. 4, n. 1, p. 55-66, 1996.
- SAHLI, F.M., ABDENNOUR, R.B. e KSOURI, M. “Nonlinear Model-Based Predictive Control Using a Generalised Hammerstein Model and its Application to a Semi-Batch Reactor”, *International Journal of Advanced Manufacturing Technology*, vol. 20, n. 11, p. 844-852, 2002.
- SANTOS, J.E.S. *Critérios de Desempenho e Aspectos de Robustez na Síntese de Controladores Preditivos Adaptativos*, Dissertação de Mestrado, PGEEL / UFSC, Florianópolis, SC, 1998.
- SANTOS, J.E.S.; SUMAR, R.R. e COELHO, A.A.R. “Uma Solução para a Multiplicidade da Lei de Controle Preditivo para o Modelo de Hammerstein”, *XV Congresso Brasileiro de Automática*, Gramado, RS, 2004.
- SANTOS, L.O.; AFONSO, P.A.F.N.A.; CASTRO, J.A.A.M.; OLIVEIRA, N.M.C. e BIEGLER, L.T. “On-line Implementation of Nonlinear MPC: An Experimental Case Study”, *Control Engineering Practice*, vol. 9, n. 8, p. 847-857, 2001.
- SCHEFFER-DUTRA, C.B.; NÚÑEZ-REYES, A. e BORDONS, C. “Controle Preditivo com Restrições Aplicado a Uma Planta Solar de Climatização”, *XIV Congresso Brasileiro de Automática*, Natal, RN, p. 2798-2803, 2002.
- SCHLOTTHAUER, G.; GAMERO, L.G.; TORRES, M.E. e NICOLINI, G.A. “Modeling, identification and nonlinear model predictive control of type I diabetic patient”, *Medical Engineering & Physics*, vol. 28, n. 3, p. 240-250, 2005.
- SISTU, P.B. e BEQUETTE, B.W. “Nonlinear Predictive Control of Uncertain Processes: Application to a CSTR”, *AIChE Journal*, vol. 37, n. 11, p. 1711-1723, 1991.

- SJÖBERG, J.; ZHANG, Q.; LJUNG, L.; BENVENISTE, A.; DELYON, B.; GLORENNEC, P.-Y.; HJALMARSSON, H. e JUDITSKY, A. “Nonlinear Black-Box Modeling in System Identification: a Unified Overview”, *Automatica*, vol. 31, n. 12, p. 1691-1724, 1995.
- SHOOK, D.S.; MOHTADI, C. e SHAH, S.L. “A Control-Relevant Identification Strategy for GPC”, *IEEE Transactions on Automatic Control*, vol. 37, n. 7, p. 975-980, 1992.
- UNBEHAUEN, H. “Some New Trends in Identification and Modeling of Nonlinear Dynamical Systems”, *Applied Mathematics and Computation*, vol. 78, n. 2-3, p. 279-297, 1996.
- VAZ, G.L.F. *Controladores Adaptativos de Variância Mínima e Dahlin: Uma Revisão e Novas Concepções de Projeto*. Dissertação de Mestrado, PGEEL / UFSC, Florianópolis, SC, 1998.
- WELLERS, M. e RAKE, H. “Nonlinear Predictive Control Based on Stable Wiener and Hammerstein Models” em ZHENG, A. e ALLGÖWER, F. *Nonlinear Model Predictive Control*, Birkhäuser, Boston, 2000.
- WELLSTEAD, P.E. e ZARROP, M.B. *Self-Tuning Systems. Control and Signal Processing*, John Wiley & Sons, New York, 1991.
- ZAMBRANO, D. e CAMACHO, E.F. “Application of MPC with Multiple Objective for a Solar Refrigeration Plant”, *Proc. IEEE Conference on Control Applications*, Glasgow, Escócia. p. 1230-1235, 2002.
- ZOU, Z.; DEHONG, Y.; HU, Z.; YU, L.; FENG, W. e GUO, N. “Design and Simulation of Nonlinear Hammerstein Systems Dynamic Matrix Control Algorithm”, *Proceedings of 6th World Congress on Intelligent Control and Automation*, Dalian, China, p. 1981-1985, 2006.
- ZHANG, H.; CHEN, Z.; LI, M.; XIANG, W. e QIN, T. “A Nonlinear Adaptive Predictive Control Algorithm Based on OFS Model” em HUANG, D.; ZHANG, X. E HUANG G. *Advances in Intelligent Computing*, Springer-Verlag, New York, 2005.
- ZHU, Q.M.; WARWICK, K. e DOUCE, J.L. “Adaptive General Predictive Controller for Nonlinear Systems”, *IEE Proceedings Part D*, vol. 138, n. 1, p. 33-40, 1991.
- ZHU, X. e SEBORG, D.E. “Nonlinear Predictive Control Based on Hammerstein Models”, *Proc. 5th International Symposium on Process Systems Engineering*, Kyongju, Coréia do Sul, p. 995-1000, 1994.

Livros Grátis

(<http://www.livrosgratis.com.br>)

Milhares de Livros para Download:

[Baixar livros de Administração](#)

[Baixar livros de Agronomia](#)

[Baixar livros de Arquitetura](#)

[Baixar livros de Artes](#)

[Baixar livros de Astronomia](#)

[Baixar livros de Biologia Geral](#)

[Baixar livros de Ciência da Computação](#)

[Baixar livros de Ciência da Informação](#)

[Baixar livros de Ciência Política](#)

[Baixar livros de Ciências da Saúde](#)

[Baixar livros de Comunicação](#)

[Baixar livros do Conselho Nacional de Educação - CNE](#)

[Baixar livros de Defesa civil](#)

[Baixar livros de Direito](#)

[Baixar livros de Direitos humanos](#)

[Baixar livros de Economia](#)

[Baixar livros de Economia Doméstica](#)

[Baixar livros de Educação](#)

[Baixar livros de Educação - Trânsito](#)

[Baixar livros de Educação Física](#)

[Baixar livros de Engenharia Aeroespacial](#)

[Baixar livros de Farmácia](#)

[Baixar livros de Filosofia](#)

[Baixar livros de Física](#)

[Baixar livros de Geociências](#)

[Baixar livros de Geografia](#)

[Baixar livros de História](#)

[Baixar livros de Línguas](#)

[Baixar livros de Literatura](#)
[Baixar livros de Literatura de Cordel](#)
[Baixar livros de Literatura Infantil](#)
[Baixar livros de Matemática](#)
[Baixar livros de Medicina](#)
[Baixar livros de Medicina Veterinária](#)
[Baixar livros de Meio Ambiente](#)
[Baixar livros de Meteorologia](#)
[Baixar Monografias e TCC](#)
[Baixar livros Multidisciplinar](#)
[Baixar livros de Música](#)
[Baixar livros de Psicologia](#)
[Baixar livros de Química](#)
[Baixar livros de Saúde Coletiva](#)
[Baixar livros de Serviço Social](#)
[Baixar livros de Sociologia](#)
[Baixar livros de Teologia](#)
[Baixar livros de Trabalho](#)
[Baixar livros de Turismo](#)