

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

CONTROLE PREDITIVO MULTI OBJETIVO
PARA PROCESSOS COM ATRASO

Tese submetida à Universidade Federal de Santa Catarina
como requisito parcial à obtenção do grau de
Doutor em Engenharia Elétrica.

CYNTHIA BEATRIZ SCHEFFER DUTRA

Florianópolis, fevereiro de 2003.

CYNTHIA BEATRIZ SCHEFFER DUTRA

CONTROLE PREDITIVO MULTI OBJETIVO
PARA PROCESSOS COM ATRASO

FLORIANÓPOLIS
2003

CONTROLE PREDITIVO MULTIOBJETIVO PARA PROCESSOS COM ATRASO

Cynthia Beatriz Scheffer Dutra

“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.”

Eugênio de Bona Castelan Neto, Dr.
Orientador

Edson Roberto de Pieri, Dr.
Coordenador da Pós-Graduação em Engenharia Elétrica

Banca Examinadora:

Eugênio de Bona Castelan Neto, Dr.
Presidente

Julio Elias Normey Rico, Dr.
Co-orientador

Wagner Caradori do Amaral, Dr.

João Manoel Gomes da Silva Jr., Dr.

Isabelle Queinnec, Dra.

**A meus pais,
por fazerem de mim quem sou.**

**A Carlos,
por seu amor e incentivo.**

Agradecimentos

A Deus, por ter me dado a oportunidade de concluir mais este importante passo em minha vida.

À Universidade Federal de Santa Catarina e à agência CAPES pelo apoio financeiro, em especial por selecionar-me como bolsista para o doutorado sanduíche na Espanha.

Aos professores Eduardo Camacho e Carlos Bordons, do *Departamento de Ingeniería de Sistemas y Automática* (DISA) da *Universidad de Sevilla*, Espanha, pela oportunidade, colaboração e amizade.

A todo o pessoal do DISA da *Universidad de Sevilla*, em especial ao Grupo de Controle Preditivo, por colaborarem nos resultados desta tese não só com recursos, mas também com conhecimentos.

A minhas companheiras de sala Asun e Amparo, porque souberam ser realmente amigas, não só no trabalho, mas no dia-a-dia, e tornaram minha estadia em Sevilha ainda mais agradável.

Ao meu querido Carlos, por amar-me e apoiar-me, estando ao meu lado, incentivando e colaborando para a execução deste trabalho.

A minha família, pelo estímulo, apoio e compreensão. E principalmente, a meus pais, por haverem suportado a distância e perdoado minha ausência em momentos difíceis deste período.

Aos meus orientadores, Eugênio de Bona Castelan Neto e Julio Elias Normey-Rico, pela dedicação, colaboração e preocupação constante, em ajudar-me a alcançar meus objetivos.

Aos demais professores do Departamento de Automação e Sistemas, UFSC, que com suas aulas enriqueceram meus conhecimentos; principalmente ao professor Augusto Bruciapaglia, por seu interesse e carinho.

Aos meus amigos André e Max, companheiros desde a graduação, pelos velhos tempos e pelos bate-papos durante os longos anos percorridos juntos dentro desta universidade.

E a todos, colegas e amigos, que colaboraram com sua preocupação, interesse e ajuda; a quem não posso citar individualmente, mas que não foram, de modo algum, menos importantes para que eu conseguisse chegar a este dia.

Resumo da Tese apresentada à UFSC como requisito parcial
à obtenção do grau de **Doutor em Engenharia Elétrica**.

CONTROLE PREDITIVO MULTIOBJETIVO PARA PROCESSOS COM ATRASO

Cynthia Beatriz Scheffer Dutra

Fevereiro/2003

Orientador: Eugênio de Bona Castelan Neto, Dr.

Co-orientador: Julio Elias Normey-Rico, Dr.

Área de Concentração: Automação e Sistemas.

Palavras-chave: controle preditivo, atraso, restrições, otimização, multiobjetivo.

Número de Páginas: 134.

Esta tese apresenta contribuições para a melhoria da solução do controle de processos com atraso, através de estratégias de controle preditivo baseado no modelo (MPC) que incorporam aspectos como robustez, restrições e otimização multiobjetivo. As contribuições estão relacionadas à duas áreas: (i) controle de processos com atrasos dominantes e (ii) otimização multiobjetivo do controle. Para análise do efeito do atraso no comportamento do sistema em malha fechada, desenvolve-se uma nova formulação do controlador preditivo por matriz dinâmica (DMC), mostrando que este é composto por um controlador primário mais um preditor. Esta formulação permite avaliar analiticamente o efeito do atraso no DMC, comparado a outros controladores MPC, através de índices de robustez. Esta análise possibilita selecionar o algoritmo MPC mais adequado à implementação prática em processos com atraso, especialmente quanto à robustez do controle frente a variações paramétricas na planta. Do ponto de vista da otimização do controle, busca-se desenvolver estratégias de controle preditivo que consideram aspectos econômicos no projeto de controle, além das restrições técnicas e/ou operacionais que habitualmente constam nos requisitos de aplicações reais. As estratégias de controle propostas utilizam um nível supervísório para determinar as referências ótimas de controle para um nível regulatório. O nível supervísório baseia-se em um otimizador de múltiplos objetivos, projetado a partir de regras que integram heurística, lógica e dinâmica do processo por meio de expressões descritas através de lógica proposicional, ou por estruturação formulada através de regras de decisão. As soluções obtidas via otimização multiobjetivo funcionam como referências para o cálculo da lei de controle do algoritmo MPC. Diversas aplicações em plantas piloto e industriais ilustram os resultados obtidos com as diferentes estratégias desenvolvidas.

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

MULTIOBJECTIVE PREDICTIVE CONTROL FOR DEAD-TIME PROCESSES

Cynthia Beatriz Scheffer Dutra

February/2003

Advisor: Eugênio de Bona Castelan Neto, Dr. Eng.

Co-advisor: Julio Elias Normey-Rico, Dr. Eng.

Area of Concentration: Automation and Systems.

Keywords: predictive control, dead-time, constraints, optimization, multiobjective.

Number of Pages: 134.

This thesis presents contributions to improve the solution of dead-time processes control, by strategies for model predictive control (MPC) including aspects such as robustness, constraints and multiobjective optimization. The contributions are related to two areas: (i) control of processes with dominant dead-time and (ii) control multiobjective optimization. To analyze the dead-time effects in closed-loop system, a new formulation of the dynamic matrix controller (DMC) is developed, showing that it is composed by a primary controller plus a predictor. This formulation allows to value the effect of the dead-time in the DMC, compared with others MPC controllers, by robustness indexes. This analysis permits to select the best MPC algorithm to practical implementation in dead-time processes, specially considering the control robustness in case of parametrical uncertainties on the plant. In the control optimization, the purpose is the development of predictive control strategies considering multiple control and economic objectives, besides the technical and/or operational constraints usually in the real applications requirements. The control strategies proposed include a supervisory level to determine the optimal control references, to be used in a regulatory level. The supervisory level is based in a multiobjective optimizator, designed by techniques based on integration of heuristics, logic and process dynamics, using expressions described in propositional logic or structured by decision rules. The solutions obtained by multiobjective optimization works as references in the calculation of the MPC control law. Several applications in pilot and industrial plants show the different strategies results.

Sumário

Lista de Figuras	xvi
Lista de Tabelas	xxi
Nomenclatura e Simbologia	xxiii
1 Introdução	1
1.1 Motivação	2
1.2 Importância da Pesquisa	2
1.3 Estado da Arte em Controle Preditivo	4
1.4 Objetivos	8
1.5 Estrutura da Tese	9
2 O Controle Preditivo Baseado em Modelo	11
2.1 Introdução	12
2.2 Descrição Geral do Algoritmo de Controle do MPC	17
2.3 MPC com Restrições	20

2.3.1	Planejamento das Restrições no MPC	20
2.3.2	Factibilidade	22
2.4	Conclusões	24
3	Controle Preditivo de Processos com Atraso Dominante	25
3.1	Introdução	26
3.2	DMC para Processos com Atraso	28
3.2.1	Representação para Processos Monovariáveis	28
3.2.2	Aplicação à Planta Piloto: Controle de Temperatura	42
3.2.3	Generalização para o Caso Multivariável	45
3.2.4	Aplicação à Planta Solar de Climatização	50
3.3	Conclusões	56
4	Otimização Multiobjetivo em Controle Preditivo de Processos	57
4.1	Introdução	58
4.2	Otimização Multiobjetivo	59
4.3	MPC com Otimização Multiobjetivo	64
4.3.1	MPC com Ponderação de Objetivos	66
4.3.2	MPC com Priorização de Objetivos	66
4.3.3	Aplicação à Planta de Extração de Azeite de Oliva (caso I)	71
4.4	MPC com Priorização Estruturada de Objetivos	79

4.4.1	MPC com Estruturação de Objetivos	81
4.4.2	Aplicação à Planta de Extração de Azeite de Oliva (caso II)	84
4.5	Conclusões	90
5	Considerações Finais	91
5.1	Contribuições	91
5.2	Publicações	93
5.3	Perspectivas	94
A	Algoritmos de Controle Preditivo	95
A.1	Controle por Matriz Dinâmica (DMC)	95
A.1.1	O Algoritmo DMC	95
A.2	Controle Preditivo Generalizado (GPC)	99
A.2.1	O Algoritmo GPC	99
A.3	GPC Baseado no Preditor de Smith (SPGPC)	103
A.3.1	O Algoritmo SPGPC	104
B	Planta Piloto	107
B.1	Descrição da Planta	107
B.2	Identificação do Modelo	110
C	Planta Solar de Climatização	111

C.1	Descrição da Planta	111
C.2	Identificação do Modelo	118
D	Planta de Extração de Azeite de Oliva	121
D.1	Descrição da Planta	121
D.2	Identificação do Modelo	123
D.3	Controle do Processo	125
	Referências Bibliográficas	127

Lista de Figuras

2.1	Diagrama do preditor de Smith.	12
2.2	Estrutura geral do MPC.	17
2.3	Estratégia do algoritmo MPC.	19
3.1	Representação do GPC como controlador primário mais preditor.	27
3.2	Esquema de controle do DMC.	33
3.3	Estrutura de controle equivalente ao DMC.	36
3.4	Robustez do GPC, do SPGPC e do DMC para processos de 1 ^a . ordem com atraso. 40	
3.5	Robustez do GPC, do SPGPC e do DMC para processos de 2 ^a . ordem com atraso. 40	
3.6	Diagrama do trocador de calor da planta piloto.	43
3.7	Resposta do sistema. Caso nominal.	43
3.8	Resposta do sistema. Caso com incertezas.	44
3.9	Resposta do sistema. Caso com incertezas (filtro T).	44
3.10	Diagrama de blocos para o cálculo da predição MIMO.	49
3.11	Estrutura de controle do DMC multivariável.	50

3.12	Esquema dos sensores da planta solar.	51
3.13	Esquema do controle SPGPC com filtro.	53
3.14	Estrutura do controle.	54
3.15	SPGPC com restrições. Seguimento de referência.	55
3.16	SPGPC com restrições. Compensação das perturbações.	55
4.1	Estrutura do controle em cascata.	72
4.2	Entradas reais do processo.	76
4.3	Saída do sistema.	76
4.4	Variáveis manipuladas.	78
4.5	Variável controlada.	78
4.6	Fluxograma do algoritmo de priorização estruturada.	82
4.7	Resposta do sistema a um degrau de 20% em u_1	87
4.8	Resposta do sistema a um degrau de 14% em u_2	87
4.9	Resposta do sistema a um degrau de 33.4% em u_3	88
4.10	Resposta do sistema a um degrau de referência de 20% em y	88
B.1	Planta piloto de processos térmicos (cortesia da ESI-US).	108
B.2	Esquema geral da planta piloto (cortesia do DISA-US).	109
B.3	Estrutura do controle.	110
C.1	Instalação solar de refrigeração (cortesia da ESI-US).	111

C.2	Esquema de funcionamento da máquina de absorção.	112
C.3	Esquema da planta solar de climatização (cortesia do DISA-US).	114
C.4	Sinais reais. Entrada e perturbações.	119
C.5	Identificação do modelo.	120
D.1	Esquema da planta de extração de azeite de oliva.	121
D.2	Modelagem do fluxo de azeite em relação à temperatura da termo-batedeira.	125

Lista de Tabelas

4.1	Conversão básica de relações lógicas em inequações inteiras-mistas.	64
4.2	Restrições do controlador multiobjetivo priorizado.	73
4.3	Índices WITSE.	89
A.1	Tabela comparativa entre algoritmos MPC.	106

Nomenclatura e Simbologia

Notação

$A(\cdot)$	Letras maiúsculas em negrito denotam matrizes polinomiais
<i>$A(\cdot)$</i>	Letras maiúsculas em itálico denotam polinômios
M	Letras maiúsculas em negrito denotam matrizes reais
b	Letras minúsculas em negrito denotam vetores reais

Símbolos

s	Variável complexa no tempo contínuo
z	Variável complexa no tempo discreto
Δ	$1 - z^{-1}$
$(M)_{ij}$	Elemento ij da matriz M
M'	Matriz transposta da matriz M
$I_{n \times n}$	Matriz identidade, tamanho $(n \times n)$
$\ \cdot\ _2$	Norma-2 de (\cdot) : $\ \cdot\ _2 = (\cdot)'(\cdot)$
$(\cdot)^*$	Valor ótimo de (\cdot)
$E[\cdot]$	Valor esperado de (\cdot)
$\hat{x}(t+j t)$	Valor predito da variável x no instante $t+j$, calculado com a informação disponível no instante t
$\min J$ $s.a. \mathbf{R}$	Minimização do vetor J sujeito a um conjunto de restrições R

Abreviaturas

<u>Termo</u>	<u>Denominação original</u>	<u>Significado</u>
ARIMA	Auto Regressive Integrated Moving Average	Modelo auto-regressivo integrado de média móvel
CARIMA	Controlled Auto-Regressive Integrated Moving Average	Modelo auto-regressivo integrado de média móvel com variável de controle
DMC	Dynamic Matrix Control	Controle por matriz dinâmica
DTC	Dead Time Compensator	Compensador de atraso
GPC	Generalized Predictive Control	Controle preditivo generalizado
IMC	Internal Model Control	Controle por modelo interno
ISE	Integral Square Error	Integral quadrática do erro
ITSE	Integral Time Square Error	Integral quadrática do erro pelo tempo
LP	Linear Programming	Programação linear
MAC	Model Algorithm Control	Controle algorítmico baseado em modelo
MIMO	Multi-Input Multi-Output	Sistema multivariável
MILP	Mixed Integer Linear Programming	Programação linear inteira mista
MINLP	Mixed Integer Nonlinear Programming	Programação não linear inteira mista
MIQP	Mixed Integer Quadratic Programming	Programação quadrática inteira mista
MLD	Mixed Logical Dynamical Systems	Sistemas lineares descritos por regras lógicas em equações dinâmicas
MMC	Modular Multivariable Controller	Controle modular multivariável
MPC	Model Predictive Control	Controle preditivo baseado em modelo
MVC	Minimum Variance Controller	Controle de variância mínima
NLP	Nonlinear Programming	Programação não linear
OP	Optimal Predictor	Preditor ótimo
PFC	Predictive Functional Control	Controle preditivo funcional
PI	Proportional Integral	Controle com ação proporcional e integral
PID	Proportional Integral Derivative	Controle com ação proporcional, integral e derivativa
PLC	Programmable Logic Controller	Controlador lógico programável
QP	Quadratic Programming	Programação quadrática
SCADA	Supervisory Control and Data Acquisition Systems	Sistema de supervisão, controle e aquisição de dados
SISO	Single-Input Single-Output	Sistema monovariável
SP	Smith Predictor	Preditor de Smith
SPGPC	Smith Predictor based Generalized Predictive Control	GPC baseado no preditor de Smith

Capítulo 1

Introdução

”The hierarchy of industrial automation has progressed steadily and continuously for the last one decade. As one of the key technologies, advanced controls have been widely applied. Many software packages tools for process modeling, simulation and controller design have contributed to their applications. In the viewpoint of total production system development, appropriate understanding of the process, higher running time of the systems, and improvement of related technologies including hardware and software are specifically important. Education of new technologies, needs for control application, and benefit evaluation are also expected for promotion of control technologies.”

H. Takatsu, T. Itoh and M. Araki.
1998.

1.1 Motivação

O emprego de estratégias avançadas de controle é, cada vez mais, uma urgente necessidade nas indústrias, com o objetivo de melhorar seus processos produtivos em consonância com a evolução do mercado, permitindo manter um grau de competitividade e rentabilidade. As exigências dos setores produtivos em matéria de qualidade, segurança, requisitos de preservação do meio ambiente, produtividade e flexibilidade na operação, entre outros, acarreta a necessidade de desenvolvimento e implantação de novas técnicas de controle que permitam alcançar um alto grau de eficácia e competitividade na operação dos processos.

Grande parte dos processos industriais são sistemas cuja estratégia de operação é determinada por uma série de critérios tanto econômicos (relacionados com a qualidade da produção) como de segurança ou de meio ambiente. Ainda que as estratégias de controle avançado possam contribuir no cumprimento desses objetivos, na prática não vêm sendo empregadas de forma extensiva, continuando-se a utilizar estratégias de controle clássicas, desenvolvidas há quarenta ou cinquenta anos. Além disso, é usual controlar os processos multivariáveis com estratégias monovariáveis, dividindo um sistema de múltiplas entradas e saídas em subsistemas de uma só entrada e uma só saída considerados independentes, tratando o efeito de outras partes do processo como perturbações. A razão fundamental para esta escassa introdução de técnicas avançadas a nível industrial é o maior grau de dificuldade conceitual e de realização deste tipo de controlador, aumentando os esforços necessários tanto a nível da implementação do controle quanto a nível da formação específica dos operadores.

Dentre as estratégias de controle que estão sendo usadas na indústria, o Controle Preditivo Baseado em Modelo (*Model Predictive Control*, MPC) talvez seja a técnica de controle avançado com maior êxito em diversos campos, desde a indústria petroquímica para o qual foi desenvolvido originalmente, até uma grande variedade de áreas de aplicação que incluem instalações químicas, de automação, indústria aeroespacial, metalúrgica, entre outras.

1.2 Importância da Pesquisa

A relevância do estudo de sistemas de controle preditivo têm sido levantada em diversos trabalhos, que mostram resultados de pesquisas realizadas na indústria nos últimos anos (ver, por exemplo, os artigos [82, 88, 103]). Essas pesquisas mostram que, nos processos onde se utilizam os algoritmos de controle preditivo baseado em modelo, existe uma proporção de engenheiros de controle e de processos similar à que se encontra em processos que utilizam os algoritmos denominados proporcionais-integrais-derivativos (*Proportional Integral Derivative* (PID) *controllers*). Com relação à implementação e utilização das diferentes es-

estratégias de controle por parte dos operadores de planta, os algoritmos de MPC já passam a ser considerados como ferramentas de engenharia de uso relativamente fácil. Com relação à satisfação no uso, aponta-se que as técnicas de MPC têm um grau de satisfação de 80% em mais de 50% dos casos analisados. As pesquisas também apresentam o percentual de indústrias que utilizam técnicas de controle avançado, mostrando que os compensadores de tempo morto (ou simplesmente DTC, do inglês *Dead Time Compensators*) são os algoritmos mais populares, seguidos pelas técnicas de MPC. Na avaliação da aplicação das técnicas de controle avançado, os algoritmos de MPC aparecem como os que geram maior grau de satisfação entre os usuários, com índices de satisfação de 94%¹. Finalmente, os MPC também têm elevados índices de aceitação quanto se trata de facilidade de implementação e expectativas de melhorias.

Em [82] são apresentadas mais de 2000 aplicações de MPC, principalmente nas grandes indústrias do setor petroquímico. O que se nota é que estas técnicas não têm sido aplicadas em pequenas e médias empresas (apesar dos benefícios quanto à melhoria de qualidade de produtos, economia energética, entre outros, já demonstrados em empresas petroquímicas) devido aos custos e à necessidade de um pessoal especializado neste tipo de técnicas, o que pressupõe importantes investimentos em formação. Assim como em [61], pretende-se desenvolver técnicas de controle adaptadas à problemática desse tipo de empresas que não necessitem investimentos elevados quanto a equipes de controle e quanto à formação específica dos operadores. Ou seja, a um custo razoável, deseja-se incrementar a produtividade dos processos pela aplicação das técnicas MPC, que resultem em sistemas de controle simples (de baixo custo) e não requeiram um pessoal excessivamente qualificado para sua operação.

A partir dos dados dessas pesquisas, é possível concluir que trabalhos orientados à solução dos problemas em sistemas de controle (tanto no caso monovariável como no de plantas multivariáveis) usando estratégias MPC contribuem para a melhoria do funcionamento de processos na indústria. Também é possível concluir que se pode realizar pesquisas orientadas à simplificação dos procedimentos de ajuste e à otimização do comportamento desses controladores.

Esta tese direciona-se ao tratamento de sistemas com atraso pela inclusão de restrições e de múltiplos objetivos de controle (inclusive os de ordem econômica) na otimização dos controladores MPC. Assim, pretende-se introduzir técnicas que possam contribuir no setor industrial, não só pela adaptação de algoritmos MPC com restrições a aplicações determinadas, mas também pela incorporação de otimização multiobjetivo, conceito novo ainda não introduzido nos pacotes comerciais. Pretende-se incorporar objetivos tanto de controle quanto econômicos no desenvolvimento dos algoritmos da otimização, trabalhando com diferentes estratégias multiobjetivo. Além disso, a presença de grandes atrasos em processos

¹Calcula-se este índice como a relação entre o número de usuários muito satisfeitos e o número total de usuários.

reais é um fator que deve ser considerado no projeto e ajuste do controlador. Por isto, uma análise entre diferentes controladores MPC, quanto a seu comportamento em malha fechada e sua robustez frente a variações paramétricas, será realizada para selecionar o algoritmo MPC mais adequado ao tratamento deste tipo de sistema. Nesta tese, enfoca-se a aplicabilidade prática das técnicas propostas e as análises realizadas. Por esta razão, diversas aplicações em plantas piloto e industriais ilustram os resultados obtidos nesta pesquisa.

1.3 Estado da Arte em Controle Preditivo

As estruturas de controle baseadas em preditores têm sido usadas em diversas aplicações de controle desde o final dos anos 50 [15, 21, 23, 38, 76, 100]. A utilização de preditores no controlador permite melhorar o comportamento do sistema em malha fechada principalmente em duas situações: (i) quando o processo tem um atraso significativo e (ii) quando a referência futura é conhecida. Conceitualmente, esses dois problemas são muito distintos. No primeiro, o principal objetivo do preditor é eliminar (ou diminuir) os efeitos prejudiciais do atraso no comportamento dinâmico e robustez do sistema de controle. No segundo, o controle preditivo permite a antecipação da ação de controle de acordo com as previsões da evolução da saída.

A respeito do uso de preditores em controle de processos², pode-se considerar o preditor de Smith (SP) como a primeira estrutura de controle preditivo apresentada na literatura (ao final dos anos 50) [100]. Inicialmente desenvolvido para melhorar o comportamento de controladores clássicos atuando em plantas com atraso, o SP recebeu diversas extensões e modificações. Uma interessante revisão do SP e de algumas modificações propostas pode ser realizada através de [61, 65, 69, 77]. Já os preditores ótimos (OP) foram introduzidos no contexto do controle ótimo [39, 79] e utilizados posteriormente nos algoritmos de controle preditivo baseado em modelo (MPC) [15]. Enquanto o SP é utilizado para compensar atrasos, os OPs são normalmente utilizados para prever o comportamento futuro da planta, seja em um único instante, como no caso do controlador de mínima variância (MVC) ou em um horizonte deslizante, como por exemplo no controle preditivo generalizado (GPC). Os OPs não aparecem explicitamente nas estruturas de controle preditivo que os utilizam, apesar de que o MVC pode ser analisado como um preditor ótimo mais um controle primário, como foi comprovado em [76]. Em [11, 16] apresenta-se um estudo para o GPC, onde também demonstra-se que é equivalente a um sistema composto por um preditor ótimo aliado a um controlador primário. Uma interessante revisão do OP e de suas várias formulações pode ser encontrada em [33].

²Alguns trechos desta revisão bibliográfica, a respeito dos preditores SP e OP, foram extraídos de [61].

Durante a última década, diversas estratégias de controle baseadas no OP foram propostas, como por exemplo: GMVC (*General Minimum Variance Controller*) [21], GPC (*Generalized Predictive Controller*) [23], EPSAC (*Extended Prediction Self Adaptive Control*) [47], EHAC (*Extended Horizon Adaptive Control*) [109]. A utilização do OP nesses controladores deve-se a suas propriedades ótimas, isto é, o OP busca gerar a melhor predição da saída da planta em uma configuração de malha aberta que considera perturbações determinísticas e estocásticas. Nos últimos anos, diversos autores têm analisado a robustez de alguns destes algoritmos [3, 22, 55, 72, 90]. Uma característica comum de todas as estruturas de controle ótimo que utilizam o OP é que o preditor é calculado considerando o comportamento em malha aberta da planta, sem considerar que o mesmo vai trabalhar em malha fechada. Já em [64, 68, 71], a influência do preditor na robustez do sistema em malha fechada é estudada, ao invés de utilizar preditores definidos com as informações de malha aberta.

Considerando a estrutura do GPC como um controlador primário associado a um preditor ótimo, em [70] foi apresentado um novo algoritmo de controle preditivo que pode ser usado em plantas estáveis. Este algoritmo utiliza parte das idéias do preditor de Smith e parte das idéias do GPC, sendo por isso definido como GPC baseado no preditor de Smith (ou simplesmente SPGPC) e propõe um novo método de ajuste dos polinômios de filtragem no GPC para melhorar sua robustez, aplicável a plantas monovariáveis e multivariáveis estáveis.

Além dos algoritmos de controle MPC citados, existem outras técnicas de MPC como: MAC (*Model Algorithmic Control*) [89] e DMC (*Dynamic Matrix Control*) [28], que não são baseadas no OP, e sim no uso de um modelo dinâmico do processo (resposta impulsiva no primeiro e resposta ao degrau no segundo) no sentido de prever o efeito das ações de controle futuras na saída, sendo que estas são determinadas pela minimização do erro predito sujeito às restrições operacionais.

A diferença principal entre os algoritmos MPC é o tipo de modelo utilizado para descrever o processo e as perturbações. Cada método apresenta vantagens e inconvenientes e diversos trabalhos têm sido publicados com análises comparativas entre os diferentes controladores [16, 36, 48, 51, 80]. Em [48], são analisados o comportamento em malha fechada e a robustez dos algoritmos MAC, DMC, EPSAC, EHAC. Já em [80], os algoritmos DMC e GPC são comparados quanto aos aspectos de implementação e à influência de parâmetros usados na função objetivo. Em ambos os artigos, o estudo comparativo se faz através de simulação, para o caso SISO e sem restrições. Em [51], é proposta uma técnica MPC baseada em estimação de estados, onde são traçadas conexões com outros controladores MPC, através de fundamentação matemática. Em [82], os algoritmos MPC mais utilizados a nível industrial são analisados com relação a aspectos práticos de implementação. Em [36], é apresentada uma revisão do MPC e são analisadas questões como ajuste de controladores, comparativos entre algoritmos e inserção das restrições.

Para o caso de processos com atraso, existem importantes diferenças entre o grupo de controladores que utilizam descrições do tipo resposta ao degrau ou impulsiva e o grupo de estratégias baseadas no OP. Podem ser citadas duas vantagens deste segundo grupo de algoritmos: (i) a representação composta pela função de transferência e o modelo é mais geral que a do outro grupo, e (ii) permite obter uma representação com um número de parâmetros muito menor, já que o atraso pode ser representado apenas por um expoente de z^{-1} (operador de atraso unitário, no caso discreto), no polinômio numerador do modelo. Além disso, nestes tipos de controlador, a robustez e a rejeição de perturbações podem ser consideradas no algoritmo através da utilização de polinômios de filtragem [22].

Considerando estes trabalhos, observa-se que a formulação de outros algoritmos MPC como um sistema composto de um controle primário e um preditor permite analisar e avaliar o comportamento robusto de diferentes controladores preditivos, analiticamente. Através de uma análise comparativa, pode-se selecionar o algoritmo MPC mais adequado à aplicação prática, especialmente do ponto de vista da robustez em malha fechada. É interessante realizar esta formulação para o controlador por matriz dinâmica (DMC), por sua elevada utilização a nível industrial, e compará-lo aos controladores GPC e SPGPC, para os quais a formulação já é conhecida [61].

Na busca por estratégias de ajuste de controladores MPC que resultem em controles simples, confiáveis e fáceis de operar, diversos trabalhos também foram publicados. Alguns procedimentos de ajuste dos controladores têm se concentrado em atender aspectos específicos como ajuste para estabilidade [25, 35, 86], robustez [50, 74], entre outros. Em [11], o método usado para implementar o GPC está baseado no fato de que muitos processos na indústria pode ser descrito por poucos parâmetros e que um conjunto de regras tipo Ziegler-Nichols relacionando os parâmetros do controlador aos do processo pode ser obtida. Em [84], um estudo comparativo de diversas orientações quanto à seleção dos parâmetros dos controladores DMC e GPC se converte em um conjunto de regras de ajuste buscando um compromisso entre simplicidade e desempenho. Já [99] apresenta uma estratégia de ajuste para o DMC que busca o seguimento de referência com mínimo sobressinal e garante a rejeição de perturbações para sistemas estáveis em malha aberta. Entretanto, a maioria dessas estratégias centra-se no problema de controle sem restrições, sendo que ainda existe a necessidade de buscar-se soluções de fácil ajuste, quando as restrições estão inseridas no projeto do controlador.

Apesar da maioria das aplicações industriais envolver restrições, ainda são poucos os artigos que tratam dos problemas de controle preditivo sob restrições, especialmente voltados à aplicação prática. A ausência de solução analítica na maioria dos problemas de controle ótimo restrito torna o seu uso mais complexo. A forma mais usual de resolver estes problemas é a aplicação iterativa do método de programação quadrática (*Quadratic Programming*, QP). Em [13], transforma-se o problema padrão QP em um problema complementar linear (LCP) equivalente, demonstrando que o esforço computacional pode ser significativamente reduzi-

do, ponto crucial em aplicações reais com dinâmicas rápidas. Seguindo esta motivação no sentido de evitar técnicas de programação matemática computacionalmente intensas, em [9] introduz-se um método de modificar o sinal de referência para evitar violações de restrições e garantir um tempo mínimo de estabilização. Além disso, é possível que um problema MPC seja mal-colocado. Isto significa que não existe solução factível que satisfaça as restrições operacionais impostas. Em [97], faz-se uma discussão sobre a relação entre estabilidade de malha fechada e factibilidade. A não-factibilidade frequentemente leva a instabilidade. A não-factibilidade temporária em aplicações reais pode ser uma consequência natural ao se tentar trabalhar sob condições ótimas de operação. A estratégia recomendada por [87] é manter uma *janela restrita* onde estejam contidas as restrições do problema. Neste caso, não-factibilidades podem ser removidas pela reformulação do problema, o que significa relaxar as restrições que tornam o problema não-factível através da abertura suficiente dessa janela. Assim, no caso de não-factibilidade do problema, uma maneira de atuar sobre o sistema é decidir a importância relativa das restrições as quais este está submetido e relaxar as relativamente menos importantes, até que a factibilidade seja recuperada.

O tema de reformulação das restrições na presença de não-factibilidades é ainda um ponto crítico no MPC. Pode-se formular a questão de otimização sob restrições em um problema com múltiplos objetivos de controle, buscando minimizar a duração e/ou o tamanho de violação de uma determinada restrição a fim de garantir um comportamento desejável ao sistema [85].

Uma maneira sistemática de descrever objetivos de controle e/ou restrições como critérios multiobjetivos é através do uso de lógica proposicional, como apresentado em [105]. Em controle preditivo, é possível combinar lógica, baseada nas decisões de controle desejadas, com o algoritmo MPC utilizando proposições lógicas representadas por variáveis inteiras. Esta formulação permite incorporar conhecimentos qualitativos do processo no cálculo do controle. Assim, pode-se criar estratégias de controle com capacidade tanto para priorizar restrições quanto para alterar o objetivo de controle dependendo das condições de entrada do processo [8]. A idéia é descrever as prioridades das restrições e/ou objetivos, através da lógica proposicional, em uma forma canônica, que pode ser transladada a um problema de otimização com variáveis inteiras. Finalmente este problema pode ser combinado com o problema QP padrão do controle preditivo e resultar em um problema de programação quadrática inteira mista (MIQP - *mixed integer quadratic programming*) - ou um problema de programação linear inteira mista, se o problema de controle preditivo for formulado como um LP. A solução do ótimo global de tais problemas pode ser obtida, mas a complexidade computacional envolvida é muito maior que os problema QP ou LP originais.

Esta abordagem foi recentemente estendida para o tratamento de sistemas híbridos que incorporam conhecimentos qualitativos do processo através de regras heurísticas e inferência lógica, resultando em sistemas dinâmicos sujeitos a restrições lineares descritas por variáveis inteiras e numéricas chamados de sistemas dinâmicos lógicos mistos (*Mixed Logical Dynam-*

ical (MLD) Systems) [8, 105]. Esses sistemas utilizam variáveis binárias (0, 1) auxiliares para transformar lógica proposicional em inequações lineares.

Considerando o tema de otimização com restrições, foi demonstrado em [106] como a magnitude de violações de restrições de menor prioridade pode ser minimizada, sem o uso de otimização inteira mista. De fato, apenas um programa linear é necessário, desde que a função objetivo seja propriamente escolhida, o que resulta em grande simplificação, quando comparado ao uso de programação inteira mista. A idéia é formular um problema de otimização tal que a violação da restrição de menor prioridade não possa ser minimizada sem aumentar a violação de uma restrição de maior prioridade. A solução de tal problema é chamada de *mínimo lexicográfico* de violação de restrições. A solução apresentada por [106] é minimizar uma combinação de variáveis de folga que aparecem na função objetivo. Se as variáveis de folga estão ordenadas para que a primeira corresponda à restrição de maior prioridade, e a última à de menor prioridade, então o mínimo lexicográfico está garantido pela escolha de uma relação suficientemente grande entre os pesos na combinação linear. Determinar quão larga deve ser esta relação envolve resolver outro problema LP, fora do algoritmo de otimização (*off-line*). Em [45], uma idéia similar ao algoritmo de [106] é usada em combinação com os sistemas MLD. Consegue-se maior flexibilidade na especificação do problema, apesar de manter a otimização inteira mista.

Essas abordagens, utilizadas no controle com restrições ou na formulação de problemas multiobjetivo, permitem estabelecer novas estratégias de controle com capacidade tanto para evitar a violação de restrições quanto para agregar objetivos múltiplos de controle, inclusive de caráter econômico, dependendo das condições desejadas de operação do processo. Uma forma de adaptar o problema de otimização multiobjetivo aos algoritmos MPC é apresentada nesta tese. Aqui propõe-se utilizar os valores ótimos desejados em diferentes estratégias de otimização multiobjetivo na minimização da função de custo do algoritmo MPC.

1.4 Objetivos

O objetivo principal desta tese é contribuir para a melhoria da solução do controle de processos com atraso. Dá-se ênfase aos problemas associados ao controle de processos com atrasos e restrições, quando se utilizam controladores preditivos baseados em modelo. No contexto de processos com atraso, desenvolve-se a generalização de alguns resultados obtidos por Normey-Rico em seu trabalho de doutorado para sistemas com atraso dominante (ver [61]). Pela formulação do DMC como um controlador primário mais um preditor, estabelece-se resultados comparativos entre diferentes algoritmos MPC, especialmente quanto ao comportamento robusto em malha fechada, com o intuito de encontrar o controlador mais adequado a aplicações reais em processos com atraso. Utiliza-se e propõe-se técni-

cas e ferramentas de controle preditivo que incorporam aspectos como robustez e restrições aliadas a estratégias de otimização multiobjetivo. O desenvolvimento das técnicas que executam algoritmos de controle preditivo com otimização multiobjetivo é realizado sobretudo no sentido de atender problemas com restrições, visando a simplicidade de implementação prática. As estratégias de controle preditivo multiobjetivo propostas utilizam um nível supervisor para determinar as referências ótimas de controle para um nível regulatório. O nível supervisor baseia-se em um otimizador de múltiplos objetivos, projetado a partir de técnicas que integram heurística, lógica e dinâmica do processo por meio de expressões descritas através de lógica proposicional, ou de estruturação formulada por regras de decisão do tipo *if-then-else*. A solução encontrada através da otimização multiobjetivo funciona como referência no cálculo da ação de controle do algoritmo MPC. Diversas aplicações em plantas piloto e industriais ilustram os resultados obtidos com as técnicas propostas, apontando as vantagens e desvantagens de cada estratégia. Busca-se obter soluções de fácil implementação para o controle de processos, considerando fundamentalmente questões como simplicidade no ajuste de parâmetros e comportamento robusto do controlador. Os problemas de controle aqui analisados são enfocados sob o ponto de vista teórico, sem perder de vista seu potencial nas aplicações práticas.

1.5 Estrutura da Tese

Este trabalho está organizado da seguinte forma:

- No capítulo 2 faz-se uma revisão do controle preditivo baseado no modelo (MPC). Apresentam-se os preditores usados no controle de processos: inicialmente representados pela ação derivativa do controle PID, depois implementados para compensação do atraso através do preditor de Smith, até atingirem a formulação conhecida para os controladores preditivos do tipo MPC. Ao final do capítulo, é abordado o tema referente à implementação do controle preditivo sob restrições.
- No capítulo 3 apresenta-se o tema associado ao tratamento de sistemas com atraso dominante. Demonstra-se que o algoritmo DMC pode ser formulado como um sistema composto por um controlador primário e um preditor. Esta formulação permite uma análise rigorosa do DMC, comparado ao GPC e ao SPGPC, em aspectos como robustez e comportamento em malha fechada. Para ilustrar esta análise, são apresentados resultados simulados e experimentais obtidos em uma planta piloto de processos térmicos. Ao final do capítulo, uma aplicação real de controle sob restrições de uma planta solar de climatização é apresentada.

- No capítulo 4 é tratado o tema associado à otimização em controle preditivo. São abordadas metodologias e problemas referentes à implementação do controle preditivo com otimização multiobjetivo, analisando a questão da factibilidade. Um algoritmo simplificado para a implementação da estratégia de multicritérios é proposto ao final desse capítulo. Resultados simulados com dados experimentais de uma planta industrial demonstram as qualidades de diferentes algoritmos.
- O último capítulo apresenta as conclusões sobre o trabalho realizado, as considerações finais, as publicações geradas e as perspectivas futuras de pesquisa.
- No apêndice A é enfatizada a implementação dos algoritmos de controle preditivo enfocados nesta tese: o DMC (Controlador por Matriz Dinâmica), o GPC (Controlador Preditivo Generalizado) e o SPGPC (GPC baseado no Preditor de Smith). Nos anexos B a D, apresentam-se a descrição e a modelagem dos processos utilizados para implementação e análise dos algoritmos aqui propostos.

Capítulo 2

O Controle Preditivo Baseado em Modelo

”Before any evaluation of MPC, a basic question is to be raised: is advanced control necessary? What is it? Definitely the answer cannot be given in terms of a list of particular selected strategies. Advanced control is not a restricted club, composed of self-styled ”optimal, general, universal” control algorithms. From the application point-of-view, which is under consideration in this special issue, the difference in control approaches comes with the necessity of modeling. The situation in industry seems to be clearer nowadays: either a model is or is not needed. If is needed then advanced control is the answer.”

J. Richalet.
1993.

2.1 Introdução

A ação preditiva de um controlador pode ser interpretada como uma maneira de gerar, através da previsão de um determinado comportamento na resposta do sistema, um sinal de atuação que possa evitá-lo ou, ao menos, diminuí-lo. A forma mais simples de previsão pode ser encontrada num controlador PID, onde a ação derivativa pode ser analisada como uma previsão linear do erro do sinal de controle. A ação preditiva da porção derivativa do PID permite que seja possível controlar processos com pequenos atrasos de uma maneira mais eficiente do que quando se utiliza um controlador do tipo PI [62]. Já quando o atraso é grande, se comparado à constante de tempo dominante, o ajuste da ação derivativa não fornecerá uma boa previsão e será necessário utilizar outro tipo de controlador. Se o atraso é dominante (maior que duas vezes a constante de tempo equivalente do processo), torna-se mais difícil controlar o processo utilizando controladores PID, já que a previsão linear do erro não é mais uma boa aproximação do erro real. Devido a essa dificuldade, em ambientes industriais, a solução mais adotada pelos operadores de planta é o desligamento da ação derivativa, além da redução do ganho proporcional do controle e o aumento do tempo integral de forma que o sistema de controle seja estável. No entanto, a utilização dessa estratégia torna o comportamento transitório muito lento. O desempenho do sistema controlado pelo PID pode ser otimizado, mas as limitações impostas pela sua estrutura de previsão linear do erro não permitem obter respostas rápidas (veja por exemplo [4, 59, 63]).

Para melhorar o desempenho obtido com um PID, devem ser utilizadas estratégias de controle com compensação do atraso, onde a previsão do erro não seja mais linear. Uma destas estratégias, chamada de preditor de Smith (SP) [101], aplica-se ao controle de processos estáveis e baseia-se na introdução de um preditor ($G_n(z)$) no esquema de controle, conforme mostra a figura 2.1. Note que, para a implementação no tempo discreto, $G(z)z^{-d}$ representa a planta real (com atraso d), $G_n(z)$ o modelo do processo desconsiderando o atraso, d_n é o atraso nominal do sistema e $C(z)$ o controlador primário implementado.




Figura 2.1: Diagrama do preditor de Smith.

Pode ser observado nesta estratégia que: (i) a saída do preditor ($\hat{y}(t + d_n)$) é uma estimativa da saída do processo sem o atraso nominal; (ii) como o modelo do preditor não é, em geral, igual ao processo real, é introduzido um fator de correção $e(t)$, gerado pela diferença entre a saída real e a predita por $(G_n(z)z^{-d_n})$; (iii) no caso ideal, o erro é zero e o controlador primário $C(z)$ pode ser ajustado considerando apenas a planta sem o atraso ($G_n(z)$). Esta solução é simples e permite obter respostas mais rápidas do que as que podem ser obtidas usando um controle PID [77].

A solução proposta por Smith vem sendo utilizada em muitas aplicações, e vários trabalhos técnicos foram publicados, analisando-a e aperfeiçoando-a. Revisões interessantes de métodos de ajuste e/ou modificações da estrutura do preditor de Smith podem ser encontradas em [65, 69, 77]. No caso de plantas estáveis, destacam-se os trabalhos: [75], que analisa a estabilidade do SP relacionada aos erros de modelagem; [59], onde é mostrado que a estabilidade robusta do sistema depende somente do ajuste do controlador $C(z)$; [91], que propõe diferentes ajustes dos parâmetros do SP com objetivo de melhorar a robustez do sistema; e [78], onde é proposta uma maneira de compensar perturbações mensuráveis no SP. Destacam-se ainda os trabalhos de Normey-Rico e Camacho, que propuseram diferentes estruturas com dois graus de liberdade para plantas de primeira ordem estáveis ou integradoras, permitindo através de ajustes simples melhorar a robustez, o seguimento de referências e a rejeição de perturbações (ver artigos [64, 67, 69], entre outros). Para processos integradores com atraso dominante, diversos autores propuseram modificações do SP original para melhorar o comportamento de malha fechada do sistema de controle [5, 52, 53, 108].

A estrutura do SP identifica duas características principais utilizadas pelo SP: (i) a introdução de um modelo do processo na estrutura do controlador, representado por $G_n(z)$; e (ii) o uso da predição da saída do processo em $t + d$ para o cálculo da lei de controle. Devido a essas características, o SP pode ser considerado como o primeiro controlador preditivo baseado em modelo proposto na literatura.

Os algoritmos agrupados dentro da denominação de **Controle Preditivo Baseado em Modelo** (MBPC, ou simplesmente MPC) não se limitam ao estudo de processos com atraso e estendem as idéias do SP considerando a predição da saída do processo até um tempo $t + N$ ($N > 0$ qualquer), permitindo a utilização de diferentes modelos do processo (inclusive não lineares) e, em geral, calculando a lei de controle via algoritmos de otimização. Mais do que uma estratégia de controle específica, o MPC identifica um conjunto de métodos de controle que foram desenvolvidos considerando algumas idéias comuns. As características principais que compartilham os controladores preditivos baseados no modelo são, conforme [15, 85]:

- O uso explícito de um modelo do processo, para realizar o cálculo da predição do comportamento futuro das variáveis que descrevem a dinâmica do processo, num determinado horizonte finito.

- O cálculo de uma seqüência de ações de controle para todo o horizonte a partir da minimização de uma determinada função objetivo. No processo de minimização da função objetivo, o MPC pode estar sujeito a restrições, sendo esta uma das suas características mais valorizadas no âmbito industrial, um diferencial quando comparado a outras técnicas de controle.
- Estratégia de horizonte deslizante, ou seja, a aplicação do controle envolve unicamente a ação de controle daquele instante e desconsidera o resto da seqüência de controle dentro do horizonte. A cada período de amostragem, o horizonte é deslocado um passo em direção ao futuro, sendo calculada uma nova seqüência de atuações.

A escolha do modelo de predição é o ponto chave no MPC: um bom projeto deve buscar obter o melhor modelo possível, que deve ser completo o suficiente para capturar adequadamente a dinâmica do processo e permitir o cálculo das predições da saída do processo, ser intuitivo e ao mesmo tempo permitir uma análise teórica do sistema. As diferentes estratégias de MPC utilizam diferentes formas para representar as relações entre entradas manipuladas, perturbações e saídas do processo. Em geral, os modelos também incluem uma representação matemática das perturbações e o ruído, assim como dos erros de modelagem. Em geral, o modelo é separado em duas partes, ambas necessários para o cálculo das predições: o modelo do processo propriamente dito e o modelo das perturbações. Quanto ao cálculo da lei de controle, em geral, os diversos algoritmos MPC utilizam diferentes funções de custo, que consideram como objetivo comum minimizar o erro entre a saída futura e a referência desejada, penalizando o esforço da ação de controle [16].

Estes princípios gerais sobre os quais se fundamentam os controladores MPC, acabam por convertê-los em estratégias de controle de natureza aberta, devido à flexibilidade que apresentam na incorporação de inovações, virtude que tem permitido que os algoritmos evoluam com o passar do tempo. Os vários algoritmos MPC diferem basicamente na forma como as predições são calculadas, ou seja, no modelo usado para representar o processo e as perturbações, na função objetivo a ser minimizada e no procedimento para manipular as restrições e o cálculo do controle.

Como, na prática, todos os processos estão sujeitos a restrições, é interessante se levar em conta as restrições de operação quando do projeto e implementação do controle. No caso de controladores preditivos, a consideração das restrições se faz diretamente na fase de otimização para obtenção do controle ótimo [16]. No caso do MPC, é possível antecipar a ocorrência da violação da restrição e corrigí-la de maneira apropriada. Restrições de saída são principalmente devidas a razões de segurança e devem ser controladas em avanço, pois as variáveis de saída são afetadas pela dinâmica do processo. As variáveis manipuladas (ou de entrada) podem ser mantidas sempre no limite pelo controlador pelo chaveamento da ação de controle a valores que satisfaçam restrições de amplitude e velocidade. Pode-se

incorporar ao processo restrições de comportamento para forçar a resposta do sistema a ter certas características desejadas (evitar fase não-mínima, garantir comportamento monótono, evitar sobre-elevação, entre outras). Além disso, é comum se fazer distinção entre restrições que não podem ser violadas, ditas restrições fortes (“*hard constraints*”), e aquelas que se gostaria de manter dentro de certos limites específicos, mas para as quais se permite que ocasionalmente sejam violadas, conhecidas como restrições brandas (“*soft constraints*”). O tratamento habitual de restrições busca mecanismos de segurança na lei de controle, a fim de manter a operação do sistema fora de zonas consideradas críticas, próximas às restrições. Outra prática comum é ignorar as restrições quando na fase de projeto do controlador e tentar compensá-las de uma forma artificial na fase de implementação do controle, como ocorre no caso da saturação da ação de controle do termo integral do PID, onde se aplica uma compensação, chamada *anti wind-up* [4].

Nota-se, entretanto, que o tratamento do MPC com restrições apresenta dificuldades adicionais, tanto teóricas como de implementação. A formulação do problema consiste no correto equacionamento das restrições e num tratamento posterior conhecido como "estudo de factibilidade e gestão de restrições" [16]. Este tratamento permite o funcionamento do algoritmo de otimização, liberando ou suavizando, quando possível, as restrições. Por outro lado, do ponto de vista da implementação do algoritmo de otimização, as pesquisas estão orientadas à melhoria da eficiência e à minimização dos tempos de cálculo. Finalmente, os problemas de estabilidade destes sistemas de controle somente têm sido resolvidos parcialmente e numerosas pesquisas vêm sendo realizadas nos últimos anos [87, 98].

Outra questão que estimulou o desenvolvimento dos controladores preditivos foi, sem dúvida, a possibilidade de sua aplicação prática na indústria, aspecto que despertou grande interesse tanto no âmbito industrial quanto no meio acadêmico. Neste sentido, deve-se destacar a pesquisa do “controle algorítmico baseado em modelo” (*Model Algorithm Control*, MAC) [89]. Este algoritmo de controle, desenvolvido no meio industrial, emprega um modelo de predição do tipo convolução (resposta ao impulso), com uma função objetivo quadrática; o qual se comercializa com o nome *Identification and Command*, ou simplesmente, IDCOM[©]. Nos anos 70, os engenheiros da empresa SHELL Co. desenvolveram um algoritmo de controle preditivo, que emprega um modelo de resposta ao degrau, que pode ser obtido experimentalmente, com função de custo quadrática. Este controlador, conhecido como “controle por matriz dinâmica” (*Dynamic Matrix Control*, DMC) [28], é comercializado por *DMC Corporation*, apresentando grande êxito na indústria, especialmente na petroquímica [32]. Na verdade, o DMC causou tanto impacto na indústria, que muito provavelmente não existe uma só companhia de petróleo no mundo, onde o DMC ou similar, não seja empregado em suas novas instalações ou atualizações de campo [57].

Paralelamente aos pacotes desenvolvidos por indústrias, alguns grupos de pesquisa que trabalhavam com controle adaptativo, desenvolviam no meio acadêmico outra família de algoritmos dentro da classe dos MPC, com uma série de características diferentes aos do

primeiro grupo [29]. Neste segundo grupo, devem ser incluídos, entre outros: o “controle preditivo generalizado” (*Generalized Predictive Controller*, GPC) [23, 24], que permite controlar uma ampla classe de processos, inclusive os de fase não-mínima, e os instáveis em malha aberta; o “controle adaptativo de predição estendida” (*Extended Prediction Self Adaptive Control*, EPSAC) [47], aplicável a sistemas não-lineares, com ações de controle repetitivas, como no caso da robótica; além do “controle adaptativo de horizonte estendido” (*Extended Horizon Adaptive Control*, EHAC) [109] e o “controle preditivo unificado” (*Unified Predictive Control*, UPC) [102]. Nestes controladores MPC, a planta é representada por uma função de transferência e as perturbações são representadas por um modelo auto-regressivo integrado e de média móvel (normalmente denominado modelo CARIMA, *Controlled Auto-Regressive Integrated Moving Average* [39]), enquanto as predições da saída do processo são calculadas usando preditores ótimos. Uma das vantagens do enfoque usado por este segundo grupo de controladores é que o modelo CARIMA é mais geral que os de resposta impulsional e de resposta ao degrau, permitindo uma representação com menor número de parâmetros (principalmente no caso de processos com atraso). Além disso, neste tipo de controladores, a robustez frente aos erros de modelagem e ruídos de medição pode ser considerada no algoritmo através da utilização de polinômios de filtragem [22].

Assim, os controladores preditivos baseados no modelo constituem uma das técnicas de controle avançado mais aplicadas e aplicáveis no controle de processos industriais. Na verdade, existem uma série de vantagens no MPC, quando comparado a outras metodologias, como razão para seu destaque [15, 60]. Entre elas:

- Apresenta intrinsecamente compensação de atraso.
- É extremamente útil em casos de referências conhecidas (por exemplo, em robótica e processo *batch*).
- Permite a compensação de perturbações mensuráveis, corrigindo-as com uma ação de controle tipo *feedforward*.
- O tratamento de restrições pode ser incluído durante o projeto do controlador.
- Pode ser implementado não só como um algoritmo de controle regulatório, mas também como uma estratégia de controle supervisório, ou mesmo em um nível superior abordando os problemas de otimização empregando diferentes funções objetivos.
- Pode ser usado em uma grande variedade de processos, desde aqueles com dinâmica simples até os de dinâmica mais complexas, incluindo sistemas não-lineares, multivariáveis, instáveis e de fase não mínima.
- É uma metodologia aberta, baseada em princípios básicos, o que permite extensões futuras, contribuições e incorporação de novos desenvolvimentos, principalmente quanto ao modelo de predição e aos critérios de otimização, entre outros.

Tudo isso mostra que os métodos MPC são versáteis e robustos, podendo apresentar bom desempenho em aplicações industriais. Na seqüência, será descrito um algoritmo geral de controle utilizado pelo MPC.

2.2 Descrição Geral do Algoritmo de Controle do MPC

Os controladores preditivos baseados no modelo podem ser representados por meio do diagrama de blocos da figura 2.2, onde podem ser observados seus componentes mais importantes:

- o modelo do processo utilizado para o cálculo da predição das saídas futuras;
- o otimizador que gera a seqüência ótima de controle, baseada na minimização de uma ou mais funções objetivos; que pode considerar, além das predições e dos erros, as restrições nas variáveis de processo e/ou de controle;
- o horizonte deslizante, aplicando à entrada da planta somente $\Delta u(t)$, primeiro elemento da seqüência de incrementos de ações futuras de controle $\Delta u(t + j)$;
- a trajetória de referência futura $w(t + j)$, que permite obter os erros futuros, com base nos valores das saídas futuras previstas.

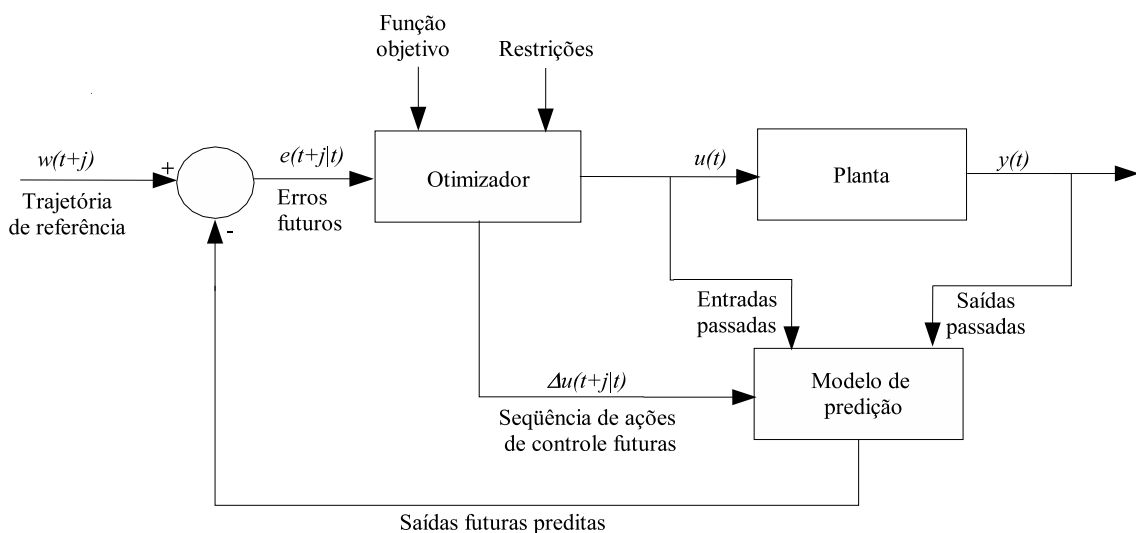


Figura 2.2: Estrutura geral do MPC.

Na figura 2.3, representa-se a evolução no tempo da estratégia do MPC, pela análise do comportamento da saída $y(t)$ em função da ação de controle $u(t)$. Esta figura permite compreender melhor a estratégia, descrita pelos seguintes passos [16]:

1. Estimar, a cada instante de tempo discreto t ($t = 0, 1, 2, \dots$), uma predição da saída do processo $\hat{y}(t + j | t)$ ¹, com $j = 1, 2, \dots, N$, onde N é o horizonte de predição. Esta predição se realiza com base em um modelo do processo, e depende dos valores conhecidos (das entrada e saídas passadas) até o instante t e dos valores da seqüência de incrementos dos sinais de controle futuros $\Delta u(t + j | t)$, $j = 0, 1, \dots, N - 1$, que serão calculados e enviados ao sistema.
2. Estabelecer uma trajetória de referência $w(t + j)$ para a saída, sobre o horizonte de predição. Esta trajetória pode ser a própria referência desejada (*setpoint*) ou mesmo uma aproximação desta, partindo do valor atual da saída em t , de modo que o sistema alcance suavemente o valor de referência em $t + j$.
3. Calcular a seqüência de ações de controle futuras $\Delta u(t + j | t)$, $j = 0, 1, \dots, N_u - 1$, pela otimização de um determinado critério, sujeito ou não a restrições. Em geral, busca-se manter o processo o mais próximo possível da trajetória de referência desejada $w(t + j)$, com um mínimo esforço de controle. O cálculo do controle futuro pode ser realizado sobre um horizonte de controle (N_u) menor que o horizonte de predição (N), assumindo que a variável controlada a partir deste instante permanece constante até alcançar o horizonte N .
4. Aplicar ao processo apenas o primeiro elemento $\Delta u(t | t)$ da seqüência de incrementos de ações futuras de controle $\Delta u(t + j | t)$, desprezando o restante dos valores. Isto porque, utilizando o conceito de horizonte deslizante, no instante de tempo seguinte $t + 1$, o valor de $y(t + 1)$ já será conhecido e repete-se o algoritmo desde o passo 1, com os valores atualizados das variáveis do processo. Assim, obtêm-se uma nova seqüência de controle $\Delta u(t + j | t + 1)$, sendo o valor de $\Delta u(t + 1 | t + 1)$ aplicado ao sistema. Observa-se que, a princípio, a seqüência $\Delta u(t + j | t + 1)$, difere da anterior $\Delta u(t + j | t)$, por causa das novas informações disponíveis no sistema.

De modo geral, para um MPC sem restrições, a seqüência de ações de controle futuras $\Delta u(t + j | t)$, $j = 0, 1, \dots, N_u - 1$ é obtida pelo cálculo de um vetor \mathbf{u} que minimiza uma função objetivo quadrática dada por:

$$J = \sum_{j=1}^N [\hat{y}(t + j | t) - w(t + j)]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(t + j - 1)]^2 \quad (2.1)$$

¹A notação $\hat{y}(t + j | t)$ indica o valor da variável no instante $t + j$, calculada com base na informação disponível no instante t .

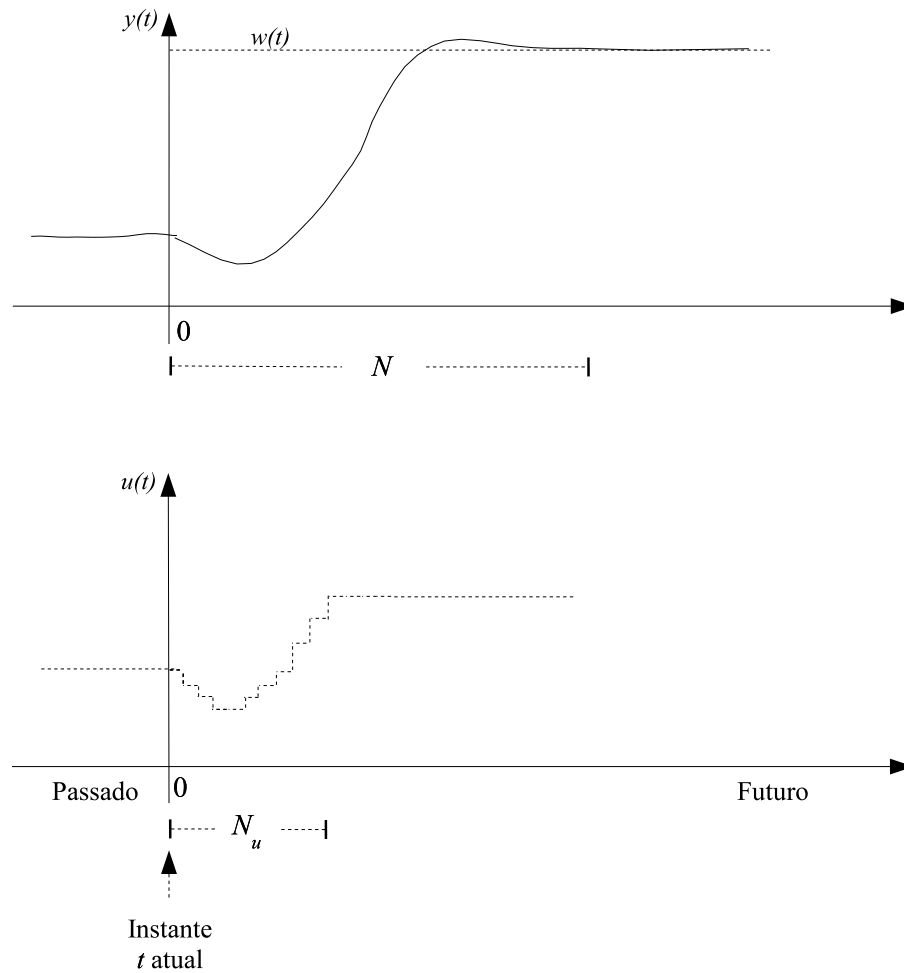


Figura 2.3: Estratégia do algoritmo MPC.

com $\lambda(j)$ representando o fator de ponderação para o controle. A solução ótima, no caso irrestrito, é encontrada pela resolução de uma equação linear, como sendo:

$$\mathbf{u} = \mathbf{K}(\mathbf{w} - \mathbf{f})$$

onde \mathbf{u} é o vetor de incrementos de ações futuras de controle, \mathbf{K} é uma matriz relacionada ao modelo do sistema, \mathbf{w} é o vetor de referências desejadas e \mathbf{f} , o vetor resposta livre do sistema. Na prática, calcula-se \mathbf{u} , e apenas o primeiro elemento de \mathbf{u} , ou seja $\Delta u(t)$, valor do sinal de controle calculado para o tempo t , é aplicado ao processo.

Esta estratégia é equivalente para os diferentes algoritmos MPC. Para auxiliar o entendimento dos próximos capítulos, sugere-se a leitura do apêndice A, com a descrição detalhada dos algoritmos MPC utilizados: DMC, GPC e SPGPC, sob os quais se realizam as simulações e ensaios desta tese.

2.3 MPC com Restrições

As técnicas de MPC são particularmente interessantes para tratar o problema de controle sob restrições. A inclusão das restrições no controle preditivo permite antecipar a violação das mesmas, impedindo que o sistema atinja situações críticas, com a vantagem de que o tratamento de restrições pode ser feito de forma sistemática durante a fase de projeto e implementação do controlador. A consideração explícita das restrições no sistema de controle é de grande importância, pois as restrições estão presentes em todos os processos industriais e em geral o ótimo se encontra na interseção das restrições. Quando o controlador considera as restrições, consegue-se melhorias na produção por duas razões: o processo pode operar mais próximo do ótimo, além de se reduzir perdas por paradas na produção pela violação das restrições.

O propósito principal do MPC é aplicar a melhor ação de controle possível minimizando uma determinada função de custo. Assim uma das formas de considerar as restrições é introduzindo-as na otimização do MPC, em vista da simplicidade de interpretação para o usuário. Para tanto, convém expressar as restrições em termos do vetor de incrementos futuros de sinais de controle \mathbf{u} , dado que a minimização da função objetivo se faz com respeito a esse vetor.

O cálculo do vetor \mathbf{u} , minimizando uma função objetivo dada por (2.1), permite obter o sinal de controle $u(t)$ a ser aplicado ao processo. Na presença de restrições, se $u(t)$ calculado viola uma restrição, é saturado em seu limite, seja pelo programa de controle seja pelo atuador. Esta forma de atuar não garante que o ótimo será alcançado quando as restrições são violadas. Assim, o principal objetivo do MPC, que é a aplicação do *melhor* sinal de controle possível dada a minimização da função custo (2.1), não está sendo atendido, ou seja, o controle perde seu caráter ótimo.

2.3.1 Planejamento das Restrições no MPC

As restrições atuando no processo podem se originar de limites na amplitude dos sinais de controle (saturação), limites nos incrementos dos sinais de controle (*slew rate*) do atuador e limites nos sinais de saída, e podem ser descritas respectivamente pelas desigualdades:

$$\begin{aligned} U_{min} &\leq u(t) \leq U_{max} \quad \forall t \\ u_{min} &\leq u(t) - u(t-1) \leq u_{max} \quad \forall t \\ y_{min} &\leq y(t) \leq y_{max} \quad \forall t \end{aligned} \quad (2.2)$$

Estes três tipos de restrições são os mais comuns na indústria de processos e em outras aplicações [13]. Para um processo de m -entradas, n -saídas e atuando em um horizonte deslizando N , essas restrições podem ser expressas como:

$$\begin{aligned} \mathbf{U}_{min} &\leq T\mathbf{u} + u(t-1)\mathbf{l} \leq \mathbf{U}_{max} \\ \mathbf{l}u_{min} &\leq \mathbf{u} \leq \mathbf{l}u_{max} \\ \mathbf{l}y_{min} &\leq \mathbf{G}\mathbf{u} + \mathbf{f} \leq \mathbf{l}y_{max} \end{aligned}$$

onde \mathbf{l} é uma matriz $(N \times n) \times m$ formada por N matrizes identidade $m \times m$, T é uma matriz bloco triangular inferior cujos blocos não nulos são matrizes identidade $m \times m$ e \mathbf{u} representa o vetor de incrementos do sinal de controle. Essas restrições podem ser expressas de uma forma condensada como:

$$\mathbf{R}\mathbf{u} \leq \mathbf{c} \quad (2.3)$$

com

$$\mathbf{R} = \begin{bmatrix} I_{N \times N} \\ -I_{N \times N} \\ T \\ -T \\ \mathbf{G} \\ -\mathbf{G} \end{bmatrix} \quad \mathbf{c} = \begin{bmatrix} \mathbf{l}u_{max} \\ -\mathbf{l}u_{min} \\ \mathbf{l}U_{max} - \mathbf{l}u(t-1) \\ -\mathbf{l}U_{min} + \mathbf{l}u(t-1) \\ \mathbf{l}y_{max} - \mathbf{f} \\ -\mathbf{l}y_{min} + \mathbf{f} \end{bmatrix}$$

As restrições nas variáveis de saída do tipo $y_{min} \leq y(t) \leq y_{max}$ são normalmente impostas por questões de segurança. As restrições relacionadas à imposição de um determinado comportamento do sistema podem ser revisadas no artigo [49].

Já que todas as restrições podem ser agrupadas na desigualdade matricial (2.3), o problema de otimização do MPC passa a ser:

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

O algoritmo MPC quando leva em conta as restrições consiste na minimização de uma função custo J , possivelmente quadrática, sujeita ao cumprimento de restrições lineares. Isto se traduz na otimização de uma função quadrática com restrições lineares, que se conhece comumente como um problema de programação quadrática (*Quadratic Programming*, QP) e que deve ser resolvido através de métodos numéricos [16]. A ausência de solução analítica na maioria dos problemas de controle ótimo restrito torna-o bastante complexo. Algumas alternativas de solução foram propostas na literatura. Em [13], transforma-se o problema

padrão QP em um problema complementar linear (LCP) equivalente, demonstrando que o esforço computacional pode ser significativamente reduzido, ponto crucial em aplicações reais com dinâmicas rápidas. No sentido de evitar técnicas de programação matemática computacionalmente intensas, em [9] introduz-se um método de modificar o sinal de referência de modo a proibir violações de restrições e garantir um tempo mínimo de estabilização. Além disso, é possível que um problema MPC seja mal-colocado. Isto significa que não existe solução factível que satisfaça as restrições operacionais impostas.

2.3.2 Factibilidade

Um problema de otimização é factível quando a função objetivo é limitada e existem pontos no espaço das variáveis de decisão que satisfazem todas as restrições. O ponto ótimo da minimização está frequentemente nas intersecções das restrições. Em alguns casos, durante o estágio de otimização, a região definida pelas restrições pode ser vazia. Nestas condições, o algoritmo de otimização não pode encontrar uma solução e a otimização é dita não-factível [81]. Objetivos de controle não atingíveis e/ou perturbações que levam o processo fora de seu ponto de operação podem causar não-factibilidade.

Os métodos de gestão de restrições tratam de recuperar a factibilidade relaxando (ou eliminando) as restrições segundo diferentes critérios que dependem do tipo de limites impostos pelas variáveis do processo. Os seguintes tipos de limites podem ser considerados:

- Limites físicos: nunca podem ser ultrapassados devido a aspectos construtivos. Estão associados sobretudo aos atuadores.
- Limites de segurança: nunca devem ser violados porque pode ser perigoso para a segurança do processo ou pode ocasionar altos custos devido ao atendimento de emergência. Estes limites estão usualmente associados às variáveis controladas do processo.
- Limites de operação: fixados pelos operadores como limites que não devem ser excedidos pelas variáveis do processo no sentido de manter as condições nominais de funcionamento do sistema.
- Limites reais: são os usados pelo algoritmo de controle a cada instante. São fornecidos pelo gerenciador de restrições, o qual deve calculá-los de tal maneira que nunca excedam os limites físicos.

A não-factibilidade pode aparecer tanto durante o regime transitório quanto no regime permanente. Os problemas de não-factibilidade em regime permanente são causados por

objetivos de controle irrealizáveis. Isto ocorre por exemplo quando não se pode chegar as referências solicitadas porque os sinais de controle das variáveis manipuladas são restritos. Estas não-factibilidades podem ser consideradas na fase de projeto pela eliminação destes objetivos. Já a não-factibilidade no transitório pode aparecer mesmo quando as restrições impostas parecem ser razoáveis. Ou seja, restrições que não causam problemas em operação normal podem se tornar temporariamente incompatíveis em regime transitório. Uma perturbação ou mudança grande na referência pode levar uma variável de saída para fora de seus limites e pode ser impossível introduzi-la novamente em sua zona normal de funcionamento usando sinais de controle limitados. A não-factibilidade pode ainda ser produzida quando um operador redefine limites de uma variável de operação enquanto o processo está em funcionamento [2]. Se as variáveis já estão fora dos novos limites, o problema será não-factível.

A factibilidade é uma questão de importância no controle MPC sob restrições, não apenas porque a prova de estabilidade de estratégias de controle MPC sob restrições requer factibilidade, mas também porque se o problema de otimização for não-factível, o MPC não funcionará e não estará habilitado a calcular o próximo sinal de controle. Sendo assim, é necessário tomar algumas precauções no uso do MPC sob restrições. Algumas técnicas de busca de soluções factíveis podem ser aplicadas no sentido de buscar restabelecer a factibilidade do problema de otimização. Dentre estas o método do relaxamento de restrições pode ser considerado um dos mais adequados, pois consiste em relaxar temporariamente os limites pelo aumento de seus valores. Uma maneira de realizar o relaxamento é mudar restrições fortes ($\mathbf{R}\mathbf{u} < \mathbf{a}$) para brandas ($\mathbf{R}\mathbf{u} < \mathbf{a} + \epsilon$), pela adição de um termo $\epsilon'\mathbf{T}\epsilon$ à função custo, penalizando qualquer violação da restrição e obtendo um melhor comportamento do sistema controlado [113]. Ao longo da execução do cálculo do controle, o termo penalizado na função objetivo levará a variável a zero. Em [87], a estratégia recomendada é manter uma *janela restrita* onde estariam contidas as restrições do problema. A não-factibilidade poderia ser evitada pela reformulação do problema através da abertura suficiente dessa janela. Para tanto, faz-se necessário que as restrições possam ser relaxadas sem causar alterações no sistema real. Assim, no caso de não-factibilidade do problema, uma das maneiras de atuar sobre o sistema é decidir a importância relativa das restrições as quais este está submetido, e eventualmente relaxar as restrições menos importantes até que a factibilidade seja recuperada.

Alguns trabalhos analisam a garantia da factibilidade associada à estabilidade do sistema em malha fechada. Em [25], Clarke e Scattolini analisam o problema no contexto do GPC, desenvolvendo um novo algoritmo, o CRHPC (*Constrained Receding-Horizon Predictive Control*). A idéia principal é impor restrições terminais aos estados, ou na relação entrada-saída, e forçar a saída predita a seguir exatamente a referência durante um horizonte m suficientemente largo após o horizonte de custo. Em [97], Scokaert e Clarke apresentaram resultados de estabilidade do CRHPC na presença de restrições, além de proporem uma forma de remover as restrições quando soluções factíveis não forem encontradas. A idéia principal é que, se uma solução factível é encontrada e o horizonte de ajuste m é grande o suficiente

para cobrir o transitório das variáveis de saída, a função custo é monotonamente decrescente (se não há perturbações externas e o processo é livre de ruído) e pode ser interpretada como uma função de Lyapunov, o que garante a estabilidade. Em [40], uma metodologia é proposta para garantir a factibilidade do GPC estável na presença de perturbações limitadas que podem levar o processo fora da região restrita. A idéia é determinar o mínimo esforço de controle a fim de rejeitar as piores perturbações no futuro. Para implementar esta idéia, restrições mais fortes que os limites físicos são impostas pelas variáveis manipuladas. A diferença entre os limites físicos e as novas restrições é o esforço de controle mínimo requerido para manter a factibilidade do problema de otimização restrita no sentido de garantir a estabilidade. As técnicas desenvolvidas para garantir a estabilidade, em geral, se baseiam primeiramente na existência de solução factível.

Apesar da maioria das aplicações envolverem restrições, ainda são poucos os trabalhos que tratam dos problemas de controle preditivo sob restrições, especialmente sob o ponto de vista de sua aplicabilidade prática. Por esse motivo, um dos objetivos deste trabalho é realizar uma aplicação real de MPC com restrições, para controlar uma planta em escala industrial, como será mostrado no próximo capítulo.

2.4 Conclusões

Nesse capítulo apresentou-se uma revisão da metodologia dos controladores preditivos baseado no modelo. Questões como cálculo da predição e da função objetivo, diferenças entre os diversos algoritmos existentes foram discutidas. Uma descrição geral do algoritmo de controle por MPC foi abordada. A formulação para o tratamento das restrições foi apresentada.

Vale salientar que o crescente aumento na utilização dos controladores preditivos leva, apesar do alto nível de desenvolvimento já obtido até então, a uma série de novas necessidades e requerimentos de controle. Assim, em vista do MPC ser uma metodologia aberta e flexível à incorporação de novas técnicas, abre-se um campo de possibilidades de pesquisa bastante promissor. Passa-se agora a análise dos temas referentes ao controle preditivo enfocados nessa tese: (i) a questão do problema de controle em processos com atrasos e (ii) a questão da otimização multiobjetivo do controle, visando a melhoria da eficiência do sistema.

Capítulo 3

Controle Preditivo de Processos com Atraso Dominante

”Simple models are very important in the process industry. There are several claims that in practice low models coupled with dead-times are sufficient for most purposes. In most cases it is possible to find two kinds of typical processes: those can be modeled by a static gain, a dead-time and a time constant and those that can be described by a integrator, a velocity gain and a dead-time. Conventional controllers, such as PID controllers, could be used when the dead-time is small but they show poor performance when the process exhibits long dead-times because a significant amount of detuning is require to maintain closed-loop stability.”

T. Haggung.
1996.

3.1 Introdução

Diversos trabalhos [82, 88, 103] apontam que os problemas causados pelos atrasos nos sistemas de controle representam, conjuntamente com os problemas causados pelas perturbações e pelas interações entre variáveis, mais de 60% dos problemas importantes encontrados na indústria de processos. Além disso, foi verificada a popularidade dos compensadores de tempo morto (DTC), comprovando que são os algoritmos mais usados após os PID, seguidos pelas técnicas de MPC. Isto prova a necessidade e importância prática existente na solução dos problemas ocasionados pelos atrasos no sistema. Assim, a consideração dos atrasos de transporte nos procedimentos de síntese de controladores tem recebido grande atenção no meio industrial e acadêmico.

As dificuldades em controlar processos com atrasos significativos são bem conhecidas e se devem ao fato de que o atraso deteriora a margem de fase do sistema. Como resultado, quando se utilizam métodos clássicos de controle para compensar sistemas com atraso, é necessário utilizar ajustes muito conservadores (baixos ganhos, que produzem respostas lentas) para garantir a estabilidade em malha fechada [4, 41]. Em geral, para atrasos pequenos, consegue-se obter uma solução aceitável com estruturas de controle clássicas. Mas se o atraso for dominante e deseja-se obter respostas mais rápidas em malha fechada, é conveniente utilizar algum sistema compensador de atraso. Entre as diferentes técnicas para se lidar com atraso, a mais popular é o preditor de Smith (SP, apresentado no capítulo 2), bastante utilizado na indústria desde os anos 80. A qualidade do SP pode ser comprovada pelas inúmeras modificações propostas no sentido de definir um ajuste apropriado de seus parâmetros ou para melhorar seu comportamento (ver por exemplo [65, 69, 77]).

Em controle de processos, é usual utilizar métodos de redução de modelos para representar o comportamento dinâmico de um sistema de ordem elevada através de um sistema de baixa ordem com atraso [42, 43, 104]. Isso porque, em geral, modelos simplificados geram controladores mais simples e com procedimentos de ajuste mais fáceis. Existem muitas opiniões dentro da comunidade científica internacional que consideram que os modelos de sistemas compostos por uma função de transferência de baixa ordem e um atraso podem ser usados com êxito na maioria das aplicações industriais [19]. Além disto, em geral, os modelos utilizados para representar as relações entrada-saída são de primeira ordem [10]. Um resultado bastante importante foi apresentado utilizando este tipo de modelo em [11, 16]. Neste trabalho, um estudo do GPC foi realizado a fim de demonstrar que é equivalente a um sistema composto por um preditor ótimo e um controlador primário de dois graus de liberdade, conforme esquema apresentado na figura 3.1. Este resultado foi posteriormente generalizado para processos de quaisquer ordens (tanto para o caso SISO quanto para sistemas MIMO) em [61]. Esta representação, que identifica a estrutura de controle primário mais preditor, permitiu realizar um estudo unificado de robustez e comportamento dos compensadores de atraso e dos controladores preditivos para processos com atraso, estabelecendo uma conexão

entre estas duas áreas de controle. Com base neste estudo, Normey-Rico propôs um novo algoritmo de controle preditivo baseado em modelo, o SPGPC (*Smith Predictor based Generalized Predictive Control*) [61]. Este reúne as boas propriedades do DTC (no caso, o SP) e do GPC para o controle de processos estáveis (mono e multivariáveis). Este algoritmo utiliza-se da principal vantagem dos DTC que é uma estrutura de previsão mais simples de projetar e ajustar que a de um GPC. Assim como inclui a principal vantagem do GPC que é o ajuste do controle primário mais simples que no DTC, além da possibilidade de considerar as restrições do processo no cálculo da lei de controle. Um estudo comparativo analisando o SPGPC e o GPC é apresentado em [61]. Conclui-se que o preditor de Smith, substituindo o preditor ótimo no algoritmo do SPGPC, contribui para a simplificação e melhoria dos resultados obtidos, o que incentiva sua utilização na prática, por seu bom comportamento e robustez.

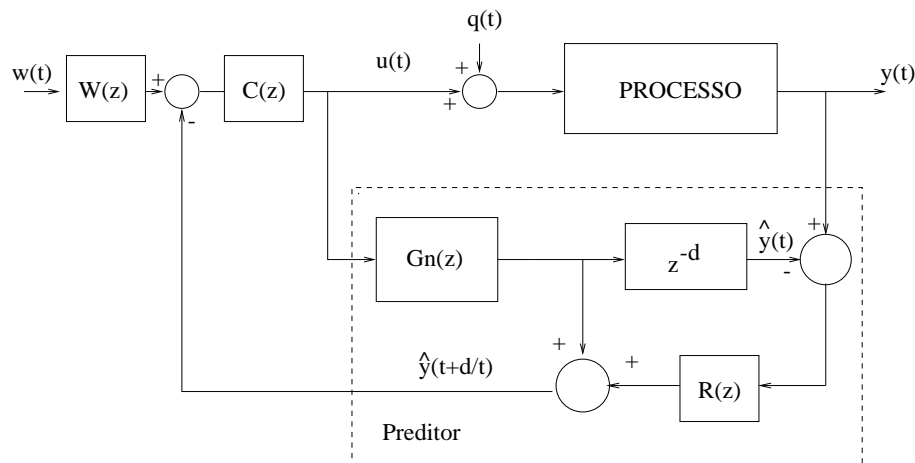


Figura 3.1: Representação do GPC como controlador primário mais preditor.

No entanto, sabe-se que o algoritmo MPC mais utilizado na indústria atualmente é o DMC [82, 85], em especial porque o cálculo da previsão é feito com base no modelo de resposta em malha aberta do processo. Assim, uma análise comparativa entre DMC, GPC e SPGPC é interessante, pois possibilita avaliar que algoritmo é mais robusto para trabalhar em aplicações reais. Com base nos resultados obtidos em [61], busca-se aqui comprovar que o algoritmo DMC também pode ser descrito como um controlador primário e um preditor, quando controlando processos com atraso. Este resultado possibilita analisar e comparar analiticamente os índices de robustez dos três controladores.

Assim, este capítulo está organizado da seguinte forma. Inicialmente, demonstra-se como a estrutura do DMC equivale a um sistema composto por um controlador primário mais um preditor, para sistemas monovariáveis. Na seqüência, os resultados desta análise são utilizados para comparar o comportamento em malha fechada e a robustez do DMC em relação aos controladores GPC e SPGPC. A generalização dos resultados obtidos é realizada para o caso multivariável. A continuação, apresentam-se ensaios simulados e práticos que ilustram

os estudos comparativos realizados. Ao final do capítulo, uma aplicação real de controle preditivo com restrições para um processo com atraso é apresentada.

3.2 DMC para Processos com Atraso

Nesta seção, apresenta-se inicialmente a representação do DMC como um controlador primário mais um preditor. A partir desta representação é realizada uma análise comparativa entre GPC e DMC, onde são discutidos os problemas da ordem do controle, do efeito do atraso e do erro de medição do mesmo. Comprova-se que os dois algoritmos diferem somente no cálculo da resposta livre. O comportamento dinâmico dos controladores também é estudado via simulação, analisando-se a robustez do controle frente a variações paramétricas na planta. Os resultados obtidos permitem comparar o comportamento em malha fechada do GPC, SPGPC e DMC, quando controlam processos com atraso. Outras informações sobre o resultado deste trabalho podem ser obtidas nos artigos [93, 94].

3.2.1 Representação para Processos Monovariáveis

Para efeito de cálculo, considere um processo monovariável descrito pela resposta em malha aberta do sistema:

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

ou ainda, pela função de transferência discreta:

$$P_n(z) = \frac{B(z^{-1})z^{-1}}{A(z^{-1})} z^{-d} \quad (3.1)$$

onde d é o atraso do sistema, e $A(z^{-1})$ e $B(z^{-1})$ são polinômios de ordem na e nb , respectivamente, dados por:

$$\begin{aligned} A(z^{-1}) &= 1 - a_1 z^{-1} - a_2 z^{-2} - \dots - a_{na} z^{-na}, \\ B(z^{-1}) &= b_0 + b_1 z^{-1} + b_2 z^{-2} + \dots + b_{nb} z^{-nb}. \end{aligned}$$

Para esses processos, é interessante obter um equacionamento do algoritmo DMC no sentido de explicitar o efeito do atraso no controlador, e poder avaliar sua influência no comportamento em malha fechada do sistema. Para tanto, escreve-se a predição no futuro em um tempo $t+k$ em função das predições até o tempo de atraso.

Considerando o modelo de resposta ao degrau, utilizado pelo DMC, os valores preditos ao longo do horizonte são:

$$\hat{y}(t+k | t) = \sum_{i=1}^{\infty} g_i \Delta u(t+k-i) + y(t) + \sum_{i=1}^N (g_{k+i} - g_i) \Delta u(t-i) \quad (3.2)$$

Note que, apesar dos elementos g_i serem obtidos pela resposta em malha aberta ao degrau, podem ser igualmente descritos pelos parâmetros da função de transferência do sistema (3.1) como sendo:

$$g_j = \sum_{i=1}^j a_i g_{j-i} + \sum_{i=0}^{j-1} b_i \quad j = 1 \dots N$$

onde N é o horizonte de controle e a_i, b_i são os coeficientes de $A(z^{-1})$ e $B(z^{-1})$, respectivamente. Note que $a_i = 0$ se $i > na$, $b_i = 0$ se $i > nb$, e $g_j = 0$ se $j \leq 0$.

Entretanto, as predições podem ser calculadas recursivamente ao longo do horizonte de predição N ($k = 1, \dots, k = d, \dots, k = N + d$), enfatizando o tempo de atraso d . Destaca-se que o DMC normalmente não utiliza o conhecimento do atraso para determinar o modelo nem o controle. Como no cálculo do controle $N_u \leq N$ para o DMC, sem perda de generalidade, assume-se $N_u = N$. Usando esta idéia, obtém-se:

$$\begin{aligned} \hat{y}(t+1 | t) &= g_1 \Delta u(t) + y(t) + (g_2 - g_1) \Delta u(t-1) + (g_3 - g_2) \Delta u(t-2) + \\ &\quad + \dots + (g_{N+1} - g_N) \Delta u(t-N) \\ \hat{y}(t+2 | t) &= g_2 \Delta u(t) + g_1 \Delta u(t+1) + \Delta u(t+1) + y(t) + (g_3 - g_1) \Delta u(t-1) + \\ &\quad + (g_4 - g_2) \Delta u(t-2) + \dots + (g_{N+2} - g_N) \Delta u(t-N) \\ &\quad \vdots \\ \hat{y}(t+d | t) &= g_1 \Delta u(t+d-1) + g_2 \Delta u(t+d-2) + \dots + g_d \Delta u(t) + y(t) + \\ &\quad + (g_{d+1} - g_1) \Delta u(t-1) + \dots + (g_{N+d} - g_N) \Delta u(t-N) \\ \hat{y}(t+d+1 | t) &= g_1 \Delta u(t+d) + g_2 \Delta u(t+d-1) + \dots + g_{d+1} \Delta u(t) + y(t) + \\ &\quad + (g_{d+2} - g_1) \Delta u(t-1) + \dots + (g_{N+d+1} - g_N) \Delta u(t-N) \\ \hat{y}(t+d+2 | t) &= g_1 \Delta u(t+d+1) + \dots + g_d \Delta u(t+2) + g_{d+1} \Delta u(t+1) + \\ &\quad + g_{d+2} \Delta u(t) + y(t) + (g_{d+3} - g_1) \Delta u(t-1) + \dots + \\ &\quad + (g_{N+d+2} - g_N) \Delta u(t-N) \\ &\quad \vdots \\ \hat{y}(t+d+N | t) &= g_1 \Delta u(t+d+N-1) + \dots + g_d \Delta u(t+N) + g_{d+1} \Delta u(t+N-1) + \\ &\quad + \dots + g_{d+N} \Delta u(t) + y(t) + (g_{d+N+1} - g_1) \Delta u(t-1) + \dots \\ &\quad + (g_{2N+d} - g_N) \Delta u(t-N) \end{aligned}$$

Na forma vetorial, tem-se:

$$\begin{bmatrix} \hat{y}(t+1|t) \\ \vdots \\ \hat{y}(t+d|t) \\ \hat{y}(t+d+1|t) \\ \vdots \\ \hat{y}(t+d+N|t) \end{bmatrix} = \mathbf{G}^\bullet \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \vdots \\ \Delta u(t+N-1) \end{bmatrix} + \mathbf{H}^\bullet \begin{bmatrix} \Delta u(t-1) \\ \Delta u(t-2) \\ \vdots \\ \Delta u(t-N) \end{bmatrix} + \mathbf{S}^\bullet [y(t)] \quad (3.3)$$

onde \mathbf{G}^\bullet , \mathbf{H}^\bullet e \mathbf{S}^\bullet são matrizes constantes de dimensão $(N+d) \times N$, $(N+d) \times N$ e $N \times 1$, respectivamente, dadas por:

$$\mathbf{G}^\bullet = \begin{bmatrix} g_1 & 0 & \dots & 0 \\ g_2 & g_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_d & g_{d-1} & \dots & g_1 \\ g_{d+1} & g_d & \dots & g_2 \\ \vdots & \vdots & \ddots & \vdots \\ g_{d+N} & g_{d+N-1} & \dots & g_{d+1} \end{bmatrix}, \quad \mathbf{S}^\bullet = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \\ 1 \\ \vdots \\ 1 \end{bmatrix},$$

$$\mathbf{H}^\bullet = \begin{bmatrix} (g_2 - g_1) & (g_3 - g_2) & \dots & (g_{N+1} - g_N) \\ (g_3 - g_1) & (g_4 - g_2) & \dots & (g_{N+2} - g_N) \\ \vdots & \vdots & \ddots & \vdots \\ (g_{d+1} - g_1) & (g_{d+2} - g_2) & \dots & (g_{N+d} - g_N) \\ (g_{d+2} - g_1) & (g_{d+3} - g_2) & \dots & (g_{N+d+1} - g_N) \\ \vdots & \vdots & \ddots & \vdots \\ (g_{d+N+1} - g_1) & (g_{d+N+2} - g_2) & \dots & (g_{2N+d} - g_N) \end{bmatrix}$$

Note que o horizonte de saída mínimo para o cálculo da função custo deve ser um valor maior que o tempo morto d , já que a saída do sistema não é afetada pelo sinal $u(t)$ para valores menores que $t = d$. Sendo assim, o primeiro sinal predito a ser utilizado na otimização será apenas em $\hat{y}(t+d+1|t)$, o que permite reescrever a equação de predição (3.3) em função de $\hat{y}(t+d|t)$ conhecido, resultando:

$$\begin{bmatrix} \hat{y}(t+d+1|t) \\ \hat{y}(t+d+2|t) \\ \vdots \\ \hat{y}(t+d+N|t) \end{bmatrix} = \mathbf{G} \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \vdots \\ \Delta u(t+N-1) \end{bmatrix} + \mathbf{H} \begin{bmatrix} \Delta u(t-1) \\ \Delta u(t-2) \\ \vdots \\ \Delta u(t-N) \end{bmatrix} + \mathbf{S} [\hat{y}(t+d|t)] \quad (3.4)$$

onde \mathbf{S} é um vetor unitário de dimensão $N \times 1$ e \mathbf{G} , \mathbf{H} são matrizes constantes de dimensão $N \times N$, dadas por:

$$\mathbf{G} = \begin{bmatrix} g_{d+1} & 0 & \dots & 0 \\ g_{d+2} & g_{d+1} & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_{d+N-1} & g_{d+N-2} & \dots & 0 \\ g_{d+N} & g_{d+N-1} & \dots & g_{d+1} \end{bmatrix}, \quad \mathbf{S} = \begin{bmatrix} 1 \\ 1 \\ \vdots \\ 1 \\ 1 \end{bmatrix},$$

$$\mathbf{H} = \begin{bmatrix} (g_{d+2} - g_{d+1}) & (g_{d+3} - g_{d+2}) & \dots & (g_{d+N+1} - g_{d+N}) \\ (g_{d+3} - g_{d+1}) & (g_{d+4} - g_{d+2}) & \dots & (g_{d+N+2} - g_{d+N}) \\ \vdots & \vdots & \ddots & \vdots \\ (g_{d+N+1} - g_{d+1}) & (g_{d+N+2} - g_{d+2}) & \dots & (g_{d+2N} - g_{d+N}) \end{bmatrix}$$

Como a matriz \mathbf{G} é calculada em função da resposta ao degrau do sistema, os valores g_1, g_2, \dots, g_d são nulos, pois até o instante $d+1$ o sistema não evolue. Assim, o primeiro valor válido da matriz \mathbf{G} será g_{d+1} e pode-se mostrar que seu valor é o mesmo que ocorreria se o sistema não tivesse atraso, ou seja, $g_{d+1} = g_1$ em um sistema sem atraso. Generalizando, $g_{d+i} = g_i$ para $i = 1, \dots, N$. Assim, as matrizes \mathbf{G} e \mathbf{H} da equação (3.4) passam a ser descritas por:

$$\mathbf{G} = \begin{bmatrix} g_1 & 0 & \dots & 0 \\ g_2 & g_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_N & g_{N-1} & \dots & g_1 \end{bmatrix} \quad (3.5)$$

$$\mathbf{H} = \begin{bmatrix} (g_2 - g_1) & \dots & (g_{N+1} - g_N) \\ (g_3 - g_1) & \dots & (g_{N+2} - g_N) \\ \vdots & \ddots & \vdots \\ (g_{N+1} - g_1) & \dots & (g_{2N} - g_N) \end{bmatrix}$$

A equação (3.4) pode ser escrita de forma vetorial como:

$$\hat{\mathbf{y}} = \mathbf{G} \mathbf{u} + \mathbf{H} \mathbf{u}_1 + \mathbf{S} \mathbf{y}_1 \quad (3.6)$$

onde:

$$\begin{aligned} \hat{\mathbf{y}} &= [\hat{y}(t+d+1|t) \dots \hat{y}(t+d+N|t)]' \\ \mathbf{u} &= [\Delta u(t) \Delta u(t+1) \dots \Delta u(t+N-1)]' \\ \mathbf{u}_1 &= [\Delta u(t-1) \Delta u(t-2) \dots \Delta u(t-N)]' \\ \mathbf{y}_1 &= \hat{y}(t+d|t) \end{aligned}$$

Os termos que dependem dos controles passados são dados por $\mathbf{f} = \mathbf{H} \mathbf{u}_1 + \mathbf{S} \mathbf{y}_1$ e correspondem à resposta livre do sistema, que é a que se obteria se o sinal de controle futuro se mantivesse constante ($\Delta u(t+i) = 0 \quad \forall i \geq 0$). Deve-se notar ainda que a matriz \mathbf{G} obtida na equação (3.5) é equivalente a matriz \mathbf{G} usado no algoritmo GPC (ver apêndice A).

Lembrando que a função objetivo do DMC é dada por:

$$J = \sum_{j=d+1}^{d+N} [\hat{y}(t+j|t) - w(t+j)]^2 + \sum_{j=1}^N \lambda(j) [\Delta u(t+j-1)]^2 \quad (3.7)$$

Ao substituir-se $\hat{\mathbf{y}}$ em (3.7), J pode ser expressa em função da seqüência de referência $\mathbf{w} = [w(t+d+1) \dots w(t+d+N)]'$ e dos vetores \mathbf{u} , \mathbf{u}_1 , \mathbf{y}_1 :

$$J = (\mathbf{G} \mathbf{u} + \mathbf{H} \mathbf{u}_1 + \mathbf{S} \mathbf{y}_1 - \mathbf{w})' (\mathbf{G} \mathbf{u} + \mathbf{H} \mathbf{u}_1 + \mathbf{S} \mathbf{y}_1 - \mathbf{w}) + \mathbf{u}' \mathbf{Q}_\lambda \mathbf{u} \quad (3.8)$$

onde a matriz \mathbf{Q}_λ é a matriz diagonal $N \times N$ de ponderação do esforço de controle. Seu elemento, $\lambda(j)$ é considerado constante, ou seja, $\lambda(j) = \lambda$.

Através de algumas manipulações algébricas, J pode ser escrito como:

$$\begin{aligned} J &= \mathbf{u}' (\mathbf{Q}_\lambda + \mathbf{G}' \mathbf{G}) \mathbf{u} + 2(\mathbf{H} \mathbf{u}_1 + \mathbf{S} \mathbf{y}_1 - \mathbf{w})' \mathbf{G} \mathbf{u} + \\ &\quad (\mathbf{H} \mathbf{u}_1 + \mathbf{S} \mathbf{y}_1 - \mathbf{w})' (\mathbf{H} \mathbf{u}_1 + \mathbf{S} \mathbf{y}_1 - \mathbf{w}) \end{aligned} \quad (3.9)$$

Minimizando J com relação ao vetor \mathbf{u} , obtém-se:

$$M \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \vdots \\ \Delta u(t+N-1) \end{bmatrix} = P_0 \left[\hat{y}(t+d|t) \right] + P_1 \begin{bmatrix} \Delta u(t-1) \\ \Delta u(t-2) \\ \vdots \\ \Delta u(t-N) \end{bmatrix} + P_2 \begin{bmatrix} w(t+d+1) \\ w(t+d+2) \\ \vdots \\ w(t+d+N) \end{bmatrix}$$

ou ainda:

$$\mathbf{M} \mathbf{u} = \mathbf{P}_0 [\hat{y}(t + d | t)] + \mathbf{P}_1 \mathbf{u}_1 + \mathbf{P}_2 \mathbf{w} \quad (3.10)$$

onde $\mathbf{M} = \mathbf{G}'\mathbf{G} + \mathbf{Q}_\lambda$, $\mathbf{P}_1 = -\mathbf{G}'\mathbf{H}$ e $\mathbf{P}_2 = \mathbf{G}'$ têm dimensão $N \times N$ e $\mathbf{P}_0 = -\mathbf{G}'\mathbf{S}$ tem dimensão $N \times 1$.

Como o algoritmo DMC utiliza a estratégia de horizonte deslizante, somente $\Delta u(t)$ é aplicada ao sistema. Portanto, se \mathbf{m} é a primeira linha de \mathbf{M}^{-1} , calcula-se $\Delta u(t)$ como:

$$\Delta u(t) = \mathbf{m}\mathbf{P}_0 [\hat{y}(t + d | t)] + \mathbf{m}\mathbf{P}_1 \mathbf{u}_1 + \mathbf{m}\mathbf{P}_2 \mathbf{w}$$

Assim, $\Delta u(t)$ é dado por:

$$\begin{aligned} \Delta u(t) = & ly \hat{y}(t + d | t) + lu_1 \Delta u(t - 1) + lu_2 \Delta u(t - 2) + \dots + \\ & + lu_N \Delta u(t - N) + \sum_{i=1}^N f_i w(t + d + i) \end{aligned} \quad (3.11)$$

onde $\mathbf{m}\mathbf{P}_0 = [ly]$, $\mathbf{m}\mathbf{P}_1 = [lu_1 \ lu_2 \ \dots \ lu_N]$ e $f_i = \sum_{j=1}^N m_j r_{ji}$; r_{ji} são os elementos de \mathbf{P}_2 e m_j os elementos de \mathbf{m} . Os coeficientes ly , lu_i e f_i são funções dos parâmetros $A(z^{-1})$, $B(z^{-1})$, λ e N .

A figura 3.2 mostra o esquema de controle resultante.

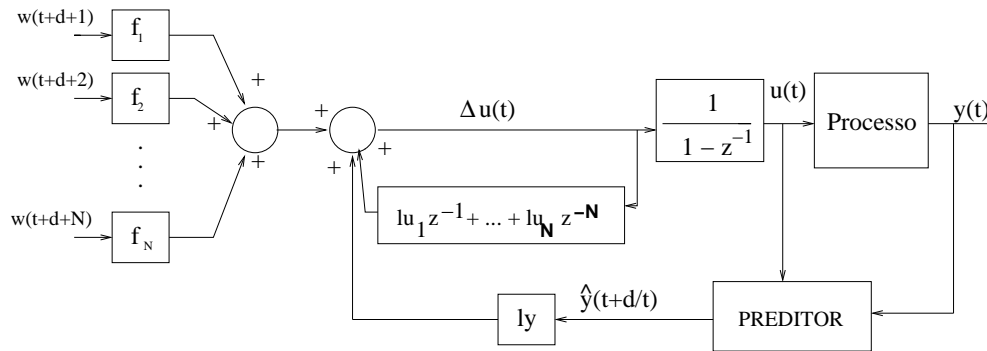


Figura 3.2: Esquema de controle do DMC.

Quando a referência futura é desconhecida, assume-se $w(t + d + i)$ igual a referência atual $r(t)$:

$$\mathbf{w} = [1 \ \dots \ 1]r(t)$$

Desta forma, o último termo de $\Delta u(t)$ passa a ser escrito como:

$$\sum_{i=1}^N f_i w(t + d + i) = \sum_{i=1}^N f_i r(t) = l_r r(t) \quad (3.12)$$

Considerando (3.12), o incremento do controle $\Delta u(t)$ é dado por:

$$\begin{aligned} \Delta u(t) = & l_y \hat{y}(t+d|t) + lu_1 \Delta u(t-1) + lu_2 \Delta u(t-2) + \dots + \\ & + lu_N \Delta u(t-N) + l_r r(t) \end{aligned} \quad (3.13)$$

A estrutura de controle, representada na figura 3.2, é utilizada apenas para análise do algoritmo, pois, na prática, a lei de controle é calculada usando a resposta livre e forçada do sistema. Neste caso, calcula-se a predição como:

$$\hat{\mathbf{y}} = \mathbf{G} \mathbf{u} + \mathbf{f} \quad (3.14)$$

e a lei de controle final, com \mathbf{K} representando a matriz de ganhos do controlador, é dada por:

$$\Delta u(t) = (\mathbf{G}'\mathbf{G} + \mathbf{Q}_\lambda)^{-1} \mathbf{G}'(\mathbf{f} - \mathbf{w}) = \mathbf{K}(\mathbf{f} - \mathbf{w}) \quad (3.15)$$

Esse resultado é equivalente ao encontrado para o algoritmo GPC [61], comprovando, através de uma abordagem diferente, o conhecido resultado que os algoritmos DMC e GPC somente diferem na resposta livre do sistema.

Para completar a análise, é necessário calcular a relação entre a entrada e saída do processo com a predição em $t+d$. Como foi demonstrado em [93], é possível calcular uma relação direta entre a predição para o DMC e os valores da saída e entrada da planta no instante t , utilizando a informação do erro de modelagem do processo $e(t)$:

$$\begin{aligned} \hat{y}(t+k|t) = & [z(1-A(z^{-1}))]^k y(t) + B(z^{-1}) \sum_{i=0}^{k-1} [z(1-A(z^{-1}))]^{k-i-1} u(t-d+i) + \\ & + \sum_{i=0}^{k-1} [z(1-A(z^{-1}))]^i e(t) \end{aligned} \quad (3.16)$$

Considerando que o modelo do processo, dado por $P_n(z)$, apresentado pela equação (3.1) difere da planta real $P(z)$, assume-se que o erro $e(t)$ é constante em todo instante t , sendo descrito por:

$$e(t) = y(t) - P_n(z) u(t) = y(t) - \left(\frac{B(z^{-1})z^{-1}}{A(z^{-1})} z^{-d} \right) u(t) \quad (3.17)$$

Se a equação (3.16) for aplicada para $k = d$:

$$\begin{aligned} \hat{y}(t+d|t) = & [z(1-A(z^{-1}))]^d y(t) + B(z^{-1}) \sum_{i=0}^{d-1} [z(1-A(z^{-1}))]^{d-i-1} u(t-d+i) + \\ & + \sum_{i=0}^{d-1} [z(1-A(z^{-1}))]^i e(t) \end{aligned} \quad (3.18)$$

Calculando os somatórios presentes na equação (3.18), obtém-se:

$$\hat{y}(t+d | t) = [z(1 - A(z^{-1}))]^d y(t) + B(z^{-1})z^{-1}(1 - A(z^{-1}))^{d-1} \left[\frac{1 - \frac{1}{(1-A(z^{-1}))^d}}{1 - \frac{1}{(1-A(z^{-1}))}} \right] u(t) + \left[\frac{1 - [z(1 - A(z^{-1}))]^d}{1 - [z(1 - A(z^{-1}))]} \right] e(t) \quad (3.19)$$

Substituindo a equação do erro de modelagem (3.17) em (3.19), a expressão resultante é:

$$\hat{y}(t+d | t) = R(z)y(t) + Q(z)u(t) \quad (3.20)$$

onde:

$$Q(z) = \frac{B(z^{-1})z^{-1}}{A(z^{-1})} z^{-d} \left[z^d + \left(\frac{[z(1 - A(z^{-1}))]^{d+1} - 1}{1 - [z(1 - A(z^{-1}))]} \right) \right]$$

e $R(z)$ é um filtro que se calcula como:

$$R(z) = \frac{1 - [z(1 - A(z^{-1}))]^{d+1}}{1 - [z(1 - A(z^{-1}))]} \quad (3.21)$$

Além disso, pode-se observar que é possível calcular $Q(z)$ como:

$$Q(z) = G_n(z) - P_n(z) R(z) = G_n(z) [1 - z^{-d} R(z)] \quad (3.22)$$

onde $G_n(z)$ representa o modelo do processo sem o atraso d .

Usando essas expressões e uma transformação de diagrama de blocos, o sistema de controle pode ser representado como na figura 3.3, onde o par $C(z)$, $W(z)$ representa o controlador primário de dois graus de liberdade:

$$C(z) = \frac{l_y}{(1 - z^{-1})(1 - l_{u_1}z^{-1} - l_{u_2}z^{-2} - \dots - l_{u_N}z^{-N})} \quad (3.23)$$

$$W(z) = \frac{l_r}{l_y} \quad (3.24)$$

Observa-se que este esquema é equivalente ao apresentado na figura 3.1 para o GPC.

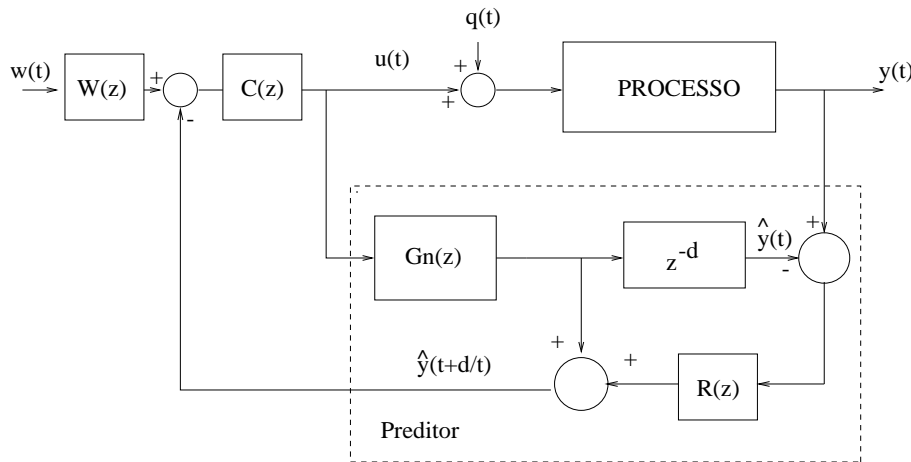


Figura 3.3: Estrutura de controle equivalente ao DMC.

A estrutura de controle obtida é equivalente a um compensador de atraso com dois graus de liberdade, similar a um preditor de Smith (SP). Note que, se $R(z) = 1$ e $W(z) = 1$, tem-se o SP clássico. Se $R(z) \neq 1$, uma versão modificada do SP é obtida, onde $R(z)$ é usado para melhorar a robustez ou a rejeição de perturbação do sistema [64]. É importante ressaltar que, para o DMC, o filtro $R(z)$ não é um parâmetro de ajuste, mas uma função do atraso d e do polinômio $A(z^{-1})$ do modelo do processo. Também deve-se enfatizar que: (i) se o atraso é zero, a lei de controle final é uma lei de controle clássica; (ii) o ajuste dos controladores, dado pelos parâmetros N e λ , afeta apenas os coeficientes do controle primário, já que as previsões somente dependem do modelo do processo e do modelo das perturbações usado no preditor.

Os resultados dessa análise são interessantes, pois permitem estudar claramente o efeito do atraso na estrutura do DMC e assim ter um melhor entendimento das qualidades e inconvenientes do DMC quando controlando processos com atraso.

Na próxima seção, uma análise da robustez do DMC e um estudo comparativo ao GPC e o SPGPC são realizados. Atenção especial será dada aos erros de estimação do atraso, porque eles são um das principais fontes de incerteza em altas frequências encontradas em processos industriais.

Análise de Robustez

Para considerar o efeito dos erros de modelagem, um modelo aditivo não-estruturado das incertezas ($P(z) = P_n(z) + DP(z)$) é usado [59]. De agora em diante, d_n será o atraso nominal, $P_n = G_n z^{-d_n}$ será o modelo nominal do processo e $DP(z)$, o erro de

modelagem. Sob esta hipótese, é possível calcular (tanto para o DMC quanto para o GPC) uma medida da robustez do sistema de controle considerando, para cada frequência, o módulo do erro máximo que mantém a estabilidade do sistema em malha fechada [59]. O índice de robustez I_r pode ser calculado através de:

$$I_r(\omega) = \frac{|1 + C(e^{j\omega})G_n(e^{j\omega})|}{|C(e^{j\omega})R(e^{j\omega})|}, \quad \forall \omega > 0 \quad (3.25)$$

Como o GPC e o SPGPC também podem ser representados usando o diagrama de blocos da figura 3.3, este índice de robustez também é válido para estes controladores, usando os apropriados $C(e^{j\omega})$ e $R(e^{j\omega})$ [68].

Para a análise comparativa, assume-se que os controladores primários foram ajustados a fim de se obter o mesmo desempenho nominal, tanto para GPC e o SPGPC quanto para DMC. Assim, faz-se o ajuste de $C(z)$ e $W(z)$ para definir um determinado comportamento no caso nominal. Isto pode ser obtido usando uma função de sensibilidade complementar definida por (para simplificar as expressões, de agora em diante, a dependência com ω , z ou z^{-1} será omitida):

$$I_p = \frac{|CG_n|}{|1 + CG_n|}$$

Isto implica:

$$I_r = \frac{|1 + CG_n|}{|CR|} = \frac{|G_n|}{|I_p R|}$$

Assim, a robustez do GPC (SPGPC) e do DMC pode ser comparada, para um mesmo desempenho nominal, usando:

$$I_{r_{DMC}} = \frac{|R_{GPC}|}{|R_{DMC}|} I_{r_{GPC}} \quad (3.26)$$

$$I_{r_{DMC}} = \frac{|R_{SPGPC}|}{|R_{DMC}|} I_{r_{SPGPC}} \quad (3.27)$$

A partir das equações (3.26) e (3.27), observa-se que o polinômio R pode ser usado como índice comparativo de comportamento dos controladores. Observa-se ainda que o SPGPC, por utilizar o preditor de Smith no cálculo da previsão, apresenta $R_{SPGPC} = 1$. Além disto, é mostrado em [61] que o módulo de R_{GPC} é maior que a unidade para toda frequência,

independente da ordem escolhida do sistema, concluindo-se que o sistema controlado pelo SPGPC será sempre mais robusto do que quando controlado pelo GPC.

A análise da robustez dos controladores MPC será feita com base apenas no polinômio R , denominado filtro de robustez. Segundo [61], pode-se demonstrar que ao ajustar o sistema de controle para melhorar a robustez, deteriora-se sua resposta de rejeição a perturbações. Por esse motivo, pode-se usar esta expressão para obter, simultaneamente, informações de robustez e rejeição de perturbações do sistema em malha fechada.

Conforme visto na equação (3.21), o filtro R para o DMC é dado por:

$$R_{DMC} = \frac{1 - [z(1 - A(z^{-1}))]^{d+1}}{1 - [z(1 - A(z^{-1}))]}$$

Considerando um mesmo modelo de processo monovariável, segundo a equação (3.1), o filtro R do GPC é descrito por [61]:

$$R_{GPC} = [z(1 - \tilde{A}(z^{-1}))]^d \quad (3.28)$$

onde $\tilde{A}(z^{-1})$ representa o polinômio $A(z^{-1})$ multiplicado por $\Delta = 1 - z^{-1}$.

Analisando as expressões de R_{GPC} e R_{DMC} , observa-se que estas somente são afetadas pelo polinômio A e o atraso d . Deve destacar-se que d não altera o ajuste do controle primário, tanto no caso do GPC quanto no DMC. Para a análise da robustez, utiliza-se o atraso nominal, ou seja, $d = d_n$.

Devido a complexidade das expressões de R , não é possível extrair conclusões gerais sobre o valor de seu módulo em função da frequência. Do ponto de vista prático, é interessante analisar os modelos de processo mais utilizados nos meios industriais para sistemas monovariáveis.

Levando em consideração que um modelo composto por uma função de transferência de baixa ordem mais um elemento de atraso é a representação mais utilizada no ajuste dos controladores comerciais, analisa-se a robustez. Em geral, uma função de transferência de primeira ou segunda ordem é suficiente para descrever com boa aproximação a maioria dos processos na indústria. Em geral, os parâmetros do modelo são obtidos usando o conhecido método de identificação por resposta ao degrau [10]. Assim, analisa-se o módulo de R (índices de robustez) para modelos de primeira ordem com atraso e de segunda ordem com atraso. O mesmo procedimento e modelos, utilizados para o estudo comparativo do GPC com o SPGPC realizado em [61], aqui são incluídos através das seguintes considerações:

- O modelo da planta é descrito por uma das funções de transferência:

– primeira ordem com atraso:

$$G(s) = \frac{K}{1 + \tau s} e^{-\tau_d s}$$

– segunda ordem com atraso:

$$G(s) = \frac{k(1 + \beta s)e^{-t_d s}}{1 + \alpha_1 s + \alpha_2 s^2}$$

com $k, \tau, \beta, \alpha_1, \alpha_2, t_d$ reais.

- Ao discretizar a função de transferência, assume-se que o período de amostragem T é escolhido corretamente, ou seja entre $1/20$ e $1/5$ da constante de tempo dominante do processo [61].

Com base nestas considerações, pode-se afirmar que:

1. Para o modelo de primeira ordem com atraso, como $a_1 > 0$, obtém-se para o GPC:

$$|R_{GPC}| = |(1 - a_1) + a_1 e^{-j\omega} |^{d_n}, \forall \omega$$

Nesse caso, $|R_{GPC}| \geq 1$ para todas as frequências (note que a soma dos vetores $(1 - a_1)$ e $(a_1 e^{-j\omega})$ será sempre maior que um), conforme provado em [61].

Para o DMC, o filtro $R(z)$ é dado pela equação (3.21), assim:

$$|R_{DMC}| = \frac{|1 - a_1^{d_n+1}|}{|1 - a_1|}, \forall \omega$$

que mostra que $|R_{DMC}|$ é um valor constante, sempre maior que um.

Como ambos controladores apresentam $|R| > 1$, pode-se concluir analiticamente que o SPGPC apresenta melhor índice de robustez que o GPC e o DMC para o caso de primeira ordem. Já que não é possível comparar os índices de robustez do GPC e do DMC analiticamente, realizam-se diversas simulações, considerando diferentes valores de a_1 , para demonstrar a robustez frente às variações paramétricas da planta. Um exemplo típico de simulação encontra-se na figura 3.4. Esta figura mostra os valores de $|1/R|$ para o GPC, o DMC e o SPGPC, para um valor típico de $a_1 = 0.9$, juntamente com o erro de modelagem DP , quando uma variação de 20% no atraso e de 10% na estimação do ganho e da constante de tempo (o atraso nominal é $d_n = 10$ e o ganho nominal é 1) são consideradas. Como pode-se ver, o DMC apresenta melhores resultados, já que o valor do $|1/R|$ para o GPC decresce muito mais rapidamente para as altas frequências. Da equação (3.26), é fácil observar que esta diferença será ainda




Figura 3.4: Robustez do GPC, do SPGPC e do DMC para processos de 1^a. ordem com atraso.

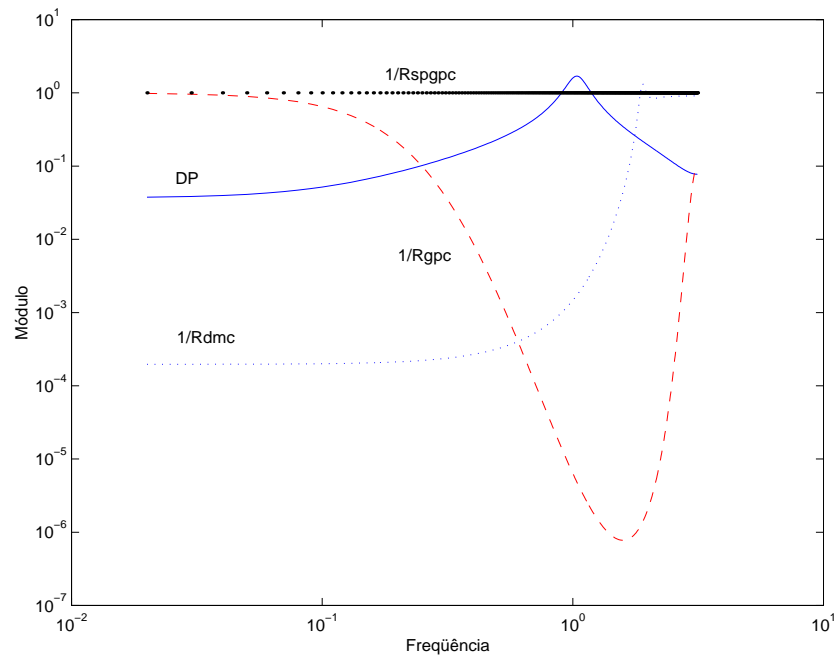


Figura 3.5: Robustez do GPC, do SPGPC e do DMC para processos de 2^a. ordem com atraso.

mais alta para o caso de grandes atrasos. Assim, esses resultados mostram que o DMC é mais robusto do que o GPC para controlar processos de primeira ordem com atraso dominante. Também verifica-se que o SPGPC é mais apropriado do que os outros controladores MPC para controlar plantas estáveis com dinâmica de primeira ordem com atraso.

2. Para o modelo de ordem 2:

$$|R_{GPC}(j\omega)| = (|(1 + a_1) + (a_2 - a_1)e^{-j\omega} - a_2e^{-2j\omega}|)^{d_n}, \quad \forall \omega$$

$$|R_{DMC}(j\omega)| = \frac{|1 - (a_1 + a_2e^{-j\omega})^{d_n+1}|}{|1 - (a_1 + a_2e^{-j\omega})|}, \quad \forall \omega$$

No caso do GPC, observa-se que: para $\omega = 0$, $|R_{GPC}| = 1 \forall a_1$ e a_2 ; e para $\omega = \pi$, $|R_{GPC}| = (|2a_1 - 1 - 2a_2|)^{d_n} > 1 \forall a_1 < 0$ e $a_2 > 0$. Assim, se $|R_{GPC}|$ é monótona, a condição $|R_{GPC}(j\omega)| > 1$ é válida, $\forall \omega$, como mostrado em [61]. No caso do DMC, para $\omega = 0$, recai-se num caso equivalente ao de primeira ordem, com $|R_{DMC}| > 1, \forall a_1$ e a_2 . Já para diferentes valores de ω , a análise não é tão simples. Como não se pode demonstrar analiticamente, realizou-se novamente uma análise numérica do módulo de R considerando diferentes pólos, através de simulações. A figura 3.5 exemplifica os valores de $|1/R|$ para o GPC, o SPGPC e o DMC, considerando $a_1 = 0.9$ e $a_2 = 0.75$. O erro de modelagem DP está estimado em 15% no valor do atraso nominal ($d_n = 15$). Como pode ser observado, fica difícil avaliar a qualidade da robustez dos controladores. No entanto, vale salientar que o sistema de controle é bastante conservativo em baixas frequências, zona onde o GPC apresenta índice de robustez equivalente ao SPGPC. Já o DMC apresenta índices de robustez superiores ao GPC em médias e altas frequências, zona onde, em geral, verificam-se as incertezas paramétricas. O SPGPC, por apresentar $R = 1$, é o controlador mais robusto em todas as simulações realizadas para este caso. Além disto, esses resultados mostram que o DMC parece ser mais apropriado do que o GPC para controlar processos de segunda ordem com atraso.

Em geral, pela análise dos casos de primeira e segunda ordem, pode-se concluir que, comparativamente ao DMC e ao GPC, o controlador SPGPC apresenta melhor índice de robustez, no controle de processos com atraso, quando estes estão bem representados por sistemas de baixa ordem. Pela presente análise:

$$I_{r_{SPGPC}} > I_{r_{DMC}} > I_{r_{GPC}} \quad (3.29)$$

Este resultado justifica a escolha do SPGPC, no controle de processos estáveis com atraso, frente aos controladores DMC e GPC.

Além disso, é bem conhecido que o uso de filtros pode melhorar a robustez dos controladores [112]. Quando se trabalha com o GPC, um polinômio T pode ser usado como filtro para modificar a equação da predição e influenciar a estabilidade robusta (ver apêndice A). Nesse caso, as predições não são ótimas, mas a robustez frente às incertezas pode ser alcançada. Por outro lado, T pode desajustar a resposta no caso de perturbações de carga não mensuráveis [22]. No caso do SPGPC, é possível incluir um filtro de robustez à saída da estrutura do controlador. Este filtro pode ser usado para aumentar o valor do índice de robustez do SPGPC, seguindo regras de ajuste apresentadas em [61], de maneira a mantê-lo sempre maior que o módulo das incertezas da planta. Já para o DMC, poderia-se incluir um filtro passa-baixa no algoritmo, atuando sobre o erro de predição [58]. O ajuste desses filtros deve ser feito para obter o melhor compromisso entre a robustez e a rejeição de perturbação.

Com relação à rejeição de perturbações, pode-se concluir que:

- se as perturbações são em alta frequência, então o GPC as rejeita mais rapidamente que o DMC, desde que o sistema em malha fechada seja estável [66]. Assim, não é possível melhorar a robustez e a rejeição de perturbações em uma mesma zona de frequências.
- se as perturbações são de baixa frequência, como é usual na indústria, então a velocidade da rejeição do GPC é superior a do DMC, já que o valor do módulo de R_{GPC} está próximo da unidade para este caso.

3.2.2 Aplicação à Planta Piloto: Controle de Temperatura

Para ilustrar a robustez e o desempenho dos controladores MPC em análise, alguns resultados de simulação, comparando o DMC ao GPC e ao SPGPC são apresentados. A implementação dos algoritmos MPC pode ser vista no anexo A. A simulação foi desenvolvida com base no modelo de uma planta piloto existente no Departamento de Engenharia de Sistemas e Automática da Universidade de Sevilla, Espanha. A idéia é controlar a temperatura TT4 da saída do trocador de calor da planta piloto, através do fluxo de água de recirculação que pode ser controlado pelo acionamento da válvula de controle v8, conforme mostra a figura 3.6. Observa-se que o atraso do sistema depende da localização do sensor de temperatura TT4. A descrição deste processo pode ser analisada no apêndice B.

O modelo do processo, de TT4 em função de v8, foi obtido pelo método da curva de reação à resposta ao degrau, sendo dado por:

$$P_n(s) = \frac{0.11e^{-14s}}{1 + 6s}$$

O tempo de amostragem escolhido foi de $T = 1s$.

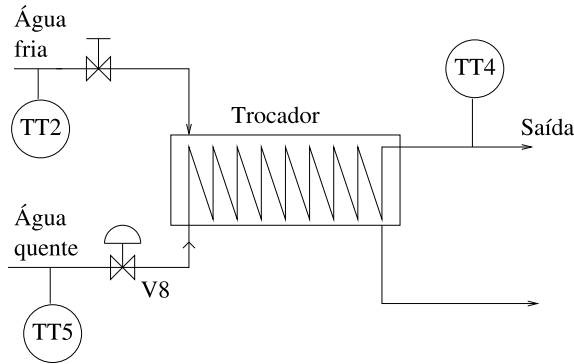


Figura 3.6: Diagrama do trocador de calor da planta piloto.

Inicialmente, não foram consideradas incertezas no modelo. Com o objetivo de obter uma resposta de malha fechada mais rápida, o peso do controle foi selecionado como $\lambda = 0.8$ e os horizontes do GPC, SPGPC e DMC foram escolhidos de modo a apresentarem uma resposta nominal similar.

O comportamento de malha fechada para os controladores, no caso nominal, pode ser visto na figura 3.7. Em todos os casos, as linhas contínuas correspondem ao SPGPC, as linhas tracejadas ao GPC e as pontilhadas ao DMC.




Figura 3.7: Resposta do sistema. Caso nominal.





Figura 3.8: Resposta do sistema. Caso com incertezas.

Figura 3.9: Resposta do sistema. Caso com incertezas (filtro T).

Para a simulação, no instante $t = 0$ foi aplicado um degrau de entrada e uma perturbação de carga tipo degrau de 10% foi incluída no sistema no instante $t = 150s$. O ruído é gerado por um modelo ARIMA com distribuição uniforme em ± 0.005 . Note que ambos os sistemas tem seguimento de referência similar e que o SPGPC e o GPC rejeitam um pouco mais rapidamente a perturbação do que o DMC.

Nas simulações seguintes, uma incerteza de 14% no atraso é considerada, sem alterar o ajuste dos controladores. O comportamento dos controladores é comparado na figura 3.8. Como pode ser observado, o DMC e o SPGPC são estáveis e o GPC é instável.

Para estabilizar a resposta do GPC, um filtro $T(z^{-1})$, descrito segundo a equação (ver apêndice A):

$$T(z^{-1}) = (1 - a_T z^{-1}), \quad 0 < a_T < 1,$$

é usado na simulação seguinte. O filtro foi ajustado com $a_T = 0.9$, o que garante um comportamento mais robusto à planta. A figura 3.9 mostra o comportamento de malha fechada do sistema controlado pelo DMC, pelo SPGPC e pelo GPC filtrado. Como pode ser visto, agora o GPC tem um comportamento estável, mas sua rejeição à perturbação é mais lenta do que a dos outros controladores.

Este exemplo de aplicação permite um melhor entendimento de alguns aspectos da operação dos controladores MPC, quando usados para controlar processos com atraso. É possível dizer que o DMC é mais robusto que o GPC, especialmente no caso de erros na estimação do atraso. Além disto, pode-se observar a elevada robustez do SPGPC, o que incentiva sua utilização nas aplicações práticas em substituição ao DMC.

3.2.3 Generalização para o Caso Multivariável

Para introduzir o DMC multivariável, procede-se como na seção 3.2.1, generalizando a representação do DMC para plantas MIMO e analisando sua estrutura como a de um preditor multivariável mais um controle primário também multivariável.

De forma geral, o modelo discreto de uma planta multivariável (com m entradas e n saídas), pode ser descrito por uma matriz função de transferência discreta $\mathbf{P}(z^{-1})$ de dimensões $n \times m$:

$$\mathbf{y}(t) = \mathbf{P}(z^{-1})\mathbf{u}(t - 1) \quad (3.30)$$

onde cada elemento $p_{ij}(z^{-1})$ de $\mathbf{P}(z^{-1})$ é uma função de transferência SISO e as variáveis $\mathbf{u}(t)$ e $\mathbf{y}(t)$ são respectivamente os vetores de entrada (de dimensão $m \times 1$) e de saída (de dimensão $n \times 1$). Com essa descrição, se o processo tem atraso entre as entradas e saídas,

as funções de transferência monovariáveis $p_{ij}(z^{-1})$ terão os primeiros coeficientes de seus polinômios numeradores iguais a zero.

Para poder aplicar o algoritmo DMC multivariável é necessário, como no caso SISO, desenvolver um modelo do processo [15]. Assim, esta análise faz-se para uma estrutura, extensão do sistema monovariável, na qual se considera que a matriz função de transferência do processo pode ser reformulada como:

$$\mathbf{P}(z^{-1}) = [\mathbf{A}(z^{-1})]^{-1} \mathbf{D}(z^{-1})\mathbf{B}(z^{-1}) \quad (3.31)$$

onde:

- $\mathbf{A}(z^{-1})$ é uma matriz diagonal. Cada elemento ii da diagonal é um polinômio $A_i(z^{-1})$ calculado como o mínimo múltiplo comum dos denominadores da linha i de $\mathbf{P}(z^{-1})$.
- $\mathbf{D}(z^{-1})$ é uma matriz diagonal de atrasos cujo elemento ii da diagonal é igual a z^{-d_i} , onde:
 - d_{ij} é o atraso da função de transferência da entrada u_j para a saída y_i ,
 - d_i é o atraso mínimo da linha i de $\mathbf{P}(z^{-1})$.
- $\mathbf{B}(z^{-1})$ é uma matriz polinomial com elementos $B_{ij}(z^{-1})$ extraídos do mínimo múltiplo comum dos denominadores, e são tais que:

$$p_{ij}(z^{-1}) = z^{-d_i} \frac{z^{-1} B_{ij}(z^{-1})}{A_i(z^{-1})} = z^{-d_i} g_{ij}(z^{-1}) \quad (3.32)$$

isto é, os $g_{ij}(z^{-1})$ são as funções de transferência SISO que relacionam a entrada j no tempo t ($u_j(t)$) com a saída i no tempo $t + d_i$ ($y_i(t + d_i)$). Além disso, os $g_{ij}(z^{-1})$ podem ser vistos como os modelos rápidos dos $p_{ij}(z^{-1})$, eliminando o atraso comum d_i . Os polinômios A_i e B_{ij} são descritos por:

$$\begin{aligned} A_i(z^{-1}) &= 1 + a_1^i z^{-1} + a_2^i z^{-2} + \dots + a_{na_i}^i z^{-na_i} \\ B_{ij}(z^{-1}) &= b_0^{ij} + b_1^{ij} z^{-1} + b_2^{ij} z^{-2} + \dots + b_{nb_{ij}}^{ij} z^{-nb_{ij}} \end{aligned}$$

Assim, $\mathbf{G}(z^{-1})$ é a matriz função de transferência sem os atrasos comuns, e verifica-se que $\mathbf{P}(z^{-1}) = \mathbf{D}(z^{-1})\mathbf{G}(z^{-1})$. Com esta representação, o preditor do controlador gerará uma saída multivariável que é a predição da saída com mínimo atraso por linha.

Usando estas considerações, o modelo do processo é dado por:

$$\mathbf{A}(z^{-1})\mathbf{y}(t) = \mathbf{D}(z^{-1})\mathbf{B}(z^{-1})\mathbf{u}(t - 1) \quad (3.33)$$

Para calcular a ação de controle do DMC-MIMO, utiliza-se uma função objetivo similar a do caso SISO [15]:

$$J = \sum_{j=N_1}^{N_2} \|\hat{\mathbf{y}}(t+j|t) - \mathbf{w}(t+j)\|_{\mathbf{Q}_\delta}^2 + \sum_{j=1}^N \|\Delta \mathbf{u}(t+j-1)\|_{\mathbf{Q}_\lambda}^2 \quad (3.34)$$

onde N_1 e N_2 são os horizontes de predição, N é o horizonte de controle, \mathbf{Q}_δ e \mathbf{Q}_λ são matrizes definidas positivas que ponderam o erro e o esforço de controle, $\|\mathbf{x}\|_{\mathbf{Q}}^2 = \mathbf{x}'\mathbf{Q}\mathbf{x}$, $\mathbf{w}(t+j)$ é a referência futura e $\hat{\mathbf{y}}(t+j|t)$ é a predição ótima da saída no tempo $t+j$ calculada em t .

Dado que, em geral, o processo têm dinâmicas diferentes e atrasos diferentes para cada saída, os horizontes também devem ser escolhidos diferentes (N_{i1} e N_{i2} para a saída i e N_j para a entrada j). Como a matriz $\mathbf{A}(z^{-1})$ é diagonal, as predições de y_i podem ser calculadas a partir do modelo, usando os valores da entrada e saída da planta no instante t , e a informação do erro de modelagem do processo:

$$A_i(z^{-1})y_i(t) = z^{-d_i}\mathbf{B}_i(z^{-1})\mathbf{u}(t-1) + e_i(t) \quad (3.35)$$

onde $\mathbf{B}_i = [B_{i1} \ B_{i2} \ \dots \ B_{im}]$ e o erro $e_i(t)$ pode ser descrito por:

$$e_i(t) = y_i(t) - P_n(z)\mathbf{u}(t) \quad (3.36)$$

O procedimento normal consiste em resolver recursivamente a equação e usar as predições de $j = N_{i1}$ a $j = N_{i2}$ na minimização de J [16]. Na prática, o horizonte mínimo é escolhido como o atraso mais um: $N_{i1} = d_i + 1$. Além disso, como em [61] para o GPC, considera-se $N_{i2} = d_i + N_{0i}$, sendo N_{0i} um parâmetro final de ajuste do controlador.

De modo geral, usando (3.35), pode-se escrever a predição como:

$$\begin{aligned} \hat{y}_i(t+k|t) &= \left[z(1 - A_i(z^{-1})) \right]^k y_i(t) + \mathbf{B}_i(z^{-1}) \sum_{l=0}^{k-1} \left[z(1 - A_i(z^{-1})) \right]^{k-1-l} \mathbf{u}(t-d_i+l) + \\ &+ \sum_{l=0}^{k-1} \left[z(1 - A_i(z^{-1})) \right]^l e_i(t) \end{aligned} \quad (3.37)$$

Se a equação (3.37) for aplicada para $k = d_i$:

$$\begin{aligned} \hat{y}_i(t+d_i|t) &= \left[z(1 - A_i(z^{-1})) \right]^{d_i} y_i(t) + \sum_{l=0}^{d_i-1} \left[z(1 - A_i(z^{-1})) \right]^l e_i(t) + \\ &+ \mathbf{B}_i(z^{-1}) \sum_{l=0}^{d_i-1} \left[z(1 - A_i(z^{-1})) \right]^{d_i-1-l} \mathbf{u}(t-d_i+l) \end{aligned} \quad (3.38)$$

Calculando os somatórios presentes na equação (3.38), obtém-se:

$$\begin{aligned} \hat{y}_i(t + d_i | t) = & \left[z(1 - A_i(z^{-1})) \right]^{d_i} y_i(t) + \left[\frac{1 - [z(1 - A_i(z^{-1}))]^{d_i}}{1 - [z(1 - A_i(z^{-1}))]} \right] e_i(t) + \\ & + \mathbf{B}_i(z^{-1}) z^{-1} (1 - A_i(z^{-1}))^{d_i-1} \left[\frac{1 - \frac{1}{(1 - A_i(z^{-1}))^{d_i}}}{1 - \frac{1}{(1 - A_i(z^{-1}))}} \right] \mathbf{u}(t) \end{aligned} \quad (3.39)$$

Substituindo a expressão do erro de modelagem (3.36) em (3.39), obtém-se a equação:

$$\hat{y}_i(t + d | t) = R_i(z) y_i(t) + Q_i(z) \mathbf{u}(t) \quad (3.40)$$

onde:

$$Q_i(z) = \frac{\mathbf{B}_i(z^{-1}) z^{-1}}{A_i(z^{-1})} z^{-d_i} \left[z^{d_i} + \left(\frac{[z(1 - A_i(z^{-1}))]^{d_i+1} - 1}{1 - [z(1 - A_i(z^{-1}))]} \right) \right]$$

e $R_i(z)$ é um filtro que se calcula como:

$$R_i(z) = \frac{1 - [z(1 - A_i(z^{-1}))]^{d_i+1}}{1 - [z(1 - A_i(z^{-1}))]} \quad (3.41)$$

Considerando:

$$\mathbf{P}_i(z^{-1}) = \mathbf{G}_i(z^{-1}) z^{-d_i} = \frac{z^{-1} \mathbf{B}_i(z^{-1})}{A_i(z^{-1})} z^{-d_i} \quad (3.42)$$

onde $\mathbf{P}_i(z^{-1})$ é a linha i de $\mathbf{P}(z^{-1})$ e $\mathbf{G}_i(z^{-1})$ é a linha i de $\mathbf{G}(z^{-1})$, a predição em $t + d_i$ se calcula como:

$$\hat{y}_i(t + d_i | t) = R_i(z^{-1}) [y_i(t) - \mathbf{P}_i(z^{-1}) \mathbf{u}(t)] + \mathbf{G}_i(z^{-1}) \mathbf{u}(t) \quad (3.43)$$

A figura 3.10 representa o diagrama de blocos para o cálculo da predição no caso multi-variável.

Escrevendo as equações de forma vetorial:

$$\begin{bmatrix} \hat{y}_1(t + d_1 | t) \\ \hat{y}_2(t + d_2 | t) \\ \vdots \\ \hat{y}_n(t + d_n | t) \end{bmatrix} = \mathbf{R}(z^{-1}) \begin{bmatrix} y_1(t) \\ y_2(t) \\ \vdots \\ y_n(t) \end{bmatrix} + \mathbf{G}(z^{-1}) \begin{bmatrix} u_1(t) \\ u_2(t) \\ \vdots \\ u_m(t) \end{bmatrix} - \mathbf{R}(z^{-1}) \mathbf{P}(z^{-1}) \begin{bmatrix} u_1(t) \\ u_2(t) \\ \vdots \\ u_m(t) \end{bmatrix}$$

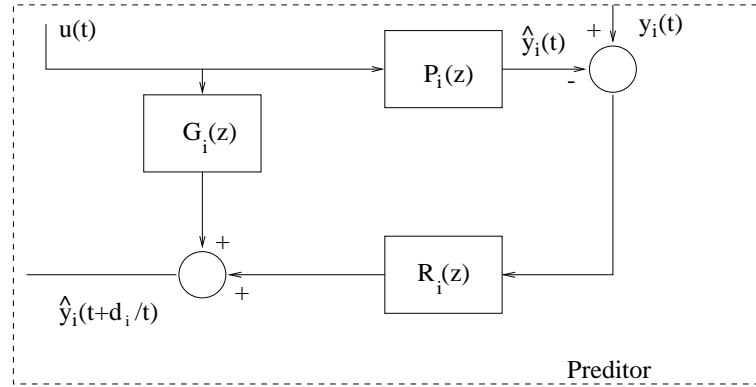


Figura 3.10: Diagrama de blocos para o cálculo da predição MIMO.

Pode-se agrupar da seguinte maneira:

$$\hat{\mathbf{y}}_d = \mathbf{G}(z^{-1})\mathbf{u}(t) + \mathbf{R}(z^{-1})[\mathbf{y}(t) - \mathbf{P}(z^{-1})\mathbf{u}(t)] \quad (3.44)$$

onde $\mathbf{R}(z^{-1}) = \text{diag}(R_i(z^{-1}))$, $\hat{\mathbf{y}}_d$ é o vetor de predições, $\mathbf{y}(t)$ é o vetor de saídas e $\mathbf{u}(t)$ o vetor de entradas. Esta equação mostra que as relações entre saídas, entradas e predições no DMC MIMO são uma extensão direta das calculadas para o caso SISO, assim como ocorre para o GPC [61].

Como no caso SISO, é possível calcular as predições que se utilizam na função objetivo J como função da resposta livre \mathbf{f}_r (formada pelo conjunto das \mathbf{f}_{ri}) e da resposta forçada do sistema (a exemplo do que foi realizado em [61] para o GPC):

$$\begin{bmatrix} \mathbf{y}_1 \\ \mathbf{y}_2 \\ \vdots \\ \mathbf{y}_n \end{bmatrix} = \mathbf{G}_f \begin{bmatrix} \mathbf{u}_{f1} \\ \mathbf{u}_{f2} \\ \vdots \\ \mathbf{u}_{fm} \end{bmatrix} + \begin{bmatrix} \mathbf{f}_{r1} \\ \mathbf{f}_{r2} \\ \vdots \\ \mathbf{f}_{rn} \end{bmatrix} = \mathbf{G}_f \begin{bmatrix} \mathbf{u}_{f1} \\ \mathbf{u}_{f2} \\ \vdots \\ \mathbf{u}_{fm} \end{bmatrix} + \mathbf{H}(z^{-1}) \begin{bmatrix} \Delta u_1(t) \\ \Delta u_2(t) \\ \vdots \\ \Delta u_m(t) \end{bmatrix} + \mathbf{S}(z^{-1})\hat{\mathbf{y}}_d \quad (3.45)$$

onde a resposta livre \mathbf{f}_r se calcula como função dos controles passados, obtidos através de $\mathbf{H}(z^{-1}) \Delta \mathbf{u}$ e das predições em $t + d_i | t$, $i = 1, 2, \dots, n$ (geradas por $\mathbf{S}(z^{-1})\hat{\mathbf{y}}_d$). As ações de controle futuras são $\mathbf{u}_{fj} = [\Delta u_j(t) \ \Delta u_j(t+1) \ \dots \ \Delta u_j(t + Nu_j)]'$, onde $Nu_j = \max_i (N_{0i} - d_{ij})$.

Substituindo a equação (3.45) em J , a minimização¹ resulta na ação de controle:

$$\mathbf{u} = \mathbf{K}(\mathbf{w} - \mathbf{f}_r) = \mathbf{K}[\mathbf{w} - \mathbf{H}(z^{-1}) \Delta \mathbf{u} + \mathbf{S}(z^{-1})\hat{\mathbf{y}}_d] \quad (3.46)$$

onde \mathbf{w} é a referência futura.

¹O procedimento para o cálculo do controle primário do DMC MIMO é similar ao realizado em [61] para o SPGPC MIMO e, por esta razão, foi omitido neste trabalho.

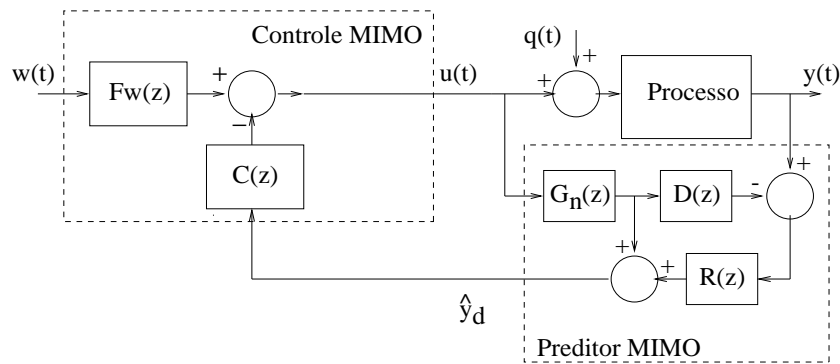


Figura 3.11: Estrutura de controle do DMC multivariável.

Na figura 3.11 pode-se ver o esquema do controle do DMC MIMO como um preditor multivariável mais um controlador primário MIMO. Também para o caso MIMO, a lei de controle final está composta por um preditor mais um controlador primário, sendo que $C(z^{-1})$ e $F_w(z^{-1})$ representam o controle primário com dois graus de liberdade. Além disso, a predição em $t + d_i$ se calcula somando a saída do modelo rápido com o erro de predição filtrado por R (que é a diferença entre a saída do processo e a do modelo em t que passa pelo filtro diagonal R). A análise anterior permite generalizar os resultados do DMC monovariável para este caso.

3.2.4 Aplicação à Planta Solar de Climatização

Como exemplo de utilização de controle preditivo em um processo real com atraso, desenvolveu-se a aplicação prática de um controlador SPGPC para uma planta solar de climatização, pertencente ao Departamento de Engenharia de Sistemas e Automática da Universidade de Sevilla, Espanha. A descrição das características do processo bem como da modelagem do sistema se encontram no apêndice C. Mais detalhes e informações sobre esta aplicação podem ser encontradas em [95].

Destaca-se que, apesar da maioria dos processos industriais envolverem restrições, ainda são poucos os trabalhos que tratam dos problemas de controle preditivo sob restrições, especialmente sob o ponto de vista de sua aplicabilidade prática. Por esse motivo, um dos objetivos deste trabalho é realizar uma aplicação real do controlador SPGPC (selecionado por suas características de robustez) com restrições, para controlar uma planta em escala industrial.

Entre as diversas aplicações térmicas da energia solar, a refrigeração é uma das mais complexas, tanto em conceito como na sua concretização prática [14]. Esta é uma das razões

pelas quais sua utilização ainda não seja tão difundida quanto a calefação de ambientes. O controle da planta solar é um problema no qual intervêm um número significativo de variáveis, e cujas condições de operação da planta estão sujeitas às condições climáticas. Uma estratégia adequada de controle objetiva o máximo rendimento da planta, levando em consideração essas influências.

Um dos procedimentos para conseguir o frio desejado a partir da energia solar é mediante o uso de máquinas de absorção de calor que produzem o frio consumindo o calor aplicado a seu gerador. Este calor pode ser obtido de muitas maneiras e uma delas é a partir da radiação solar [92]. Analisando a configuração geral da planta solar, concentrada sobre a máquina de absorção, pode-se dizer que corresponde a uma instalação de climatização que utiliza duas fontes de calor para produzir energia térmica adequada: i) energia solar vinda dos painéis ou dos tanques de acumulação ou ii) gás natural proveniente da caldeira. Para a correta operação da máquina de absorção de calor, se faz necessário o ajuste de sua temperatura de entrada dentro de uma certa faixa, a fim de permitir seu rendimento ótimo. Por este motivo, é apropriado aplicar um algoritmo de controle com otimização que garanta seu melhor funcionamento. O uso de um controlador preditivo com restrições é uma boa opção, pois permite corrigir os problemas apresentados pelo controle clássico PID anteriormente testado [1, 30].

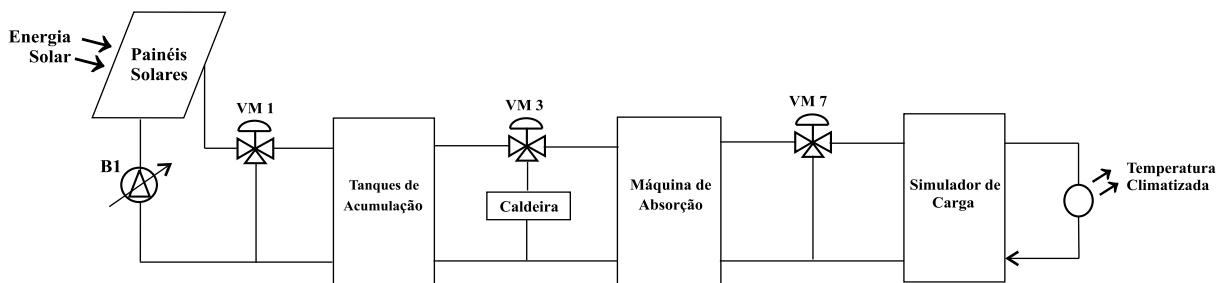


Figura 3.12: Esquema dos sensores da planta solar.

A instrumentação, os equipamentos e os sensores instalados na planta solar permitem o controle automático de quatro elementos, como mostra a figura 3.12. A bomba B1 possui um variador de frequência que permite atuar sobre o fluxo que circula pelos painéis solares. Um PID controla a abertura de uma válvula de três vias (VM1), permitindo atuar sobre a recirculação de água nos painéis solares, para que atinjam uma temperatura desejada. Um PID aplicado sobre outra válvula de três vias (VM3) controla a temperatura de entrada do gerador da máquina de absorção pela mescla de água da caldeira com a dos painéis (e/ou tanques). Além destes, existe mais um PID controlando a abertura da válvula VM7, existente no simulador de cargas, o que permite variar a carga térmica a ser aplicada à planta solar pela regulação do fluxo que circula pelo intercambiador de calor pertencente a este circuito [30].

O objetivo final de controle da planta solar é a regulação da temperatura de saída do sistema, ou seja, a temperatura climatizada. Para que esta temperatura atinja as especificações desejadas, é necessário controlar anteriormente a temperatura da máquina de absorção, pois desta depende o correto funcionamento da produção de frio. Assim sendo, a variável mais importante a ser controlada neste processo é, sem dúvida, a temperatura de entrada do gerador da máquina de absorção que, conforme descrito no anexo C, deve estar entre 75 e 100°C. Sobre esta variável, atua-se principalmente através de uma válvula, a VM3. A estratégia de controle é a de economia energética, de tal forma que se busque conseguir a temperatura desejada através dos painéis solares e/ou tanques de acumulação, sem necessidade de fazer uso de uma caldeira de gás. Quando esta temperatura não é suficiente para o funcionamento da máquina de absorção, a caldeira de gás atua como mecanismo de apoio, aportando a energia faltante ao sistema, pela mescla da água dos tanques com a proveniente da caldeira. O controle PID inicialmente instalado sobre essa válvula permite regular a saída. No entanto não elimina as oscilações que apresenta a temperatura de entrada do gerador, devido ao acionamento da caldeira (controle ON/OFF), nem permite incluir as restrições e perturbações no projeto do controlador [1].

Para suprir estas deficiências do PID que controla a válvula VM3, e com base nas necessidades de operação da planta, um controlador preditivo SPGPC com restrições foi desenvolvido. Este controlador foi implementado para controlar a temperatura de entrada da máquina de absorção, pela regulação da abertura da válvula VM3, em um valor ótimo de operação, selecionado como 83°C. É necessário destacar que o SPGPC implementado trata as perturbações mensuráveis do sistema. Estas perturbações são a temperatura da caldeira de gás e a temperatura dos tanques de acumulação, que influenciam diretamente na temperatura da máquina de absorção, e têm grande influência no desempenho, porque estão relacionadas a quantidade de energia armazenada no sistema. O algoritmo de controle preditivo permite utilizar o conhecimento das perturbações mensuráveis nas equações de predição, tratando-as simplesmente como entradas no modelo do sistema.

A função de transferência do processo foi modelada pela equação:

$$y(z) = G_u(z)u(z) + [\mathbf{G}_q(z)] \mathbf{q}(z)$$

onde a variável controlada $y(z)$ é a temperatura de entrada da máquina de absorção, a variável manipulada $u(z)$ corresponde a abertura da válvula de três vias VM3, e o vetor \mathbf{q} corresponde às perturbações mensuráveis q_1 e q_2 , respectivamente, à temperatura de saída dos tanques de acumulação e à temperatura de saída da caldeira. As matrizes de transferência G_u e \mathbf{G}_q foram encontradas com base em testes e ensaios realizados na planta real. O modelo do processo e das perturbações utilizado para a simulação está apresentado no apêndice C.

O algoritmo SPGPC calcula o sinal de controle, minimizando uma função de custo, se-

gundo a equação (2.1):

$$J = \sum_{j=d+1}^{N+d} [\hat{y}(t+j | t) - w(t+j)]^2 + \sum_{j=1}^{N_u} \lambda [u(t+j-1)]^2 \quad (3.47)$$

Para o ajuste do controlador SPGPC, foram selecionados os horizontes de controle N_u e de predição N iguais a 30 ($N = N_u = 30$) e a ponderação do esforço de controle como $\lambda = 0.5$. As restrições incluídas no SPGPC para o cálculo da função objetivo (3.47) foram as de amplitude e velocidade de alterações no sinal de controle, assim como restrições de amplitude na variável controlada (temperatura de entrada da máquina de absorção), descritas segundo a equação (2.2) como:

$$\begin{aligned} 0 &\leq u(t) \leq 100 \quad \forall t \\ -0.5 &\leq u(t) - u(t-1) \leq 0.5 \quad \forall t \\ 75 &\leq y(t) \leq 100 \quad \forall t \end{aligned}$$

O esquema do controlador SPGPC pode ser visto na figura 3.13. Ao esquema de controle, foi incluído um filtro de robustez à saída do sistema, do tipo $F(z) = \left(\frac{1-a}{1-az^{-1}}\right)$ com a finalidade de obter um comportamento mais robusto da planta em malha fechada. O parâmetro a do filtro foi selecionado como $a = 0.1$, seguindo regras de ajuste para o filtro de robustez apresentadas em [61]. Para a análise da robustez, incertezas no modelo foram consideradas sem alterar o ajuste do controlador. O modelo de simulação difere do modelo utilizado no controlador em 10% no valor dos coeficientes dos polinômios da função de transferência e em 50% no atraso do processo.

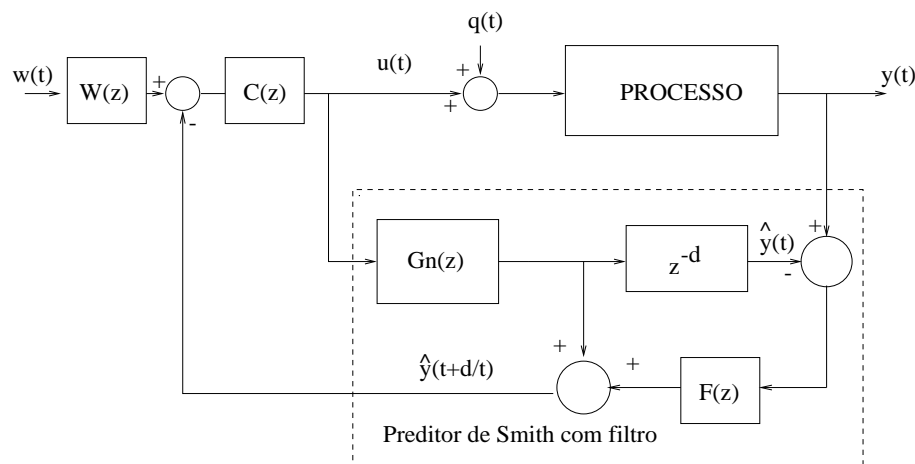


Figura 3.13: Esquema do controle SPGPC com filtro.

Este controlador foi implementado em linguagem de programação Visual C++², tendo sido utilizada uma plataforma integrada para o controle e a automação da planta solar. Para o controle da instalação, dispõe-se de um sistema de controle distribuído, formado por um controlador e um supervisor conectados por uma rede local de alta velocidade, conforme mostrado na figura 3.14. O primeiro deles se encarrega de executar as rotinas de controle digital, enquanto o segundo atua como plataforma de programação e comunicação com o operador.




Figura 3.14: Estrutura do controle.

A figura 3.15 apresenta um ensaio de 5000 amostras, onde se efetuaram várias mudanças de referência. No primeiro gráfico, pode-se observar a temperatura de entrada do gerador da máquina de absorção, controlada dentro dos valores estipulados, isto é, entre 75 e $100^{\circ}C$. No gráfico seguinte representa-se o sinal de atuação da válvula VM3, cujo comportamento demonstrado é o apropriado para seguir a referência e compensar as perturbações. Os gráficos seguintes representam as duas perturbações mensuráveis consideradas no sistema de refrigeração solar: a temperatura dos tanques de acumulação e a temperatura da caldeira, respectivamente. É importante destacar que os sinais das perturbações selecionadas para a simulação são reais, tomados em ensaios realizados com a planta solar em funcionamento, amostrados a cada $4s$, da mesma forma que na identificação do modelo. Optou-se por utilizar os dados reais das perturbações ao longo de todos os ensaios para que o comportamento simulado da planta resultasse mais confiável e próximo ao do sistema em malha fechada real.

A figura 3.16 representa um ensaio de 600 amostras de simulação, onde não se realiza nenhuma mudança de referência. Observa-se, notoriamente, o comportamento do controlador frente às alterações nos sinais das perturbações. Note que, aproximadamente na amostra 250, se produzem mudanças quase simultâneas na temperatura dos tanques de acumulação e na temperatura da caldeira. O controlador atua abrindo a válvula VM3 e compensando as perturbações, sem que a temperatura a controlar se distancie muito (apenas alguns décimos) da referência desejada (no caso $83^{\circ}C$).

O controlador SPGPC com restrições foi aplicado à planta solar com sucesso. Esse controlador é mais indicado para a aplicação real sobre a planta solar do que o PID, já que o processo apresenta restrições importantes em seu funcionamento, tanto na entrada quanto na saída. É importante salientar que a inclusão das perturbações mensuráveis no projeto do controlador foi crucial para o funcionamento adequado do sistema, sendo esta a principal vantagem frente ao controlador PID anteriormente testado [1] no controle da temperatura da máquina de absorção.

²As implementações em Visual C++ foram realizadas por Amparo Núñez-Reyes, do Departamento de Engenharia de Sistemas e Automática da Universidade de Sevilla, Espanha.




Figura 3.15: SPGPC com restrições. Seguimento de referência.




Figura 3.16: SPGPC com restrições. Compensação das perturbações.

3.3 Conclusões

Neste capítulo foi proposta uma metodologia para o cálculo do DMC quando controlando processos com atraso, para sistemas monovariáveis. Demonstrou-se que o esquema de controle do DMC também pode ser descrito como composto por um controlador primário mais um preditor. Com base nesta representação, uma análise comparativa da robustez dos controladores DMC, GPC e SPGPC foi desenvolvida. Apesar do SPGPC ser o controlador mais robusto, o DMC se mostra como uma boa alternativa frente ao GPC, no controle de processos com atrasos dominantes. Em especial, no caso de um processo poder ser modelado por uma função de transferência de primeira ordem com atraso. Uma aplicação a uma planta piloto de processos térmicos foi utilizada para comparar os índices de robustez dos controladores. A generalização do algoritmo para o caso multivariável também foi apresentada. Ao final do capítulo, desenvolveu-se e analisou-se uma aplicação real de SPGPC sob restrições a uma planta solar de climatização.

Capítulo 4

Otimização Multiobjetivo em Controle Preditivo de Processos

”Model-based Predictive Control or MPC is probably the most important approach to the advanced control of complex interacting industrial processes. Uniquely amongst modern theories, MPC can handle real-time state and actuator constraints in a natural way, enabling plants to operate more closely to their ultimate profitable margins. The richness of the field - there being wide ranges of choice in model structures, prediction horizons and optimization criteria - allows a control designer to tailor MPC for his application, whether it be a high-speed machine tool, a patient in the operating theatre, or a large-scale industrial process.”

D. Clarke.
Oxford, 1993.

4.1 Introdução

A implantação de um MPC em processos industriais é, com certeza, uma tarefa não trivial e, em geral, mais difícil do que colocar em funcionamento controladores do tipo PID. Comparativamente às aplicações clássicas, a instalação de uma aplicação MPC é mais cara, consome mais tempo e requer pessoal com melhor treinamento em controle de processos. A necessidade de ter um bom modelo do processo a ser controlado requer, em muitos casos, testes significativos com a planta, inclusive fora de suas condições de operação nominal. O equipamento necessário para sua implantação requer, na maior parte dos casos, a utilização de processadores com maior capacidade de cálculo e instrumentação de melhor qualidade. Além disso, a aquisição de pacotes computacionais comerciais e o treinamento do pessoal de manutenção da planta (ou do sistema de controle) podem representar investimento financeiro significativo em curto prazo.

Apesar dessas dificuldades, o MPC tem provado ser economicamente rentável pela redução dos custos de operação ou pelo incremento de produção, e tem se tornado uma das técnicas de controle avançadas mais usadas na indústria [16]. Dentre as razões para esse sucesso, deve-se destacar as habilidades do MPC para:

- **Otimização de condições de operação:** o MPC otimiza uma função de custo que pode ser formulada no sentido de minimizar os custos de operação ou qualquer outro objetivo com implicações econômicas.
- **Otimização de transitórios:** a função objetivo MPC pode ser formulada no sentido de otimizar uma função que mede o custo de levar o processo de um ponto de operação a outro, considerando os melhores tempos de inicialização e de partida do processo.
- **Minimização da variância do erro:** um MPC pode ser formulado a fim de minimizar a variância do erro de saída e produzir benefícios econômicos, pois:
 - uma pequena variância pode aumentar a qualidade do produto assim como garantir sua uniformidade;
 - uma pequena variância permitirá que o processo opere próximo das condições ótimas de operação.
- **Manuseio explícito das restrições:** a consideração explícita das restrições pode reduzir o número de violações, diminuindo assim a necessidade de reinicializações na planta, permitindo ao processo operar mais próximo às restrições e em condições de operação ótimas.

Muito embora as questões relacionadas à otimização e à inserção das restrições nos algoritmos MPC venham sendo tratadas pela comunidade científica, a possibilidade da inclusão

de múltiplos objetivos de controle dentro do algoritmo MPC é um tema ainda pouco explorado. A maioria dos resultados existentes são fundamentalmente teóricos e de difícil aplicação prática. Um campo aberto para pesquisa é a aproximação de resultados teóricos com a prática, para a qual se direciona este capítulo.

Neste sentido, apresenta-se a seguir conceitos de otimização multiobjetivo, importantes para uma melhor compreensão das seções seguintes. A continuação, a aplicação destes conceitos é vinculada ao controle preditivo de processos. Três estratégias MPC usando metodologias de otimização multiobjetivo são apresentadas: o MPC ponderado, o MPC priorizado e o MPC estruturado. No decorrer do capítulo, simulações utilizando dados reais de uma planta industrial são realizadas, a fim de comparar os diferentes algoritmos. Ao final do capítulo, destaca-se a qualidade do algoritmo proposto para a estruturação de objetivos, por sua simplicidade de programação e cumprimento das prioridades impostas.

4.2 Otimização Multiobjetivo

A otimização multiobjetivo está relacionada com a minimização de um vetor de objetivos $\mathbf{v}(\theta) = [v_1(\theta), v_2(\theta), \dots, v_m(\theta)]'$, onde θ é o conjunto de variáveis de decisão do problema, que pode estar sujeito a restrições ou limites. Note que, se algum dos componentes de $\mathbf{v}(\theta)$ estiverem competindo entre si, não existe uma solução única para o problema de minimização. Com isto, a abordagem multiobjetivo utiliza o conceito de não-inferioridade [26]. Resolver um problema de otimização multiobjetivo geralmente requer a identificação de soluções Pareto-ótimas, um conceito introduzido por Pareto no ano de 1896.

Seja um problema de otimização multiobjetivo descrito por:

$$\min_{\theta} \mathbf{v}(\theta) \quad (4.1)$$

$$\text{sujeito a } \mathbf{R}(\theta) \leq \alpha$$

onde $\mathbf{v}(\theta) = [v_1(\theta) \dots v_m(\theta)]'$, é o vetor composto por m objetivos, e $\mathbf{R}(\theta) \leq \alpha$ define um dado conjunto de restrições.

Definição (Solução Pareto-ótima): Uma solução θ^* é dita *Pareto-ótima* se $\forall \theta \neq \theta^*$, existe i tal que $v_i(\theta) > v_i(\theta^*)$ ou $v_i(\theta) \geq v_i(\theta^*)$, para todo i .

Assim, diz-se que uma solução é Pareto-ótima, se o valor de alguma das componentes da função objetivo que formam o problema de minimização não puder ser melhorada sem

a degradação de pelo menos umas das outras componentes envolvidas na função custo, ou seja, se não pode ser encontrada uma solução que melhore uniformemente todas as $v_i(\theta)$. Pode-se ainda concluir que uma solução θ^* não é Pareto-ótima se existe $\theta \neq \theta^*$, tal que $\forall i : v_i(\theta) \neq v_i(\theta^*)$ e $\exists i : v_i(\theta) < v_i(\theta^*)$. Assim, as soluções referidas para este tipo de problema são normalmente soluções de melhor compromisso, onde a otimalidade de Pareto é uma propriedade necessária [18].

Com o intuito de buscar soluções Pareto-ótimas para o problema de otimização multi-objetivo, existem algumas estratégias bastante difundidas como o algoritmo por soma ponderada (*Weighting Method*), o método da restrição ϵ (*ϵ -Constraint Method*), assim como a abordagem da satisfação dos objetivos (*Goal Attainment Method*) [27].

Métodos de Otimização Multiobjetivo

Uma maneira simples de encontrar uma solução Pareto-ótima é resolver:

$$\theta^* = \min_{\theta} \sum_{i=1}^m w_i v_i(\theta), \quad w_i \geq 0$$

Pela variação dos pesos w_i , pode-se gerar um conjunto de soluções Pareto-ótima.

O método *Weighting* ou da soma ponderada dos objetivos envolvidos no índice de minimização é umas das técnicas mais antigas de otimização multiobjetivo [18, 26]. A relevância de cada um dos objetivos pode ser modulada pelo ajuste apropriado de todos os w_i . Isto é, entretanto, um problema de solução não trivial em virtude da dificuldade em determinar os pesos que representam a importância relativa dos objetivos. A deficiência do algoritmo está na seleção dos coeficientes de pesos atribuídos a cada objetivo individualmente e na maneira de formalizar a relação entre eles. Normalmente o método é usado para aproximar o conjunto não-inferior de soluções através do seguinte procedimento: começa-se pela otimização de cada objetivo individualmente, resolvendo vários problemas onde o peso atribuído ao objetivo de interesse seja 1 e o restante 0, o que permite verificar os pontos finais do conjunto não-inferior de soluções. Depois de cada objetivo ter sido otimizado individualmente, realiza-se uma variação sistemática dos pesos, resolvendo o problema de otimização para cada caso testado.

Em alguns casos, a importância relativa dos objetivos pode ser estabelecida através de priorização, na qual os objetivos de maior prioridade devem ser alcançados antes de outros objetivos de menor prioridade serem considerados. O projeto dos pesos a serem atribuídos a cada objetivo é um processo arbitrário, guiado pelo conhecimento heurístico do sistema, sendo que a atribuição de pesos maiores deve ser reservada aos objetivos de maior importância. No entanto, não há garantia que a escolha dos pesos resulte na priorização desejada

de objetivos para todas as condições de operação. Portanto, esta é uma tarefa complexa, usualmente realizada pelo método de tentativa e erro. Este procedimento pode apresentar problemas de convexidade (gerar soluções não-convexas), se mal-formulado [18].

Um procedimento que reduz algum dos problemas de convexidade da técnica de soma ponderada de objetivos é o método ϵ -Constraint. Este método minimiza um dos objetivos envolvidos no custo (dito objetivo primário), enquanto mantém o restante deles limitados em um valor ϵ_i , expressos como restrições de desigualdade [27]. Matematicamente, pode ser formulado como:

$$\begin{aligned} \min_{\theta} \quad & v_p(\theta) \\ \text{s.a.} \quad & v_i(\theta) \leq \epsilon_i, \quad i = 1, \dots, m \quad i \neq p \end{aligned}$$

Assim, converte-se o problema multiobjetivo em vários problemas com restrições. Este método apresenta como característica a arbitrariedade de prioridades entre os objetivos, pois impõe a seleção de um objetivo primário a cada minimização. O valor ϵ_i está relacionado à limitação atribuída a cada objetivo do problema. Sua principal desvantagem está na escolha de ϵ_i de modo a garantir uma solução factível.

O método de satisfação dos objetivos de Gembicki [37] se baseia na minimização de uma variável de folga. Os objetivos de controle representados pelo vetor $\mathbf{v}(\theta)$ estarão associados a um conjunto de soluções desejadas $\mathbf{v}^*(\theta) = [v_1^*(\theta), v_2^*(\theta), \dots, v_m^*(\theta)]'$. O grau de aproximação da solução do problema é controlado por um vetor de coeficientes de ponderação $\beta = \{\beta_1, \beta_2, \dots, \beta_m\}$, que é descrito como um problema de otimização padrão dado pela seguinte formulação:

$$\begin{aligned} \min \quad & \gamma \\ \text{tal que} \quad & v_i(\theta) - \beta_i \gamma \leq v_i^*(\theta), \quad i = 1, \dots, m \end{aligned}$$

O termo $\beta_i \gamma$ introduz uma folga na satisfação dos objetivos do problema, mas possibilita que a solução desejada ainda seja encontrada. O vetor de pesos β permite expressar uma medida da importância relativa entre os objetivos. Note que restrições duras podem ser incorporadas ao problema, zerando um determinado peso (i.e. $\beta_i = 0$). Esse algoritmo pode ser implementado em MATLAB através da função `fgoalattain`, incorporando ainda um programa seqüencial quadrático SQP (*Sequential Quadratic Programming*) que permite definir a importância relativa entre a função objetivo e a redução na violação das restrições, o que torna o método mais robusto [27].

As metodologias anteriores permitem resolver o problema de otimização multiobjetivo definido pela equação (4.1), gerando soluções Pareto-ótimas, e podem ser aplicadas ao controle preditivo. Os métodos discutidos permitem impor uma priorização pela escolha de pesos maiores a objetivos de maior relevância. Entretanto, existem ainda diferentes abordagens para a otimização multiobjetivo com o intuito de buscar a solução ótima através de uma hierarquia com diferentes prioridades para os vários objetivos. Neste caso, o problema de otimização busca encontrar um conjunto de soluções Pareto-ótimas que estarão otimizadas com respeito a *prioridades* relativas entre todos os objetivos $v_i(\theta)$. Buscar-se-á resolver primeiramente um objetivo de maior prioridade, utilizando sua solução para impor restrições de igualdade no momento de resolver uma segunda otimização, e assim por diante. A complexidade do problema de otimização multiobjetivo a ser resolvido não aumenta, nem decresce, como resultado da adoção de tal estratégia. Em particular, para a solução do primeiro objetivo (mais importante a ser resolvido) existe um menor número de conflitos e um maior número de graus de liberdade, o que leva a crer que existem melhores expectativas de uma boa solução ser encontrada, e de forma rápida. O tópico seguinte discute alguns aspectos da priorização multiobjetivo.

Priorização Multiobjetivo

Dentre as soluções ótimas de Pareto, destacam-se as soluções do tipo priorizadas [44]. Faz-se necessário, inicialmente, definir o que se entende por prioridade. Assume-se que *um objetivo associado à função de custo $v_i(\theta)$ tem maior prioridade que outro associado à $v_{i+1}(\theta)$.*

Definição (Solução priorizada-ótima): Uma solução θ^* é dita *priorizada-ótima* se **não** existe $\theta \neq \theta^*$, tal que $v_{i^*}(\theta) < v_{i^*}(\theta^*)$, onde i^* é o índice do primeiro elemento onde $v(\theta)$ e $v(\theta^*)$ diferem.

Uma solução Pareto-ótima priorizada é obtida pela solução de uma seqüência de problemas de otimização, para os m objetivos envolvidos:

$$v_i^* = \min_{\theta} v_i(\theta)$$

sujeito às restrições:

$$v_j(\theta) = v_j^*, \quad j = 1, \dots, m$$

O processo da busca da solução global requer a realização de m problemas de minimização. A solução do m -ésimo problema de otimização será a solução priorizada-ótima. Essa

abordagem é utilizada em [54, 106]. Apesar de ser fácil de implementar, esse método sempre requer a solução de m problemas de minimização. Nesse caso, determinar a solução priorizada-ótima é o mesmo que encontrar o *mínimo lexicográfico*¹ do problema multiobjetivo.

Com o intuito de solucionar o problema de minimização multiobjetivo, uma forma sistemática de integrar a formulação de priorização de múltiplos objetivos foi proposta por Tyler e Morari [105]. A idéia é descrever as prioridades das restrições e objetivos através da lógica proposicional [17, 83], em uma forma canônica, que pode ser transladada num problema de otimização com variáveis inteiras (em realidade, binárias $\{0, 1\}$). Essa abordagem foi recentemente adaptada em um procedimento de tratamento de sistemas híbridos que incorpora conhecimentos qualitativos do processo através de regras heurísticas e inferência lógica resultando em sistemas dinâmicos sujeitos a restrições lineares descritas por variáveis inteiras e numéricas chamado de sistemas dinâmicos lógicos mistos (*Mixed Logical Dynamical (MLD) Systems*) [7, 8]. Esta metodologia de sistemas MLD passou a ser utilizada em virtude de sistemas híbridos serem bastante comuns na prática. Os sistemas MLD incluem todos aqueles que podem ser descritos por leis físicas interdependentes, regras lógicas e restrições de operação. Em muitas aplicações, o sistema a ser controlado, além de conter seus componentes dinâmicos, é também constituído de elementos discretos que podem ser descritos por *lógica*, tais como chaves ou válvulas liga/desliga, seletores de velocidade, engrenagens, entre outros.

Em adição aos modelos quantitativos usados para descrever um processo, freqüentemente existem outras informações disponíveis sobre o comportamento do sistema, como evoluções dependentes de regras tipo “*if-then-else*”, ou ainda propriedades qualitativas que podem ser convenientemente enumeradas e associadas a uma variável inteira. Esse procedimento para a modelagem de sistemas híbridos deve levar a um compromisso entre complexidade do modelo e a análise lógica necessária para a formulação. Isso em virtude da complexidade de uma descrição genérica da lógica proposicional, que possa ser aplicado a todos os casos e sistemas. Em realidade, a técnica proposta em [105] apresenta essa dificuldade: é necessário descrever as inequações para cada caso a ser otimizado, baseado unicamente nas variáveis do problema e nas condições e prioridades impostas a estas. A descrição de uma metodologia padrão realizada em [8] também está restrita a uma classe de sistemas; aqueles com dinâmica linear, permitindo a inclusão de variáveis binárias. Isto porque a transformação da lógica proposicional em um conjunto equivalente de restrições lineares não é única. Estes sistemas utilizam variáveis binárias (0,1) auxiliares para transformar lógica proposicional em inequações lineares. A lógica proposicional é o elo de ligação entre as regras lógicas do algoritmo multiobjetivo e as variáveis dinâmicas do processo. Um resumo das propriedades lógicas utilizadas se encontra na tabela 4.1, onde pode-se ver que elementos *conectivos* da álgebra booleana (\wedge , \vee , \sim , \oplus , \rightarrow , \leftrightarrow) são usados para transformar relações complexas em

¹Este é um processo análogo a arranjar um conjunto de palavras alfabeticamente, por isso o uso do termo *lexicográfico*. Por exemplo, o mínimo lexicográfico do conjunto $\{[2, 3, 1], [3, 2, 1], [2, 2, 4], [2, 2, 1], [2, 2, 3]\}$ é $[2, 2, 1]$. Mais detalhes podem ser obtidos em [46].

inequações inteiras-mistas equivalentes de menor complexidade [56].

Relação	Lógica	(In)equações
AND (\wedge)	$X1 \wedge X2$	$\delta_1 = 1, \delta_2 = 1$
OR (\vee)	$X1 \vee X2$	$\delta_1 + \delta_2 \geq 1$
NOT (\sim)	$\sim X1$	$\delta_1 = 0$
XOR (\oplus)	$X1 \oplus X2$	$\delta_1 + \delta_2 = 1$
IMPLICA (\rightarrow)	$X1 \rightarrow X2$	$\delta_1 - \delta_2 \leq 0$
SSE (\leftrightarrow)	$X1 \leftrightarrow X2$	$\delta_1 - \delta_2 = 0$
SENTENÇA ($\Rightarrow, \Leftrightarrow$)	$X3 = X1 \wedge X2$ $X3 \leftrightarrow X1 \wedge X2$	$\delta_1 + (1 - \delta_3) \geq 1$ $\delta_2 + (1 - \delta_3) \geq 1$ $(1 - \delta_1) + (1 - \delta_2) + \delta_3 \geq 1$
EVENTO	$[f(x) \leq 0] \leftrightarrow [\delta = 1]$	$f(x) \leq M - M\delta$ $f(x) \geq \epsilon + (m - \epsilon)\delta$
IF-THEN-ELSE	IF X THEN $z = f_1(x)$ ELSE $z = f_2(x)$ ($z = \delta f_1(x) + (1 - \delta)f_2(x)$)	$(m_2 - M_1)\delta + z \leq f_2(x)$ $(m_1 - M_2)\delta - z \leq -f_2(x)$ $(m_1 - M_2)(1 - \delta) + z \leq f_1(x)$ $(m_2 - M_1)(1 - \delta) - z \leq -f_1(x)$

Tabela 4.1: Conversão básica de relações lógicas em inequações inteiras-mistas.

A descrição do comportamento desejado para sistema híbrido através da forma MLD requer a aplicação de um conjunto de regras lógicas, o que pode ser um processo longo e tedioso. Com o objetivo de automatizar a realização desta tarefa, o grupo de pesquisa em Sistemas Híbridos comandado por Morari (ETH, Zurique) desenvolve um compilador e uma linguagem de especificação de problema (HYSDEL - *HYbrid System DEscription Language*) que visam realizar esta descrição [6]. O mesmo grupo também desenvolveu uma rotina para MATLAB (`miqp.m`) para a solução do algoritmo MIQP.

A seguir, descreve-se como a otimização multiobjetivo pode ser adaptada ao problema de controle preditivo, incluindo objetivos de ordem econômica ao processo.

4.3 MPC com Otimização Multiobjetivo

No sentido de determinar a seqüência de controle futura que provê o melhor comportamento do processo, as estratégias MPC são baseadas na otimização de uma função custo, que é usualmente quadrática e única. Entretanto, em aplicações práticas, o comportamento

do processo não pode ser medido por uma função objetivo simples pois, na maior parte do tempo, existem diferentes, e até mesmo conflitantes, objetivos de controle a serem atendidos. Raramente uma única função objetivo com diferentes restrições pode representar adequadamente um problema que se queira resolver. Mais freqüentemente existe um conjunto de objetivos $J = \{J_1, J_2, \dots, J_m\}$ que deve ser satisfeito sobre determinadas condições. A importância relativa destes objetivos não é geralmente conhecida até que os melhores ajustes do sistema sejam determinados e as relações entre os objetivos sejam compreendidas. Com o aumento no número de objetivos, cresce também a complexidade em determinar as relações entre eles e a maneira como quantificá-las. Uma estratégia multiobjetivo capaz de formular sistematicamente um problema de controle pode facilitar esta tarefa [16].

As razões para a consideração de múltiplos objetivos de controle no MPC são variadas:

- Processos industriais têm diferentes estágios de operação, segundo o estado em que se encontram. Por exemplo, na fase de arranque de um processo, um tempo mínimo de inicialização pode ser desejado. Por outro lado, uma vez que o processo tenha atingido o regime de operação nominal, a mínima variância das variáveis de controle pode ser o principal objetivo de controle. Além disso, normalmente é preciso priorizar a rejeição de perturbações a custo de diminuir a eficácia no seguimento de referências.
- Mesmo em um estágio de operação particular, o objetivo de controle pode depender do valor das variáveis. Por exemplo, o objetivo de controle quando um processo está no ponto de operação nominal pode ser minimizar a soma ponderada dos erros quadráticos de variáveis controladas com respeito aos valores previstos. Mas se o valor de uma das variáveis é muito alto, por causa de uma perturbação por exemplo, o objetivo principal do controle pode ser reduzir o valor desta variável o mais rápido possível.
- Em muitos casos, o objetivo de controle não é otimizar a soma de erros quadráticos, mas manter algumas variáveis dentro de certos limites aceitáveis. Se o objetivo é manter a variável dentro da região limitante, podem ocorrer algumas excursões da variável fora desta região, que não são desejáveis, mas permitidas (note que esta situação é diferente do controle MPC sob restrições, onde não se pode ultrapassar os limites em hipótese alguma). No MPC, as variáveis devem se manter dentro da região preestabelecida por limitações físicas, segurança da planta ou outras considerações. Estes tipos de objetivos podem ser expressos pela penalização do quanto a variável em questão viola um limite imposto.
- Na presença de não-factibilidades, ponto crítico no MPC sob restrições, pode-se solucionar a violação de restrições por meio de um problema de otimização multiobjetivo, do tipo minimizar a duração e/ou o tamanho de violação da restrição de modo a garantir um determinado comportamento aceitável do sistema [85].

Na seqüência, apresenta-se como formular diferentes estratégias de otimização multiobjetivo, segundo os conceitos introduzidos na seção 4.2, em conjunto ao controle preditivo.

4.3.1 MPC com Ponderação de Objetivos

Considere um conjunto de objetivos de controle $J = \{J_1, J_2, \dots, J_m\}$. O método da soma ponderada de objetivos consiste em converter J em um problema escalar construído a partir da soma ponderada de todos os objetivos a serem minimizados. Levando em conta todos os objetivos, pode-se transformar na minimização de uma função quadrática J_i , sujeita a um conjunto de restrições lineares nas variáveis de decisão $\mathbf{R}_i \mathbf{u} \leq \mathbf{a}_i$. A seqüência de controle futura pode ser determinada pela solução do problema de otimização:

$$\min J = \sum_{i=1}^m w_i J_i, \quad w_i \geq 0 \quad (4.2)$$

$$\text{s.a.} \quad \mathbf{R}_i \mathbf{u} \leq \mathbf{a}_i, \quad i = 1, \dots, m$$

A relevância de cada um dos objetivos pode ser modulada pelo ajuste apropriado de todos os w_i . No entanto, a escolha dos pesos não necessariamente corresponde a importância relativa entre os objetivos, ou seja, o fato de se selecionar para um determinado objetivo um fator de ponderação de maior valor não garante que este objetivo tenha maior prioridade no momento de encontrar a solução do problema. Essa abordagem, onde são empiricamente atribuídos pesos aos objetivos de controle, com base no conhecimento do processo, ao ser aplicada ao MPC será referenciada como controlador MPC *ponderado*.

4.3.2 MPC com Priorização de Objetivos

A aplicação da formulação por prioridades ao MPC foi também apresentada em [105]. O problema de priorização de múltiplos objetivos pode ser combinado com um QP padrão do controle preditivo, resultando em um problema de programação quadrática inteira mista (MIQP - *Mixed Integer Quadratic Programming*) - ou num problema de programação linear inteira mista (MILP), se o problema de controle preditivo for formulado como um LP.

A solução do ótimo global de tais problemas pode ser obtida em um único passo, mas a complexidade computacional envolvida é muito maior do que os problema QP ou LP originais. Com exceção de alguns casos particulares, o tempo de solução para problemas de programação inteira mista envolvendo variáveis $\{0, 1\}$ cresce exponencialmente com o tamanho

do problema [83]. Apesar de sua natureza combinatória, existem diversas abordagens para resolver problemas do tipo MIQP. No entanto, em [34] uma experiência numérica comparando diferentes abordagens é relatada, comprovando que os resultados obtidos através do método *Branch and Bound* são superiores em diferentes aspectos. O algoritmo *Branch and Bound* para MIQP consiste em resolver e gerar novos problemas QP em concordância à uma árvore de busca, onde os nós das árvores correspondem a sub-problemas QP. *Branching*, ou seja, ramificar, significa gerar nós-filhos a partir de nós-pais de acordo com as regras de ramificação, que podem estar baseadas, por exemplo, nas especificações a priori das prioridades feitas através das variáveis inteiras. Os nós são rotulados de acordo com o crescimento do ramo; se um determinado problema QP não tem solução, o ramo passa a ser completamente explorado. O algoritmo pára quando todos os nós forem resolvidos. O sucesso do método *Branch and Bound* está ligado ao fato de que sub-árvores inteiras de busca podem ser excluídas pela resolução do nó-pai correspondente. Isto acontece se um subproblema QP correspondente é infactível ou se uma solução inteira é obtida. Neste segundo caso, o valor correspondente da função custo serve de limite superior (*Bound*) para a solução do problema MIQP e é usado na ramificação dos outros nós. Para maiores esclarecimentos sobre o método, ver [34].

Na área de controle preditivo, pela formulação de proposições lógicas representadas por variáveis inteiras, é possível combinar lógica baseada nas decisões de controle desejadas com o algoritmo MPC. Isto permite criar estratégias de controle com capacidade tanto para priorizar restrições quanto para alterar o objetivo de controle dependendo das condições de entrada do processo [8]. A abordagem apresentada em [105] considera um processo a controlar com uma série de m objetivos J_i . Suponha que o objetivo J_i tem maior prioridade que o objetivo J_{i+1} e que os objetivos podem ser expressos pelas restrições do processo como $\mathbf{R}_i \mathbf{u} \leq \mathbf{a}_i$.

A idéia principal consiste em introduzir variáveis inteiras L_i que assumem valor unitário quando os objetivos são alcançados e nulo em outros casos. Os objetivos passam a ser descritos como:

$$\mathbf{R}_i \mathbf{u} \leq \mathbf{a}_i + M_i(1 - L_i) \quad (4.3)$$

onde M_i é um limite superior conservativo em $\mathbf{R}_i \mathbf{u} - \mathbf{a}_i$. Se o objetivo J_i é satisfeito, $L_i = 1$ e o objetivo reformulado coincide com o objetivo de controle original. Pela introdução de M_i , o objetivo reformulado (restrição) é satisfeito mesmo quando o objetivo de controle correspondente não for alcançado ($L_i = 0$).

A priorização de objetivos implica que os objetivos 1 até i devem ser satisfeitos antes do objetivo $i + 1$. Esta condição pode ser expressa pela imposição das seguintes restrições nas variáveis inteiras L_i :

$$L_i - L_{i+1} \geq 0 \quad i = 1, \dots, m - 1 \quad (4.4)$$

O seguinte problema de programação inteira mista, onde se busca maximizar o número de objetivos de controle satisfeitos, pode ser usado para satisfazer os critérios multiobjetivos:

$$\min J = - \left(\sum_{i=1}^m L_i \right)$$

sujeito a (4.3) e (4.4)

O conjunto de restrições (4.3) pode ser modificado no sentido de melhorar o grau de verificação da restrição de objetivos que não podem ser satisfeitos [105]. Suponha que nem todos os objetivos podem ser satisfeitos num dado instante e que o objetivo J_f é o primeiro objetivo que falha. A fim de permitir chegar mais próximo possível da satisfação desse objetivo, uma nova variável de folga ϕ é introduzida para satisfazer o seguinte conjunto de restrições:

$$\mathbf{R}_i \mathbf{u} \leq \mathbf{a}_i + \phi + M_i \left((i-1) + (1-L_i) - \sum_{j=1}^{i-1} L_j \right) \quad (4.5)$$

O problema de minimização passa a ser:

$$\min J = - M_\phi \left(\sum_{i=1}^m L_i \right) + f(\phi) \quad (4.6)$$

sujeito a (4.3), (4.4) e (4.5)

onde $f(\cdot)$ é uma função de penalização da variável de folga ϕ (positiva e estritamente crescente), M_ϕ é um limite superior de $f(\cdot)$. As restrições (4.3), (4.4) e (4.5) estão descritas segundo as regras lógicas apresentadas na tabela 4.1.

O algoritmo de otimização tentará maximizar o número de objetivos satisfeitos ($L_i = 1$) antes de procurar reduzir $f(\phi)$. Isto porque a função objetivo global poderá ser feita a menor possível pelo aumento do número de variáveis L_i não nulas, mais do que pela redução de $f(\phi)$. Como todos os objetivos J_i , para $i < f$, são satisfeitos ($L_i = 1$), as restrições (4.5) serão sempre satisfeitas para qualquer valor de ϕ . Se J_f é o primeiro objetivo que falha, então:

$$\sum_{i=1}^{i-1} L_i = f - 1, \quad i \geq f$$

Isto é, para $i = f$, o termo multiplicando M_i da restrição (4.5) é zero, enquanto que para $i > f$ esse termo é maior que um. Isto implica que todas as restrições (4.5) podem ser satisfeitas para $i > f$. Portanto, a única restrição ativa envolvendo ϕ corresponde a:

$$\mathbf{R}_f \mathbf{u} \leq \mathbf{a}_f + \phi$$

sendo o mínimo ϕ igual a folga dada ao objetivo J_f , satisfazendo o critério multiobjetivo.

Deve-se destacar que o método de otimização tentará priorizar o grau de satisfação do primeiro objetivo que falha, somente após todos os demais objetivos prioritários terem sido alcançados. Note que $L_i = 0$ não implica que o objetivo J_i não é satisfeito, somente indica que a restrição correspondente tem que ser relaxada.

Se o processo é linear e $f(\cdot)$ é uma função linear de ϕ , o problema de maximização (4.6) pode ser resolvido por um programação linear inteira mista (MILP). Se $f(\cdot)$ é uma função quadrática, o problema pode ser resolvida por um algoritmo de programação quadrática inteira mista (MIQP). Se ϕ for um escalar, pode-se escolher $f(\phi) = \phi$ ou $f(\phi) = \phi^2$. Conforme já mencionado, apesar de existirem algoritmos eficientes para resolver problemas de programação inteira mista, a carga de cálculo computacional requerida é muito mais elevada que a necessária para os problemas padrão de programação linear (LP) ou quadrática (QP). Deve-se, portanto, utilizar um número de objetivos pequeno no sentido de permitir a implementação do método em tempo real.

No algoritmo proposto por Tyler e Morari em [105], não fica evidente onde está inserida a otimização multiobjetivo dentro da realização do algoritmo MPC. Já a proposta de Bemporad e Morari [8] resulta em um controlador preditivo inteiro misto (*Mixed-integer Predictive Controller*) que, essencialmente, resolve a cada instante de tempo um problema de controle através de uma otimização do tipo MIQP, aplicando a solução ótima de acordo com a filosofia de horizonte deslizante. Em [45], uma extensão a esta proposta é realizada, com o intuito de garantir a satisfação do maior número de objetivos dentro de um determinado nível de prioridades violado. Estas propostas não foram testadas neste trabalho, por incluírem no decorrer do método de otimização a aplicação *on-line* da busca de uma solução do tipo MIQP.

Para aplicar a priorização de objetivos ao controle preditivo, utilizou-se como base o MMC (*Modular Multivariable Controller*) de Meadowcroft e Stephanopolos [54]. O MMC representa uma metodologia de controle que está baseada na solução de um problema de otimização multiobjetivo usando uma estratégia de programação lexicográfica pela satisfação seqüencial e prioritária de objetivos (SQP). A idéia extraída desse controlador foi a utilização das relações de regime permanente do processo em questão, como valores de referência, para o cálculo do controle. Então, assim como no MMC, o controlador MPC com

priorização de objetivos proposto faz uso dos ganhos estáticos do processo e dos valores estáticos das variáveis manipuladas. Estes valores, referenciados como v_{ref} , irão satisfazer um dado conjunto de objetivos como solução do problema de controle em regime permanente. Esta solução estática da planta pode ser encontrada de diversas maneiras, até mesmo pela análise em experiências anteriores de controle da planta.

O algoritmo proposto para a resolução do problema multiobjetivo priorizado pode ser descrito pelos seguintes passos:

Inicialização - Passo 0: Estabelecer as relações entrada-saída pela análise estática do sistema. Com base nessas relações de regime permanente, formular as prioridades através da lógica proposicional, conforme [105]. Selecionar adequadamente os valores das variáveis de folga M_i , ϕ e M_ϕ .

Passo 1: Resolver o problema de priorização multiobjetivo para uma situação de regime permanente desejada. Os valores obtidos na otimização serão passados como referência ao controlador MPC. Estes valores serão referenciados como v_{ref} - problema de otimização concluído. Se existe solução factível, vá para o passo 3.

Passo 2: Se o problema de priorização multiobjetivo não for factível, pode-se utilizar um gerenciador de factibilidade. Este buscará suavizar as restrições, substituindo o conjunto de variáveis de folga M_i , ϕ e M_ϕ por outro M_i^\bullet , ϕ^\bullet e M_ϕ^\bullet menos restrito, até que exista uma solução que satisfaça as prioridades e minimize o critério de otimização. Repetir os passos 1 e 2 até que o problema de priorização esteja concluído.

Passo 3: Utilizar v_{ref} como referência no cálculo da ação de controle do algoritmo do controlador MPC empregado, o que envolve outro problema de minimização. A função de custo consistirá de uma soma ponderada dos quadrados dos objetivos individuais J_i , expressos por uma equação equivalente a (4.2), onde cada J_i é dado por $J_i = (v_i - v_{ref})^2$, sendo que v_i representa o valor atual dos objetivos.

Assim, a cada instante de tempo, dois problemas de otimização precisam ser resolvidos. O primeiro está relacionado à priorização dos objetivos e fornece valores ótimos para as variáveis envolvidas. O segundo problema de minimização envolve o cálculo da ação de controle, dependente dos valores ótimos gerados pela priorização. Isto significa que a etapa de otimização multiobjetivo se encontra em um nível mais alto que o cálculo do controle em si. Esse controlador será referenciado como MPC *priorizado*, daqui por diante.

Estas duas estratégias (MPC *ponderado* e MPC *priorizado*) podem ser aplicadas a qualquer controlador preditivo baseado no modelo. No entanto, para o estudo comparativo entre

as técnicas propostas neste capítulo, far-se-á uso do controlador SPGPC, selecionado através da análise realizada no capítulo 3. Devido às suas qualidades no controle de processos com atraso, em especial por sua robustez frente a variações paramétricas, este será o controlador MPC presente nos ensaios e simulações do decorrer do capítulo. Os detalhes do algoritmo SPGPC encontram-se no apêndice A. Na seqüência, trata-se de um exemplo real da aplicabilidade do MPC com otimização multiobjetivo, implementado através do SPGPC.

4.3.3 Aplicação à Planta de Extração de Azeite de Oliva (caso I)

Como exemplo inicial de aplicação das estratégias multiobjetivo ao MPC, utiliza-se uma planta de extração de azeite de oliva, cuja descrição encontra-se no apêndice D. Esta é uma planta multivariável com diversos objetivos a serem atendidos, que são dependentes de lógica. O processo tem vários graus de liberdade, o que permite a aplicação de diferentes estratégias de controle. Os dados usados na identificação das variáveis foram obtidos experimentalmente em uma indústria de extração de azeite de oliva, localizada em Málaga, Espanha. Os parâmetros do modelo do sistema foram determinados através de estimação por mínimos quadrados recursivos e pelo método da curva de reação. A descrição do processo por matriz de transferência pode ser vista na equação (4.7), onde a variável controlada $y(z)$ é o fluxo de azeite, as variáveis manipuladas $u_1(z)$, $u_2(z)$ e $u_3(z)$ são, respectivamente, a temperatura na termo-batedeira, o fluxo da pasta para o decantador e o fluxo de água para o decantador, $q_1(z)$ e $q_2(z)$ são as perturbações mensuráveis relacionadas à matéria-prima (quantidade de gordura e umidade da azeitona), tendo grande influência no desempenho da planta:

$$y(z) = [G_{u_1}(z) \ G_{u_2}(z) \ G_{u_3}(z)] \mathbf{u}(z) + [G_{q_1}(z) \ G_{q_2}(z)] \mathbf{q}(z) \quad (4.7)$$

Para simplificar as expressões, de agora em diante, a dependência com a variável discreta z será omitida. Para maiores detalhes sobre o processo, ver o apêndice D.

A experiência prática na planta real mostra que o processo pode ser bem controlado por um SPGPC com restrições, limitando o número de variáveis manipuladas. A escolha em operar o sistema através de um SPGPC foi feita com base em seu elevado índice de robustez, conforme demonstrado no capítulo 3. Entretanto, freqüentemente, uma perturbação (em geral relacionada ao tipo da azeitona) leva o sistema a uma região onde o problema de otimização do SPGPC é infactível, ou seja, nenhuma ação de controle pode ser computada. A factibilidade pode ser recuperada pela suavização das restrições, usando variáveis de folga. Além disso, as restrições e os objetivos de controle podem ser reestruturados por uma hierarquia de níveis de prioridade. A otimização multiobjetivo, além de possibilitar a inclusão de novos objetivos, com diferentes prioridades, no controle do processo, pode melhorar o desempenho industrial pela redução dos casos não-factíveis.

A estrutura física para a implementação do controle da planta de azeite de oliva é uma estrutura em cascata, com dois níveis, como pode ser visto na figura 4.1. Um controlador SPGPC é implementado para que o fluxo de azeite siga uma referência desejada, modificando as variáveis manipuladas que atuam como sinais de referência a uma malha interna, operada por controladores clássicos PID monovariáveis. A implementação industrial de um SPGPC com restrições mostrou a importância em incluir-se objetivos de controle e econômicos no sistema de produção do azeite de oliva [12, 96].




Figura 4.1: Estrutura do controle em cascata.

O algoritmo para priorização de objetivos implementado na planta de extração de azeite de oliva apresenta quatro objetivos de controle e de ordem econômica. As prioridades de controle estão relacionadas às entradas do operador na planta. Estas entradas são chamadas de y_{ref} para a referência de saída (*setpoint*) e \mathbf{u}_{ref} (com $\mathbf{u}_{ref} = [u_{1ref} \ u_{2ref} \ u_{3ref}]'$) para as variáveis manipuladas desejadas. O critério de desempenho selecionado, em ordem de decrescente importância, é descrito a partir das restrições (agora, objetivos de controle):

J_1 - manter a temperatura da termo-batedeira o mais próximo possível do valor ótimo, o que garante melhores características ao azeite produzido:

$$|u_1 - u_{1ref}| \leq \epsilon_{u_1} \quad (4.8)$$

J_2 - maximizar a quantidade de azeite extraído:

$$|y - y_{ref}| \leq \epsilon_y \quad (4.9)$$

J_3 - manter o fluxo de massa de azeitonas o mais próximo possível da referência do operador (reduzir o fluxo necessário para uma dada quantidade de óleo obtida):

$$|u_2 - u_{2ref}| \leq \epsilon_{u_2} \quad (4.10)$$

J_4 - reduzir o fluxo de água necessário na produção (a fim de baixar custos):

$$|u_3 - u_{3ref}| \leq \epsilon_{u_3} \quad (4.11)$$

onde ϵ_i , ($i = u_1, u_2, u_3, y$) são escalares positivos de magnitude pequena, representando a máxima tolerância admissível para atender os objetivos.

O primeiro objetivo é o mais importante, pois a variação de u_1 pode alterar as características do produto final. O segundo objetivo é o ajuste da variável de saída para ser controlada em torno do seu *setpoint*. O terceiro e o quarto objetivo estão relacionados à economia de energia no decorrer do processo de extração. Cada um destes objetivos é associado a um valor distinto de L_i , $i = 1, \dots, 4$, com diferentes pesos de priorização. O projeto dos pesos é um procedimento arbitrário, guiado pela heurística.

A tabela 4.2 resume a descrição destas prioridades através de lógica proposicional. A escolha dos pesos é dada pelos valores de ϵ_i e M_i , associados a cada objetivo i . As variáveis K_{u_i} representam os ganhos estáticos das funções de transferência G_{u_i} do processo, solução do problema de controle em regime permanente.

Objetivo 1: $ u_1 - u_{1ref} \leq \epsilon_{u_1}$	$-u_1 \leq -u_{1ref} + \epsilon_{u_1} + M_1(1 - L_1)$ $u_1 \leq u_{1ref} + \epsilon_{u_1} + M_1(1 - L_1)$
Objetivo 2: $ y - y_{ref} \leq \epsilon_y$	$-K_{u_1}u_1 - K_{u_2}u_2 - K_{u_3}u_3 \leq -y_{ref} + \epsilon_y + M_2(1 - L_2)$ $K_{u_1}u_1 + K_{u_2}u_2 + K_{u_3}u_3 \leq y_{ref} + \epsilon_y + M_2(1 - L_2)$
Objetivo 3: $ u_2 - u_{2ref} \leq \epsilon_{u_2}$	$-u_2 \leq -u_{2ref} + \epsilon_{u_2} + M_3(1 - L_3)$ $u_2 \leq u_{2ref} + \epsilon_{u_2} + M_3(1 - L_3)$
Objetivo 4: $ u_3 - u_{3ref} \leq \epsilon_{u_3}$	$-u_3 \leq -u_{3ref} + \epsilon_{u_3} + M_4(1 - L_4)$ $u_3 \leq u_{3ref} + \epsilon_{u_3} + M_4(1 - L_4)$
$\min \phi$	$-u_1 \leq -u_{1ref} + \epsilon_{u_1} + \phi + M_1L_1$ $u_1 \leq u_{1ref} + \epsilon_{u_1} + \phi + M_1L_1$ $-K_{u_1}u_1 - K_{u_2}u_2 - K_{u_3}u_3 \leq -y_{ref} + \epsilon_y + \phi + M_1(1 + L_2 - L_1)$ $K_{u_1}u_1 + K_{u_2}u_2 + K_{u_3}u_3 \leq y_{ref} + \epsilon_y + \phi + M_1(1 + L_2 - L_1)$ $-u_2 \leq -u_{2ref} + \epsilon_{u_2} + \phi + M_3(2 + L_3 - L_2 - L_1)$ $u_2 \leq u_{2ref} + \epsilon_{u_2} + \phi + M_3(2 + L_3 - L_2 - L_1)$ $-u_3 \leq -u_{3ref} + \epsilon_{u_3} + \phi + M_4(3 + L_4 - L_3 - L_2 - L_1)$ $u_3 \leq u_{3ref} + \epsilon_{u_3} + \phi + M_4(3 + L_4 - L_3 - L_2 - L_1)$
Restrições inteiras	$L_i \in \{0, 1\}, i = 1, \dots, 4$
Priorização de objetivos	$-L_2 + L_1 \geq 0$ $-L_3 + L_2 \geq 0$ $-L_4 + L_3 \geq 0$

Tabela 4.2: Restrições do controlador multiobjetivo priorizado.

No sentido de aplicar este procedimento ao MPC, para cada instante de tempo, o problema de priorização é recalculado. Os valores ótimos obtidos na priorização de objetivos são usados como referências desejáveis para um controlador SPGPC. A função custo implementada no SPGPC *priorizado* consiste de uma soma ponderada dos objetivos individuais,

descrita por:

$$J_{prior} = (y - y_{ref})^2 + \gamma \| \mathbf{u} - \mathbf{u}_{ref} \|_2 \quad (4.12)$$

Como pode ser observado, o problema de controle inclui uma priorização "natural" de objetivos. De qualquer modo, dois possíveis controladores foram implementados no sentido de resolver este problema: (i) um controlador multiobjetivo priorizado, segundo as prioridades descritas, e (ii) um controlador multiobjetivo ponderado, sem priorização. Através de uma análise comparativa entre ambos, selecionou-se o mais adequado a substituir o SPGPC com restrições, em funcionamento na planta real.

Análise I: SPGPC Ponderado x SPGPC Priorizado

Os parâmetros do processo que intervêm no cálculo dos controladores podem ser detalhados na seguinte lista.

- Entradas desejadas pelo operador:

$$\mathbf{u}_{op} = [35 \quad 2700-3000 \quad 150]$$

- Restrições dos sinais de entrada:

$$\begin{aligned} \mathbf{U}_{max} &= [37 \quad 4000 \quad 500] \\ \mathbf{U}_{min} &= [24 \quad 2000 \quad 0] \end{aligned}$$

- Restrições dos incrementos dos sinais de entrada:

$$\begin{aligned} \mathbf{u}_{max} &= [0.3 \quad 100 \quad 10] \\ \mathbf{u}_{min} &= [-0.3 \quad -100 \quad -10] \end{aligned}$$

Para o projeto do SPGPC *ponderado*, a função objetivo deve ser formalizada de acordo com a equação (4.2), só que levando em conta os objetivos de controle relacionados às entradas do operador na planta. Assim:

$$J_{pond} = (y - y_{op})^2 + \lambda \| \Delta \mathbf{u} \|_2 + \gamma \| \mathbf{u} - \mathbf{u}_{op} \|_2 \quad (4.13)$$

Os pesos λ e γ podem ser escolhidos por tentativa e erro, através de simulações numéricas, até que a maioria dos objetivos sejam satisfeitos. Este é um processo que depende da heurística, e usualmente leva mais tempo que a implementação do algoritmo de priorização. Os

controladores foram ajustados até alcançarem o melhor desempenho possível. Os pesos para o SPGPC *ponderado* foram selecionados como:

$$\lambda = [1 \quad 1 \quad 1]$$

$$\gamma = [0.01 \quad 0.01 \quad 0.01]$$

Observa-se que γ pondera diretamente os valores dos sinais de entrada selecionados pelo operador (\mathbf{u}_{op}).

Ao projetar o controlador SPGPC *priorizado*, descreve-se o processo através da lógica proposicional, sendo que apenas os limites das variáveis de interesse serão parâmetros de projeto do controle. Assim para as prioridades dos objetivos J_1, \dots, J_4 descritas pelas equações (4.8)-(4.11), os valores de ϵ foram escolhidos como:

$$\begin{aligned} |u_1 - u_{1ref}| &\leq 0.00001 \\ |y - y_{ref}| &\leq 0.01 \\ |u_2 - u_{2ref}| &\leq 5.00 \\ |u_3 - u_{3ref}| &\leq 20.00 \end{aligned}$$

As variáveis de folga M_i e ϕ foram selecionadas como: $\phi = 100.00$, $M_{u_1} = 0.00001$, $M_y = 2.00$, $M_{u_2} = 20.00$ e $M_{u_3} = 40.00$.

A comparação entres os controladores foi realizada, submetendo o sistema a três mudanças de comportamento: um degrau de referência de 3% foi aplicado em $t = 150$, uma mudança no fluxo de massa (entrada 2) de 12% no instante $t = 350$, assim como uma variação nas perturbações de 1.43% de gordura e 0.7% da umidade, no instante de simulação $t = 600$. Nas figuras 4.2 e 4.3, pode-se observar os resultados da simulação. As linhas contínuas representam o comportamento do controlador SPGPC *ponderado*, enquanto as linhas pontilhadas representam o comportamento do SPGPC *priorizado*.

Até o instante de simulação 150, pode-se comprovar que os 4 objetivos são atendidos para ambos os controladores. O algoritmo MIQP apresenta as seguintes entradas ótimas como solução da priorização de objetivos:

$$\mathbf{u}_{ref} = [35.00 \quad 2705.00 \quad 147.85]$$

A partir do instante 150, quando ocorre a mudança de referência, o controlador SPGPC *ponderado* modifica a temperatura da termo-batedeira, saturando-a em 37° C, a fim de alcançar o *setpoint* solicitado. Já o SPGPC *priorizado* para alcançar a referência modifica apenas a entrada de menor prioridade (fluxo de água), mantendo as demais com seus valores constantes. Assim, garante-se que todos os objetivos se cumprem, exceto o último. Nesse caso, o MIQP fornece como valores ótimos de entrada:

$$\mathbf{u}_{ref} = [35.00 \quad 2705.00 \quad 197.01]$$




Figura 4.2: Entradas reais do processo.

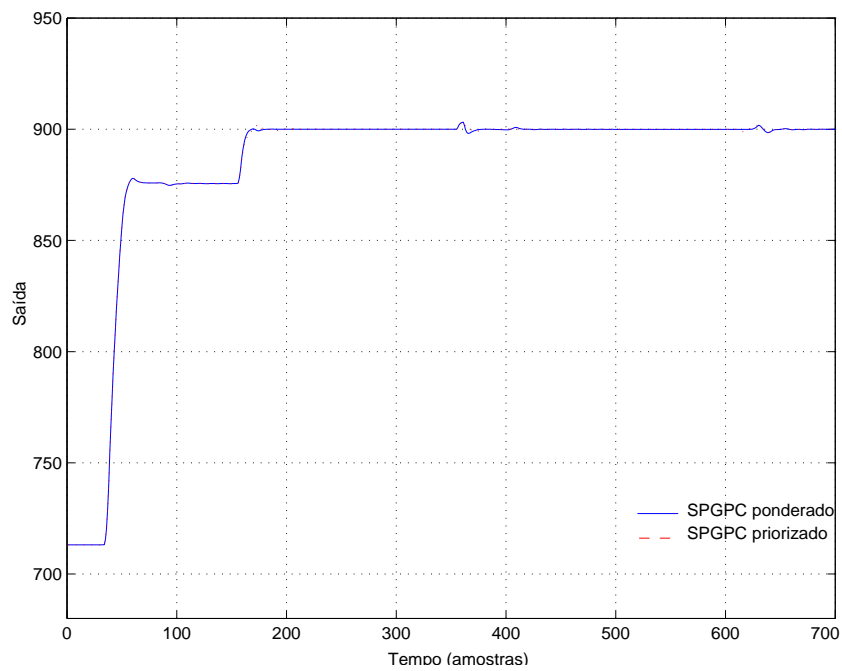


Figura 4.3: Saída do sistema.

No caso da mudança de fluxo de massa, as entradas desejadas calculadas pelo MIQP são:

$$\mathbf{u}_{ref} = [35.00 \quad 2976.70 \quad 90.00]$$

Nesse caso apenas os dois objetivos de maior prioridade são atendidos, isto é, a temperatura da termo-batedeira mantém-se a 35° C e a referência é alcançada, em penalização aos outros objetivos. Enquanto, o SPGPC *priorizado* controla o sistema, modificando os fluxos de massa e água, o SPGPC *ponderado* varia também a temperatura, levando-a novamente a saturação (24°C).

No instante 600, sob a atuação das perturbações, tem-se uma nova solução para o algoritmo MIQP:

$$\mathbf{u}_{ref} = [35.00 \quad 2995.00 \quad 101.1]$$

Assim, cumprem-se os três objetivos mais prioritários no caso do controlador SPGPC *priorizado*. A situação do SPGPC *ponderado* praticamente não se altera, mas a temperatura da termo-batedeira não está mais saturada.

Por estes resultados, pode-se concluir que o SPGPC *priorizado* é vantajoso, no sentido que permite cumprir as prioridades dos objetivos. Além disso, é mais intuitivo dar valores as variáveis de folga do algoritmo *priorizado* do que pesos aos termos da função objetivo. Seu maior inconveniente reside na necessidade de utilizar um algoritmo MIQP².

Análise II: SPGPC com Restrições x SPGPC Priorizado

Para ilustrar a aplicação prática do SPGPC *priorizado*, este foi comparado ao SPGPC com restrições existente na planta de extração de azeite de oliva. Ambos os controladores utilizam as três variáveis manipuladas; a temperatura da termo-batedeira, o fluxo de massa de azeitonas e o fluxo de água, para ajustar a variável controlada, o fluxo de azeite. As condições desejáveis de operação (y_{ref} , \mathbf{u}_{ref}) são usadas como referências ótimas para o controle multiobjetivo. Os dados do sistema foram normalizados e as referências selecionadas em $\mathbf{u}_{ref} = [50\%, 70\%, 50\%]$, representando os mesmos valores do caso anterior ([35, 2850, 150]). Os resultados desse trabalho estão publicados em [96].

Para a sua aplicação na planta real, estes foram implementados na linguagem de programação Visual C++, com a inclusão das rotinas da biblioteca NAG a fim de resolver os problemas de programação linear inteira mista, usando o método *Branch and Bound*.

²As simulações foram realizadas com a rotina `miqp.m`, uma versão não comercial para MATLAB, gentilmente cedida por Domenico Mignone, do grupo de pesquisa de Sistemas Híbridos do ETH, Zurique. Como a rotina ainda está em testes, seu uso não seria apropriado para aplicação em plantas reais.




Figura 4.4: Variáveis manipuladas.




Figura 4.5: Variável controlada.

Para as simulações com a planta, o atraso do modelo difere do tempo morto do processo em 40%. As incertezas são consideradas sem alterar o ajuste dos controladores. Dados reais das perturbações foram incluídos na simulação. Estes dados não podem ser apresentados devido a questão de sigilo industrial. O comportamento de malha fechada para o SPGPC com restrições e o SPGPC priorizado pode ser visto nas figuras 4.4 e 4.5. Em todos os gráficos, as linhas sólidas correspondem ao SPGPC com restrições e as linhas tracejadas ao controlador multiobjetivo SPGPC *priorizado*.

Para a simulação, um degrau de referência de 85% foi aplicado em $t = 100$, outro degrau de referência de 9% em $t = 370$, assim como um degrau de perturbação de 2% foi aplicado na entrada da planta em $t = 500$. Note que as respostas são similares e ambos os controladores estão bem ajustados, resultando em um bom seguimento de referência. O controlador SPGPC multiobjetivo apresenta até mesmo uma resposta mais rápida. Mas o maior atributo desse controlador é a garantia que os objetivos são satisfeitos, segundo as prioridades impostas. Note que todos os objetivos são satisfeitos até que ocorra a segunda mudança de referência. Neste estágio, o controlador pode satisfazer três dos objetivos, resultando que o fluxo de água não alcança o valor ótimo, de acordo com as prioridades. Quando a perturbação atua no sistema, a temperatura da termo-batedeira é a única variável que pode ser satisfeita, controlada em seu valor desejado (50%). Assim, este algoritmo é capaz de priorizar as restrições bem como alterar os objetivos de controle dependendo das condições das entradas do sistema. Como pode ser observado, o SPGPC com restrições pode controlar o sistema, mas as variáveis manipuladas possuem valores distintos dos desejados.

A análise dos controladores demonstra a vantagem em modificar-se a aplicação do SPGPC com restrições existente na planta para o SPGPC *priorizado*. A aplicação do controlador SPGPC *priorizado* na planta real pode ser justificada como segue:

- o controlador provê uma resposta mais rápida;
- as variáveis manipuladas freqüentemente atingem os valores ótimos;
- o objetivo principal é sempre alcançado; e
- quando são minimizados os fluxo de água e de massa, pode-se conseguir economia energética no sistema.

4.4 MPC com Priorização Estruturada de Objetivos

Embora a aplicação prática da metodologia de priorização dos objetivos seja viável, esta técnica apresenta como maior inconveniente a necessidade de dispor de algoritmos numéri-

cos que resolvam um problema do tipo MIQP ou MILP. A maioria dos *softwares* matemáticos difundidos no mercado ainda não dispõe deste recurso, tornando necessária também a programação desta rotina matemática. Esta tarefa não é trivial, devido especialmente aos casos particulares nos quais o problema não tem solução. Além disso, os problemas de programação inteira mista apresentam dificuldades em sua resolução, sendo que, no pior caso, o tempo de solução cresce exponencialmente com o tamanho do problema [83]. Desse modo, a implementação do controlador priorizado não se constitui em uma estratégia simples, adaptável ao meio industrial.

Num problema de controle, quando não se pode satisfazer todas as restrições simultaneamente, é desejável satisfazer tantas restrições de maior prioridade quanto possível. As violações das outras restrições (não-factíveis) devem ser minimizadas, levando em conta a prioridade relativa entre elas [98]. Em [106], foi demonstrado como a magnitude de violações de restrições de menor prioridade pode ser minimizada sem a necessidade de uso de otimização inteira mista. Este trabalho mostra que, quando a função objetivo é propriamente escolhida, apenas um programa linear (*Linear Programming*, LP) é necessário para solucionar o problema de controle. Isto resulta em uma significativa simplificação comparado ao uso de programação inteira mista. A idéia apresentada em [106] para o tratamento de restrições no MPC é formular um problema de otimização tal que a violação da restrição de menor prioridade não possa ser minimizada sem aumentar a violação de uma restrição de maior prioridade, buscando o *mínimo lexicográfico* de violação de restrições. A solução apresentada é minimizar uma combinação de variáveis de folga que aparecem na função objetivo. Se as variáveis de folga estão ordenadas para que a primeira corresponda à restrição de maior prioridade, e a última à de menor prioridade, então o mínimo lexicográfico está garantido pela escolha de uma relação suficientemente grande entre os pesos na combinação linear. Determinar quão larga deve ser esta relação envolve resolver outro problema LP, fora do algoritmo de otimização (*off-line*). Assim, é apresentado um algoritmo que permite calcular o controle na presença de não-factibilidades, levando em conta a informação contida na priorização das restrições [106, 107]. Este algoritmo pode ser resumidamente descrito pelos seguintes passos:

1. verifica a factibilidade do problema de otimização sob restrições;
2. suaviza as restrições não-factíveis, obedecendo às prioridades, por meio de um problema de minimização auxiliar;
3. resolve o problema de otimização, com todas as restrições agora factíveis.

Inspirado nessas idéias de [106, 107] para o problema de tratamento de restrições, propôs-se nesta tese uma solução simplificada e de fácil programação para o problema de otimização multiobjetivo. Esta metodologia proposta utiliza expressões de natureza estruturada (regras do tipo *if-then-else*) aplicadas sobre os diferentes objetivos associados ao controle MPC.

4.4.1 MPC com Estruturação de Objetivos

Para um dado processo a controlar, considere um conjunto de objetivos de controle $\mathbf{J} = \{J_1, J_2, \dots, J_m\}'$. O método por priorização estruturada dos objetivos visa converter \mathbf{J} em um problema escalar construído a partir da soma ponderada de todos os objetivos. Diferentemente do MPC ponderado, atribui-se variados pesos aos objetivos, dependendo do cumprimento ou não das prioridades impostas. Seja p o número de prioridades relacionadas ao problema de controle. Note que p não necessariamente é igual a m , pois diferentes objetivos podem estar associados ao mesmo nível de prioridade. Assim, $p \leq m$. Levando em conta todos os objetivos J_i , pode-se converter na minimização de uma determinada função custo $\mathbf{J}_{(p)}$, escolhida de acordo com uma prioridade p , sujeita a um conjunto de restrições lineares nas variáveis de decisão $\mathbf{R}_i \mathbf{u} \leq \mathbf{a}_i$.

A seqüência de controle futura é determinada pela minimização de uma função objetivo do tipo:

$$\min \mathbf{J}_{(p)} = \sum_{i=1}^m p_i J_i, \quad p_i \geq 0 \quad (4.14)$$

$$\text{s.a.} \quad \mathbf{R}_i \mathbf{u} \leq \mathbf{a}_i, \quad i = 1, \dots, m$$

onde p_i são os pesos atribuídos aos objetivos de controle J_i dentro de cada função custo $\mathbf{J}_{(p)}$. Para cada $\mathbf{J}_{(p)}$, a importância relativa entre os objetivos é modulada pelo ajuste dos pesos p_i .

O algoritmo proposto associa uma variável inteira L_p , a cada nível de prioridade p , buscando atender os objetivos, de acordo com os níveis de prioridade arbitrados. Por exemplo, supondo que cada objetivo tenha prioridades distintas, quando um determinado objetivo J_1 (mais prioritário) se cumpre, $L_1 = 1$ e a função objetivo associada ao mesmo não é selecionada. Se o objetivo J_2 não é atendido, $L_2 = 0$ e a função objetivo $\mathbf{J}_{(2)}$ será selecionada a fim de que este objetivo se cumpra também. Dessa forma, o algoritmo garante que os objetivos de maior prioridade são atendidos antes dos menos prioritários. O controlador relativo a este algoritmo será referenciado como MPC *estruturado*.

O algoritmo proposto para resolver o problema multiobjetivo estruturado, sujeito às restrições com prioridades, apresenta uma etapa de ajuste da estruturação, composta por 6 passos, e outra etapa *on-line* executada dentro do algoritmo MPC. Os passos de inicialização são os seguintes:

Passo 1: Definir as p prioridades existentes entre os m objetivos de controle J_i . Associar funções de otimização $\mathbf{J}_{(p)}$.

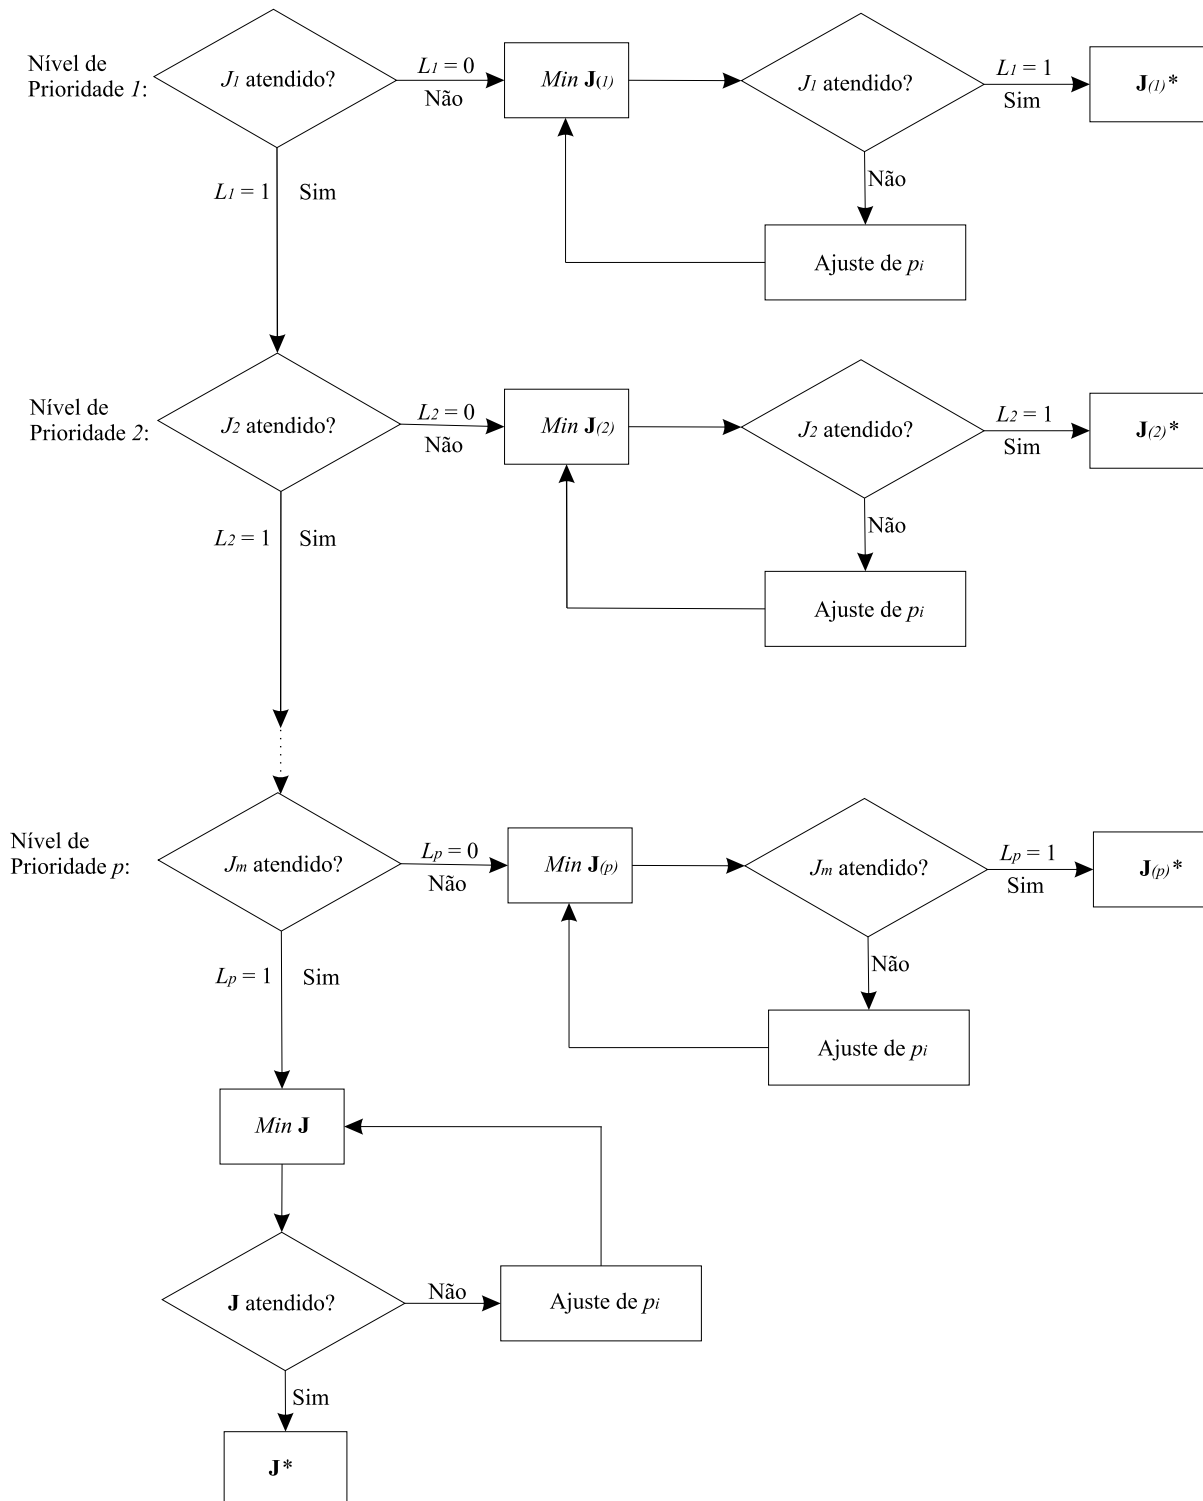


Figura 4.6: Fluxograma do algoritmo de priorização estruturada.

Passo 2: Resolver o problema de otimização associado a $\mathbf{J}_{(p)}$ definido de acordo com (4.14), de modo a satisfazer o objetivo mais prioritário. Atribuir diferentes p_i , por tentativa e erro, até obter uma solução factível. Se a solução factível existe, este ótimo $\mathbf{J}_{(p)}^*$ foi encontrado - um problema de minimização concluído.

Passo 3: Verificar a existência de solução para o conjunto \mathbf{J} , considerando cada uma das p prioridades atribuídas. Repetir o passo 2, p vezes, até obter os pesos p_i que levam ao ótimo para cada prioridade.

Passo 4: Se o conjunto de prioridades p e critérios $\mathbf{J}_{(p)}$ associados não for factível, deve-se substituí-los por outro conjunto de prioridades p^* e critérios $\mathbf{J}_{(p^*)}$ associados. Repetir os passos 3 e 4, até que a solução satisfaça as prioridades e minimize o critério de otimização.

Passo 5: Estabelecer regras de decisão, do tipo *if-then-else*, que permitam alternar entre as diferentes $\mathbf{J}_{(p)}$ envolvidas no problema de otimização. O algoritmo MPC deve verificar estas regras para saber qual $\mathbf{J}_{(p)}$ utilizar na minimização em cada instante de tempo.

Passo 6: Atribuir uma variável inteira L_p , a cada nível de prioridade p estipulado. Quando o(s) objetivo(s) J_i envolvido(s) em uma prioridade p forem atendidos, $L_p = 1$, senão $L_p = 0$. O algoritmo busca o primeiro objetivo mais prioritário não satisfeito ($L_p = 0$) para selecionar a $\mathbf{J}_{(p)}$ que resolve o problema de minimização.

As etapas *on-line* do algoritmo MPC estruturado são as seguintes:

Passo 7: Verificar, segundo os níveis de prioridades, o cumprimento ou não de um objetivo, com base nas variáveis do processo. Quando o(s) objetivo(s) J_i envolvido(s) em uma prioridade p forem cumpridos, $L_p = 1$, senão $L_p = 0$.

Passo 8: Verificar os valores das variáveis L_p , buscando o primeiro objetivo prioritário não satisfeito ($L_p = 0$) para selecionar a função $\mathbf{J}_{(p)}$ correspondente que minimize o(s) objetivo(s) mais prioritário(s) não atendido(s).

Passo 9: Resolve o problema de otimização associado ao nível de prioridade cujo $L_p = 0$. A ação de controle calculada, segundo a priorização, é aplicada ao processo. As demais variáveis do processo são recalculadas de acordo com o algoritmo MPC padrão.

Durante o funcionamento do sistema de controle, repete-se os passos 7, 8 e 9 a cada instante de tempo, para seleção da função objetivo. A mudança para uma ou outra dessas funções objetivo irá depender das excursões das variáveis fora de sua região limitante, selecionada através do algoritmo. Essas etapas do algoritmo podem ser melhor compreendidas pelo fluxograma da figura 4.6.

A aplicação desta estratégia de otimização multiobjetivo à planta de extração de azeite de oliva será apresentada na seqüência, utilizando para tanto o controlador SPGPC. Demonstre-se, em uma análise comparativa aos outros dois controladores multiobjetivo já implementados, a qualidade do algoritmo proposto.

4.4.2 Aplicação à Planta de Extração de Azeite de Oliva (caso II)

Três diferentes controladores preditivos são comparados, todos tentando atender as mesmas especificações de controle apresentadas no caso I, da seção 4.3.3: (i) um controlador multiobjetivo MPC *priorizado* idêntico ao apresentado anteriormente; (ii) um controlador multiobjetivo MPC *ponderado*; e (iii) um controlador multiobjetivo MPC *estruturado*, nos moldes do algoritmo descrito nesta seção.

No MPC *estruturado*, a idéia é criar uma estrutura de controle que utilize uma lista de decisão baseada em um conjunto de declarações do tipo *if-then-else* para selecionar a função objetivo atual, que deve ser fornecida para o cálculo do controle MPC. A implementação lógica está relacionada à importância dos objetivos J_1 a J_4 , descritos pelas equações (4.8)-(4.11), na seção 4.3.

As regras de decisão atribuem valores as variáveis inteiras L_p , relacionadas a cada objetivo J_i (no caso, i níveis de prioridade), conforme se mostra a seguir:

$$\begin{array}{llll}
 \text{SE} & |u_1 - u_{1ref}| \leq \epsilon_{u_1} & \text{ENTÃO} & L_1 = 1 \rightarrow J_1 \text{ atendido} \\
 \text{SE} & |y - y_{ref}| \leq \epsilon_y & \text{ENTÃO} & L_2 = 1 \rightarrow J_2 \text{ atendido} \\
 \text{SE} & |u_2 - u_{2ref}| \leq \epsilon_{u_2} & \text{ENTÃO} & L_3 = 1 \rightarrow J_3 \text{ atendido} \\
 \text{SE} & |u_3 - u_{3ref}| \leq \epsilon_{u_3} & \text{ENTÃO} & L_4 = 1 \rightarrow J_4 \text{ atendido}
 \end{array}$$

As funções objetivo implementadas para resolver o problema de minimização do MPC seguem as seguintes regras lógicas:

$$\begin{array}{llll}
 \text{SE} & L_1 = 0 & \text{ENTÃO} & \mathbf{J}_{(1)} = \delta(y - y_{ref})^2 + \lambda(\Delta u)^2 + \gamma_1 \|\mathbf{u} - \mathbf{u}_{ref}\|_2 \\
 \text{SENÃO SE} & L_2 = 0 & \text{ENTÃO} & \mathbf{J}_{(2)} = \delta(y - y_{ref})^2 + \lambda(\Delta u)^2 + \gamma_2 \|\mathbf{u} - \mathbf{u}_{ref}\|_2 \\
 \text{SENÃO SE} & L_3 = 0 & \text{ENTÃO} & \mathbf{J}_{(3)} = \delta(y - y_{ref})^2 + \lambda(\Delta u)^2 + \gamma_3 \|\mathbf{u} - \mathbf{u}_{ref}\|_2 \\
 \text{SENÃO SE} & L_4 = 0 & \text{ENTÃO} & \mathbf{J}_{(4)} = \delta(y - y_{ref})^2 + \lambda(\Delta u)^2 + \gamma_4 \|\mathbf{u} - \mathbf{u}_{ref}\|_2 \\
 \text{SENÃO} & & & \mathbf{J}_{(5)} = \delta(y - y_{ref})^2 + \lambda(\Delta u)^2 + \gamma_5 \|\mathbf{u} - \mathbf{u}_{ref}\|_2
 \end{array}$$

Após aplicar os passos de inicialização do algoritmo MPC *estruturado*, obtém-se os pesos para cada caso. Os parâmetros δ , λ foram fixados ($\delta = 1$ e $\lambda = [10 \ 10 \ 10]'$) para todas as

funções objetivo e o valor de γ muda de acordo com os níveis de prioridade:

$$\begin{aligned} \gamma_5 = \gamma_1 &= [1 \ 0 \ 0], & \gamma_2 &= [0 \ 0 \ 0] \\ \gamma_3 &= [0 \ 1 \ 0], & \gamma_4 &= [0 \ 0 \ 1] \end{aligned}$$

A escolha dos pesos γ_i foi simplificada pela inclusão somente do objetivo não atendido à função objetivo (por isso, o vetor γ_i assume apenas valores 0 ou 1). Note que a última função objetivo, $\mathbf{J}_{(5)}$, só será selecionada no caso de todos os objetivos terem sido atendidos. No presente caso, fez-se $\mathbf{J}_{(5)} = \mathbf{J}_{(1)}$, a fim de garantir o cumprimento do objetivo mais prioritário, mas nada impede que se atribuisse pesos distintos a γ_5 .

Para o MPC *ponderado*, utilizou-se um novo ajuste a fim de melhor compará-lo ao MPC *estruturado*. O ajuste dos pesos foi selecionado como: $\lambda = [10 \ 10 \ 10]'$ e $\gamma = [1 \ 1 \ 0]'$.

Análise Comparativa: MPC Ponderado x MPC Priorizado x MPC Estruturado

Para ilustrar a aplicação desses três métodos de otimização multiobjetivo, considere a planta de azeite de oliva descrita no anexo D. Os controladores utilizam as variáveis manipuladas; a temperatura da termo-batedeira, o fluxo de massa de azeitonas e o fluxo de água, para ajustar o fluxo de azeite (variável controlada). As condições desejáveis de operação (y_{ref} , \mathbf{u}_{ref}) são usadas como referências ótimas para o controle multiobjetivo. As prioridades de controle estão descritas conforme apresentado na seção 4.3.3. A idéia principal dos controladores implementados é atender ao maior número de objetivos prioritários, além de obter um bom comportamento em malha fechada.

No sentido de comparar as diferentes estratégias, os controladores foram submetidos a mudanças tipo degrau de referência nas três entradas assim como diferentes perturbações. Considera-se que um controlador atende um objetivo quando o valor do sinal correspondente não excede uma dada banda com respeito ao valor desejado. Os valores destas bandas devem levar em conta a experiência com a planta real. Os resultados desta análise foram apresentados em [73].

Em todos os casos, as linhas pontilhadas correspondem aos sinais do MPC *ponderado*, as linhas sólidas fina e espessa correspondem ao MPC *estruturado* e MPC *priorizado*, respectivamente. As figuras aparecem por ordem de prioridades, o que significa que se mostram os valores de u_1 , da saída y , u_2 e u_3 , nessa seqüência. Nos gráficos das entradas, as linhas tracejadas referem-se às entradas desejadas, assim como no gráfico de saída, esta curva corresponde à referência. Para todas as simulações, os valores assumidos pelas variáveis foram normalizados.

Para a primeira simulação, mostrada na figura 4.7, um degrau de 20% foi aplicado na entrada u_1 . É possível observar como o primeiro objetivo é atendido pelos três controladores simulados, alcançando o valor desejado para u_1 . O segundo objetivo também é alcançado por todos os controladores, apesar de que o comportamento do MPC *priorizado* é muito mais suave que dos outros, chegando ao valor de referência primeiramente. O terceiro objetivo é apenas atendido pelo MPC *priorizado*. Uma vez que os outros violam a referência de u_2 , note que o controlador MPC *estruturado* apresenta um erro médio menor que o MPC *ponderado*, estando em alguns instantes muito próximo de atender este objetivo. E finalmente, o quarto objetivo não é atendido por nenhum dos controladores. Note que o erro do controlador MPC *priorizado* é até superior ao dos outros no objetivo de menor prioridade, porque u_3 é sacrificada para que se possa alcançar os objetivos de maior prioridade.

Na figura 4.8, o comportamento dos controladores é mostrado quando uma mudança tipo degrau de 14% em u_2 , produzida pelo operador, é aplicada. Os controladores MPC *priorizado* e MPC *estruturado* atendem todos os objetivos exceto o último, enquanto o MPC *ponderado* apenas atende o primeiro e o segundo. É necessário enfatizar que, no MPC *priorizado*, é possível alcançar mais um objetivo porque afasta-se um pouco, nos objetivos de maior prioridade, dos valores desejados, sem deixar as bandas de segurança permitidas.

No terceiro caso, visto na figura 4.9, um degrau 33.4% na entrada u_3 é produzido. Os três controladores alcançam o primeiro e o segundo objetivos, mas os controladores MPC *priorizado* e MPC *estruturado* estão mais perto da referência do terceiro objetivo que o MPC *ponderado*. Para isto, eles afastam-se muito mais dos objetivos de menor prioridade.

Na quarta simulação, figura 4.10, um degrau de referência de 20% no fluxo de azeite é executado. Os controladores MPC *priorizado* e MPC *estruturado* comportam-se melhor que o MPC *ponderado*, já que eles cumprem todos os objetivos, menos o de menor prioridade. O MPC *ponderado* gera um comportamento pior, pois só atende os dois objetivos prioritários.

Com o intuito de comparar quantitativamente as violações dos objetivos dos três controladores nos quatro casos anteriores, um novo índice de comportamento foi calculado, com base no ITSE³. Este índice, denominado WITSE, considerando a média ponderada (de acordo com a prioridade de cada objetivo) dos valores de ITSE, calculados pelos erros obtidos em cada controlador, é dado por:

$$\text{WITSE} = \sum_{i=1}^4 W_i * \text{ITSE}_i \quad (4.15)$$

onde W_i pondera os valores de cada ITSE, segundo às prioridades impostas.

³O índice de comportamento ITSE, calculado por $\text{ITSE} = \int_0^T t.e^2 dt$, foi usado para analisar o erro na entrada como uma diferença entre os valores de entrada desejados e seu valor real, e no caso da saída como a diferença entre a saída real e sua referência.




Figura 4.7: Resposta do sistema a um degrau de 20% em u_1 .




Figura 4.8: Resposta do sistema a um degrau de 14% em u_2 .




Figura 4.9: Resposta do sistema a um degrau de 33.4% em u_3 .




Figura 4.10: Resposta do sistema a um degrau de referência de 20% em y .

A tabela 4.3 resume os erros para cada uma das simulações anteriores, com respeito às mudanças em u_1 , u_2 , u_3 e y , nessa ordem.

Controlador	MPC ponderado	MPC priorizado	MPC estruturado
Degrau em u_1	0.025118	0.008618	0.005683
Degrau em u_2	7.402732	4.062447	6.729413
Degrau em u_3	0.355468	0.012871	0.005420
Degrau em y	11.953248	2.811858	8.243687

Tabela 4.3: Índices WITSE.

Na tabela 4.3, é possível observar que o comportamento do MPC *ponderado* é pior que dos outros controladores. Já a operação dos controladores MPC *priorizado* e MPC *estruturado* são similares e dependentes do ajuste de seus parâmetros. A qualidade de cada um dependerá da natureza do sistema a ser controlado. Se a aplicação necessita um controlador com resposta suave no caso de mudanças nas entradas ou de referência, é necessário ajustar o parâmetro γ do MPC *estruturado* com menores valores do que os usados no controlador MPC *priorizado*. Este ajuste resulta em um acréscimo nos índices de erros do MPC *estruturado*. Em contraste, se um sistema requer resposta mais rápida e não restringe a abrupticidade nos sinais de controle, então o MPC *estruturado* pode ser ajustado para obter índices ITSE menores que os conseguidos pelo MPC *priorizado*.

Todos os controladores presentes nessa análise são válidos para serem implementados na planta real. A escolha deve ser feita baseada nas vantagens e desvantagens de cada um, nos recursos de aplicação e sobretudo nas exigências e requerimentos do sistema de controle.

O controlador MPC *priorizado* apresenta melhor comportamento com respeito ao atendimento das prioridades dos objetivos. Além disso, não necessita de ajuste dos pesos da função objetivo $(\gamma, \lambda, \delta)$, vantagem em relação ao MPC *ponderado*, já que o ajuste destes pesos costuma levar tempo e não é simples, por causa da complexidade do sistema: um processo multivariável, lento e com grande atraso. Esse controlador tem outros parâmetros de ajuste que são as folgas dos objetivos, mais fáceis e intuitivos de se obter. A principal desvantagem do MPC *priorizado* é a necessidade de um custo adicional importante, tanto do ponto de vista computacional como econômico, já que requer um pacote de *software* que permita a solução do problema MILP. Outra desvantagem é a necessidade de gerenciamento da factibilidade, no caso do problema MILP ser infactível.

O controlador MPC *estruturado* foi concebido para resolver as desvantagens do MPC *priorizado*. Este controlador possui um ajuste simples, e seu tempo de cálculo é muito menor que dos outros controladores. Seu comportamento com respeito ao cumprimento das prioridades é bastante bom, e aceitável, chegando mesmo a ser superior ao MPC *priorizado* em algumas situações. Seu principal inconveniente consiste em alcançar um equilíbrio entre as diferentes

funções objetivos, para evitar sinais abruptos durante os chaveamentos. Vale salientar que este comportamento pode ser evitado pela inclusão, no algoritmo do MPC *estruturado*, de regras de decisão relacionadas às variações dos sinais de controle Δu_i ($i = 1, \dots, 4$), segundo os incrementos máximos permitidos. No entanto, buscando igualdade entre os algoritmos, ao incluir regras sobre os incrementos do sinal de controle para o MPC *priorizado*, estas tornam o problema computacionalmente intratável. Por esta razão, esta solução não é apresentada nessa comparação.

4.5 Conclusões

Esse capítulo abordou soluções para resolver a otimização de múltiplos objetivos em controle preditivos de processos, enfocando o tema da priorização. Uma revisão de diferentes técnicas de otimização multiobjetivo foi apresentada, enfatizando questões como cálculo da função multiobjetivo e diferenças entre os algoritmos discutidos. Uma aplicação das estratégias multiobjetivo no controle de uma planta real foi analisada. Ao final do capítulo, desenvolveu-se e analisou-se uma formulação para tratamento do problema multiobjetivo, usando regras de decisão.

O resultado desse estudo mostra que, apesar de todas as estratégias de controle multiobjetivo poderem ser aplicadas ao processo real, cada uma apresenta vantagens e desvantagens em seu emprego. O controlador MPC *ponderado* possui o pior comportamento comparado aos outros controladores devido ao baixo número de objetivos atendidos. A necessidade de ajuste dos pesos da função de custo é outra desvantagem dessa estratégia. Contudo, não necessita nenhum *software* adicional para seu desenvolvimento. Com o MPC *priorizado*, o maior número de objetivos satisfeitos, sem a necessidade de ajuste de pesos, está garantido. Seu ponto fraco é a necessidade de *software* complexo, tendo como conseqüência um acréscimo no custo total do sistema e no tempo de processamento. Uma opção intermediária é o uso do controlador MPC *estruturado*. Este requer ajuste simplificado de pesos nas funções objetivo envolvidas mas, por outro lado, apresenta um comportamento mais abrupto no chaveamento das diferentes funções objetivos (o que pode ser solucionado pela inclusão de regras de decisão relativas aos incrementos do controle).

Uma boa alternativa para solucionar o problema de controle de um sistema através de otimização multiobjetivo é um controlador que alie o MPC *estruturado* ao MPC *priorizado*, com a função de um gerenciador de factibilidades. Assim, sempre que a solução do problema MILP for infactível, o controlador MPC *estruturado* substitui o MPC *priorizado* no cálculo da ação de controle.

Capítulo 5

Considerações Finais

Esta tese centrou-se no estudo do controle preditivo baseado no modelo (MPC) e sua aplicabilidade à processos industriais. No âmbito de controladores preditivos, as possibilidades de lidar com sistemas multivariáveis e não-lineares, compensar atrasos e perturbações mensuráveis e incluir o tratamento de restrições no projeto do controlador indicam seu valor para aplicações práticas de controle e desenvolvimento de pesquisas, tanto no meio acadêmico quanto no industrial.

O enfoque desta tese foi a contribuição para a melhoria da solução do controle de sistemas, com o intuito de produzir técnicas e ferramentas de controle preditivo que incorporassem aspectos como tratamento de atraso, robustez, restrições e otimização multiobjetivo. Nesta tese, realizam-se contribuições basicamente em duas áreas: (i) no controle de processos com atrasos dominantes e (ii) na otimização multiobjetivo do controle, ambas visando a melhoria da eficiência do sistema.

5.1 Contribuições

Como contribuição na área de sistemas com atrasos, uma análise do efeito de grandes atrasos no sistema em malha fechada, permitiu comprovar que a composição controlador primário mais preditor é válida para outros algoritmos MPC. Este estudo foi realizado no contexto do controlador preditivo por matriz dinâmica (DMC). Desenvolveu-se uma representação do DMC como um controlador primário mais um preditor, a fim de discutir o efeito do atraso e do erro de medição do mesmo, na busca da melhoria da robustez do controle frente a variações paramétricas na planta. Os resultados obtidos são úteis, porque per-

mitem comprovar que o controlador DMC apresenta melhor robustez que o GPC, em sistemas monovariáveis de primeira ordem com atrasos dominantes. Além disto, esta análise permitiu demonstrar que, no caso geral, o controlador SPGPC apresenta índice de robustez superior aos controladores GPC e DMC. Esta análise, comprovando que o SPGPC é mais robusto do que o DMC, incentiva sua utilização a nível industrial, especialmente no controle de processos estáveis com atrasos, setor onde o DMC se encontra amplamente difundido.

Analisando o tema da otimização do controle, o objetivo deste trabalho foi o desenvolvimento de estratégias de controle preditivo para processos industriais, que considerassem no projeto de controle, aspectos econômicos, além das restrições técnicas e/ou operacionais que habitualmente constam no controlador. As estratégias de controle propostas utilizam um nível supervisor para determinar as referências ótimas de controle para um nível regulatório. Dois métodos foram descritos. Em um deles, o nível supervisor baseia-se em um otimizador, projetado a partir de uma função objetivo, baseada na integração de heurística, lógica e dinâmica do processo por meio de regras descritas através de lógica proposicional, resultando em um problema de programação quadrática inteira mista. Na busca por uma solução mais simples e aplicável à indústria, o outro método proposto utiliza-se de lógica estruturada para realizar a seleção entre as múltiplas funções objetivo de controle, também descritas por prioridades segundo a dinâmica desejada do processo. Ambas as estratégias desenvolvidas permitiram a melhoria do desempenho do sistema, especialmente do ponto de vista econômico. Deve-se notar que a disposição de um sistema que possa otimizar uma função objetivo com critérios tanto tecnológicos como econômicos se traduz em um benefício claro, pois naturalmente se pretenderá reduzir custos de operação (associados com a energia consumida e as matérias primas) e melhorar a qualidade do produto. Os benefícios econômicos derivados do uso destes controladores poderão ser:

- Economia energética, devido a diminuição da variância das variáveis controladas;
- Aumento da produção ao poder operar mais próximo das restrições;
- Melhoria da qualidade dos produtos ao diminuir a variabilidade na produção;
- Otimização econômica ao considerar custos como parte da função multiobjetivo.

Os algoritmos foram desenvolvidos, buscando obter soluções de fácil implementação e utilização no meio industrial para o controle de processos, considerando fundamentalmente questões como simplicidade no ajuste de parâmetros do controlador e comportamento robusto do mesmo. Buscando maior robustez ao sistema, a otimização multiobjetivo foi implementada conjuntamente com o controlador SPGPC, comprovado anteriormente como mais robusto que os controladores MPC usuais da indústria. As propostas aqui apresentadas foram implementadas e aplicadas a processos reais, entre eles uma planta de extração de azeite de

oliva, uma planta solar de climatização e uma planta piloto para processos térmicos. O produto final desta pesquisa pode ser de grande interesse a empresas de pequeno e médio porte. Estas empresas não estão em geral preparadas para embutir controle avançado em seus produtos de mercado, devido tanto ao custo econômico dos controladores atuais (como no caso do DMC, projetado para grandes empresas petroquímicas) quanto ao investimento necessário em pessoal qualificado.

Deve-se ressaltar que, durante o período de doutorado, realizou-se um período de estágio no grupo de pesquisa DISA, da Universidade de Sevilha, Espanha. Este estágio permitiu consolidar este trabalho de pesquisa através do contato com outros pesquisadores da área, do *Departamento de Ingeniería de Sistemas y Automática* (DISA), que possuem experiência no controle de processos industriais, onde realizaram numerosas aplicações de controladores MPC. Além das aplicações industriais e do nível de competência técnica, o sucesso alcançado no estágio no DISA se deve ao elevado investimento que o departamento fez na área de processos, construindo para isto uma série de instalações em escala semi-industrial, mas que são fiéis às encontradas nas indústrias. Destas instalações, cita-se as seguintes plantas utilizadas como campo de prova para o desenvolvimento dessa tese:

- Planta piloto de processos térmicos;
- Instalação solar de refrigeração.

5.2 Publicações

- 2002** C.B. Scheffer-Dutra, A. Núñez-Reyes, C. Bordons. *Controle Preditivo com Restrições aplicado a uma Planta Solar de Climatização*. **XIV Congresso Brasileiro de Automática**, UFRN, Natal, CD-ROM CBA2002, páginas 2798-2803.
- 2002** A. Núñez-Reyes, C.B. Scheffer-Dutra, C. Bordons. *Comparison of Different Predictive Controllers with Multi-objective Optimization. Application to an Olive Oil Mill*. **Congress of Control Applications**, Glasgow-Escócia, CD-ROM CCA2002, páginas 1242-1247.
- 2002** C.B. Scheffer-Dutra, J.E. Normey-Rico, E.B. Castelan. *Robustness Analysis of DMC for First Order plus Dead-time Processes*. **15th IFAC World Congress**, Barcelona-Espanha, CD-ROM B'02, 6 páginas.
- 2002** C.B. Scheffer-Dutra, A. Núñez-Reyes, C. Bordons. *Predictive Control of an Olive Oil Mill with Multi-objective Prioritization*. **15th IFAC World Congress**, Barcelona-Espanha, CD-ROM B'02, 6 páginas.

- 2001** C.B. Scheffer-Dutra, J.E. Normey-Rico. *Un DMC Simplificado para Control de Procesos con Retardo*. **XXII Jornadas de Automática**, UAB, Barcelona-Espanha, CD-ROM JA2001, 6 páginas.
- 1999** O.M. Almeida, A.C.G. Rodrigues, C.B. Scheffer, J.F.T. Vargas, A.A.R. Coelho. *Avaliação Experimental de Hibridização de Estratégias de Controle Nebulosa e Preditiva em um Processo Não Linear de Luminosidade*. **IV Congresso Brasileiro de Redes Neurais**, ITA, São José dos Campos, páginas 136-141.
- A publicar** D.R. Ramírez, C.B. Scheffer-Dutra, E.F. Camacho. *Lienalidad a Trozos de los Controladores Min-Max MPC con Restricciones*. **Capítulo de livro de Controle de Processos Industriais: Red Iberoamericana de Informática (RIII) do Programa Iberoamericano de Ciencia y Tecnología para el Desarrollo (CYTED)**, Espanha.

5.3 Perspectivas

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

- Realizar a análise da robustez do DMC, para sistemas multivariáveis.
- Buscar uma solução simplificada para a questão de gerenciamento de factibilidade de restrições, com base nos trabalhos [106, 107], adaptando estas idéias à otimização multiobjetivo.
- Utilizar os resultados propostos em aplicações industriais na região (indústria cerâmica, por exemplo), e no país.

Apêndice A

Algoritmos de Controle Preditivo

Este apêndice é dedicado a revisão dos algoritmos MPC utilizados como base no desenvolvimento desta tese: o DMC (*Dynamic Matrix Control*), o GPC (*Generalized Predictive Control*) e o SPGPC (*Smith Predictor Generalized Predictive Control*).

A.1 Controle por Matriz Dinâmica (DMC)

O algoritmo DMC foi desenvolvido por Cutler e Ramaker [28] da companhia Shell Oil Co. e tem sido largamente empregado no mundo industrial, principalmente em indústrias petroquímicas [82]. O DMC emprega um método não paramétrico. O modelo do processo é calculado pela resposta ao degrau da planta, em geral obtida pela curva de reação do sistema, método bastante difundido na prática de controle de processos. Assim, para sua aplicação, é necessário que o processo seja estável em malha aberta. Atualmente, o DMC é mais do que um algoritmo e parte de seu sucesso se deve ao fato de seus produtos comerciais cobrirem uma série de tópicos como identificação ou otimização da planta.

A.1.1 O Algoritmo DMC

Como modelo de processo utiliza-se a resposta ao degrau do sistema, segundo a equação:

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

Para o modelo de perturbações, considera-se $q(t | t)$, valor das perturbações assumido no instante t , constante ao longo de todo o horizonte. Isto significa ser igual à saída medida ($y_m(t)$) no instante de tempo t menos o valor da saída estimado pelo modelo ($\hat{y}(t | t)$):

$$\hat{q}(t + k | t) = q(t | t) = y_m(t) - \hat{y}(t | t) \quad (\text{A.1})$$

Predição

Os valores preditos ao longo do horizonte são:

$$\begin{aligned} \hat{y}(t + k | t) &= \sum_{i=1}^{\infty} g_i \Delta u(t + k - i) + \hat{q}(t + k | t) \\ &= \sum_{i=1}^k g_i \Delta u(t + k - i) + \sum_{i=k+1}^{\infty} g_i \Delta u(t + k - i) + \hat{q}(t + k | t) \end{aligned} \quad (\text{A.2})$$

onde o primeiro termo contém as ações de controle futuras a serem calculadas, o segundo os valores passados das ações de controle e portanto conhecidos, e o último representa as perturbações. A função custo pode considerar apenas os erros futuros ou pode incluir também o esforço de controle.

Como as perturbações são consideradas constantes (A.1), pode-se reescrever a equação (A.2) como:

$$\begin{aligned} \hat{y}(t + k | t) &= \sum_{i=1}^k g_i \Delta u(t + k - i) + \sum_{i=k+1}^{\infty} g_i \Delta u(t + k - i) + y_m(t) - \sum_{i=1}^{\infty} g_i \Delta u(t - i) \\ &= \sum_{i=1}^k g_i \Delta u(t + k - i) + f(t + k) \end{aligned}$$

onde $f(t + k)$ é a resposta livre do sistema, que é a parte da resposta que não depende das ações de controle futuras e é dada por:

$$f(t + k) = y_m(t) + \sum_{i=1}^{\infty} (g_{k+i} - g_i) \Delta u(t - i)$$

Se o processo é assintoticamente estável, os coeficientes g_i da resposta ao degrau tendem a um valor constante após N períodos de amostragem, então pode-se considerar que:

$$g_{k+i} - g_i \approx 0, \quad i > 0$$

e então a resposta livre do sistema pode ser computada como:

$$f(t+k) = y_m(t) + \sum_{i=1}^N (g_{k+i} - g_i) \Delta u(t-i)$$

Note que se o processo não é estável, então N não existe e $f(t+k)$ não pode ser calculada (apesar de existir uma generalização no caso de instabilidade produzida apenas por integradores [28, 51]).

As predições podem ser calculadas ao longo do horizonte de predição ($k = 1, \dots, p$), considerando m ações de controle:

$$\begin{aligned} \hat{y}(t+1 | t) &= g_1 \Delta u(t) + f(t+1) \\ \hat{y}(t+2 | t) &= g_2 \Delta u(t) + g_1 \Delta u(t+1) + f(t+2) \\ &\vdots \\ \hat{y}(t+p | t) &= \sum_{i=p-m+1}^p g_i \Delta u(t+p-i) + f(t+p) \end{aligned}$$

que pode ser escrito na forma vetorial como:

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{f} \quad (\text{A.3})$$

onde:

$$\hat{\mathbf{y}} = \begin{bmatrix} \hat{y}(t+1 | t) \\ \hat{y}(t+2 | t) \\ \vdots \\ \hat{y}(t+p | t) \end{bmatrix} \quad \mathbf{u} = \begin{bmatrix} \Delta u(t) \\ \Delta u(t+1) \\ \vdots \\ \Delta u(t+m-1) \end{bmatrix}$$

$$\mathbf{G} = \begin{bmatrix} g_1 & 0 & \dots & 0 \\ g_2 & g_1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ g_m & g_{m-1} & \dots & g_1 \\ \vdots & \vdots & \ddots & \vdots \\ g_p & g_{p-1} & \dots & g_{p-m+1} \end{bmatrix} \quad \mathbf{f} = \begin{bmatrix} f(t+1) \\ f(t+2) \\ \vdots \\ f(t+p) \end{bmatrix}$$

A matriz \mathbf{G} é denominada **matriz dinâmica do controlador** e é construída a partir das m colunas da resposta ao degrau. O vetor $\hat{\mathbf{y}}$ de dimensão p contém as predições da saída ao longo do horizonte, \mathbf{u} representa o vetor incremento dos sinais de controle (de dimensão m) e \mathbf{f} é o vetor da resposta livre do sistema.

Se perturbações forem incluídas no modelo do sistema, pode-se obter a mesma estrutura para tratar este caso, ou seja, perturbações mensuráveis podem facilmente ser adicionadas às equações de predição. A expressão (A.3) pode ser usada para descrever as perturbações na forma:

$$\hat{\mathbf{y}}_q = \mathbf{Q}\mathbf{q} + \mathbf{f}_q$$

sendo \mathbf{Q} , a matriz dinâmica com perturbações, similar a \mathbf{G} para degrau na perturbação. O vetor $\hat{\mathbf{y}}_q$ é a contribuição da perturbação mensurável à saída do sistema; \mathbf{q} é o vetor do incremento da perturbação e \mathbf{f}_q é a parte da resposta que não depende da perturbação.

Então no caso mais geral de perturbações mensuráveis e não mensuráveis, a resposta livre completa do sistema (fração da saída que não depende da variável manipulada) pode ser considerada como a soma de quatro efeitos: a resposta à entrada $u(t)$, à perturbação $q(t)$, à perturbação não mensurável e ao estado atual do processo:

$$\mathbf{f} = \mathbf{f}_u + \mathbf{Q}\mathbf{q} + \mathbf{f}_q + \mathbf{f}_n$$

Logo, a predição pode ser calculada com a expressão geral:

$$\hat{\mathbf{y}} = \mathbf{G}\mathbf{u} + \mathbf{f} \quad (\text{A.4})$$

Cálculo da Lei de Controle

O objetivo de um controlador DMC é direcionar a saída tão próxima da referência quanto possível no sentido dos mínimos quadrados com a possibilidade da inclusão de um termo de penalização nas entradas aplicadas. Além disso, as variáveis manipuladas são selecionadas para minimizar um objetivo quadrático que pode ser considerado como a minimização dos erros futuros e do esforço de controle:

$$J = \sum_{j=1}^p [\hat{y}(t+j | t) - w(t+j)]^2 + \sum_{j=1}^m \lambda(j) [\Delta u(t+j-1)]^2 \quad (\text{A.5})$$

onde $\hat{y}(t+j | t)$ é a predição ótima da saída do sistema em um tempo j no futuro baseada na informação disponível no tempo t , $w(t+j)$ é o sinal de referência futura, $\Delta u(t)$ são os incrementos na ação de controle, p é o horizonte de predição, m é o horizonte de controle e $\lambda(j)$ é o fator de ponderação para o controle.

Cada um dos parâmetros tem um regra específica de sintonia no algoritmo DMC. Uma boa escolha para p é não ser muito maior que o tempo de acomodação da planta. De fato, o

valor recomendado para p é o tempo de subida da planta. Uma regra para λ é penalizar as ações de controle excessivas. Quanto maior o valor de λ , mais lento é o controle, suavizando-o. O horizonte m especifica os graus de liberdade na escolha dos controles futuros, ou seja, após m intervalos de amostragem futuros, os incrementos de controle são assumidos nulos, resultando num sinal de controle constante. Uma regra básica para seleção de m em plantas estáveis é setar $m = 1$, o que usualmente garante um desempenho aceitável. Note também que a escolha dos parâmetros tem influência direta sobre o tamanho das matrizes requeridas para calcular o controle ótimo, e assim no esforço computacional envolvido.

Se não há restrições, a solução da minimização da função custo $J = \mathbf{e}\mathbf{e}' + \lambda\mathbf{u}\mathbf{u}'$, onde \mathbf{e} é o vetor dos erros futuros ao longo do horizonte de predição e \mathbf{u} é o vetor formado pelos incrementos de controle $\Delta u(t), \dots, \Delta u(t+m)$, pode ser obtida analiticamente igualando o gradiente de J a zero, o que resulta no controle como:

$$\mathbf{u} = (\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T (\mathbf{w} - \mathbf{f}) \quad (\text{A.6})$$

Como em todas estratégias preditivas, o algoritmo é de horizonte deslizante, sendo apenas o primeiro sinal de controle aplicado à planta (primeiro elemento do vetor \mathbf{u}). Assim a lei de controle final é:

$$\Delta u(t) = \mathbf{K}(\mathbf{w} - \mathbf{f}) \quad (\text{A.7})$$

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

A.2 Controle Preditivo Generalizado (GPC)

O GPC é um dos controladores que tem recebido mais atenção nos últimos anos. Desde que foi proposto por Clarke et al. [23], muitos trabalhos foram escritos analisando o seu comportamento e robustez [3, 22, 24, 55, 90, 110]. Na seqüência, mostra-se como o GPC permite tratar plantas instáveis e de fase não-mínima, e consegue obter uma solução analítica para o controle, no caso de ausência de restrições no sistema.

A.2.1 O Algoritmo GPC

A idéia utilizada pelo algoritmo GPC é bastante simples: usando um modelo para prever o comportamento da planta num dado horizonte, calcula-se a ação de controle a partir da minimização de um critério que considera o erro entre a mencionada predição e a referência

assim como uma ponderação do esforço de controle. Desta forma, o sistema de controle obtido possui duas partes principais. Na primeira parte, calculam-se as previsões da saída da planta usando-se para isto um preditor ótimo que permite encontrar o valor esperado da saída, na presença de perturbações estocásticas, como função dos controles futuros. Na segunda etapa, as ponderações do erro e do esforço de controle devem ser definidas para a minimização do critério.

Predição

Para o cálculo das previsões, supõe-se que o comportamento do sistema pode ser bem representado (pelo menos nas vizinhanças do ponto de operação) por um modelo auto-regressivo do tipo CARIMA [23]:

$$A(z^{-1})y(t) = z^{-d}B(z^{-1})u(t-1) + T(z^{-1})\frac{e(t)}{C(z^{-1})\Delta} \quad (\text{A.8})$$

onde $u(t)$ e $y(t)$ são respectivamente os controles aplicados e as saídas obtidas, $e(t)$ é um ruído branco de média nula e A , B , C e D são polinômios no operador atraso z^{-1} :

$$\begin{aligned} A(z^{-1}) &= 1 + a_1z^{-1} + a_2z^{-2} + \dots + a_{na}z^{-na} \\ B(z^{-1}) &= b_0 + b_1z^{-1} + b_2z^{-2} + \dots + b_{nb}z^{-nb} \\ C(z^{-1}) &= 1 + c_1z^{-1} + c_2z^{-2} + \dots + c_{nc}z^{-nc} \\ T(z^{-1}) &= 1 + t_1z^{-1} + t_2z^{-2} + \dots + t_{nt}z^{-nt} \end{aligned}$$

Nesta representação, d é o atraso do sistema, $\Delta = 1 - z^{-1}$ e considera-se $b_0 \neq 0$. Os polinômios $C(z^{-1})$ e $T(z^{-1})$ representam as características estocásticas do ruído. Geralmente, como estes polinômios são difíceis de estimar, é comum utilizar na prática um modelo com $C(z^{-1}) = 1$ e $T(z^{-1}) = 1$ para a análise do algoritmo básico do GPC [16].

Entretanto, o polinômio $T(z^{-1})$ pode ser usado como parâmetro de projeto para melhorar a robustez do sistema [55, 61]. Neste caso, $T(z^{-1})$ não está mais relacionado com o modelo do ruído. O ajuste deste filtro $T(z^{-1})$ pode ser feito para obter o melhor compromisso entre a robustez e a rejeição de perturbação. No caso de plantas estáveis, a resposta do GPC pode ser ajustada pela inclusão de um polinômio T de primeira ordem, do tipo:

$$T(z^{-1}) = (1 - a_T z^{-1}) \quad (\text{A.9})$$

onde $0 < a_T < 1$. Como, em geral, as incertezas de alta frequência são maiores que as de baixa frequência, a regra intuitiva *aumentar o valor de a_T para aumentar a robustez* funciona

em alguns casos. Alguns trabalhos demonstram que nem sempre é possível aumentar o índice de robustez, baixando a frequência de corte do filtro (aumentando a_T) [110, 111]. No caso do GPC, isto ocorre porque a lei de controle também dependerá do polinômio $T(z^{-1})$ escolhido. Um método de ajuste do filtro de robustez no GPC, válida tanto para plantas estáveis quanto instáveis, foi proposto em [61].

Para calcular a predição da saída do sistema em um tempo $t + j$ com a informação conhecida em t , o GPC utiliza o valor esperado da variável como sendo a predição ótima [62]. Assim, a melhor predição de $y(t + j)$ em t , definida como $\hat{y}(t + j | t)$, calcula-se como:

$$\hat{y}(t + j | t) = E(y(t + j))$$

Para encontrar o valor de $\hat{y}(t + j | t)$ como função dos valores das saídas passadas e os controles, utiliza-se o modelo do sistema e a solução da seguinte equação Diofantina:

$$1 = E_j(z^{-1})\tilde{A}(z^{-1}) + z^{-j}F_j(z^{-1}) \quad \text{com } \tilde{A}(z^{-1}) = \Delta A(z^{-1}) \quad (\text{A.10})$$

Nessa igualdade, os polinômios E_j e F_j estão definidos de maneira única respeitando-se as ordens $j - 1$ e na , respectivamente. Estes polinômios podem ser obtidos de maneira muito simples dividindo o polinômio 1 pelo polinômio $\tilde{A}(z^{-1})$ até que o resto possa ser fatorizado como $z^{-j}F_j(z^{-1})$. Nesta divisão, os sucessivos quocientes são os polinômios $E_j(z^{-1})$.

Se a equação (A.8) é multiplicada por $\Delta E_j(z^{-1})z^j$

$$\begin{aligned} \tilde{A}(z^{-1})E_j(z^{-1})y(t + j) &= E_j(z^{-1})B(z^{-1})\Delta u(t + j - d - 1) \\ &\quad + E_j(z^{-1})e(t + j) \end{aligned} \quad (\text{A.11})$$

Considerando (A.10) e isolando $y(t + j)$, a equação (A.11) pode ser reescrita como:

$$y(t + j) = F_j(z^{-1})y(t) + E_j(z^{-1})B(z^{-1})\Delta u(t + j - d - 1) + E_j(z^{-1})e(t + j) \quad (\text{A.12})$$

Do segundo membro da igualdade somente os termos dependentes do ruído futuro não são conhecidos e, como o grau do polinômio $E_j(z^{-1})$ é $j - 1$, todos os termos dependentes do ruído estão no futuro. Assim, ao calcular o valor esperado da expressão (A.12), o melhor valor para $y(t + j)$ (no sentido estocástico) é aquele que considera ruído futuro nulo e portanto:

$$\hat{y}(t + j | t) = G_j(z^{-1})\Delta u(t + j - d - 1) + F_j(z^{-1})y(t)$$

onde $G_j(z^{-1}) = E_j(z^{-1})B(z^{-1})$.

Isto implica que a predição ótima pode ser calculada como uma combinação linear das saídas anteriores do processo (de t a $t - na$) e dos controles passados e futuros. Os polinômios E_j e F_j podem ser calculados recursivamente usando o procedimento da divisão de polinômios ou outros métodos [16, 23].

Cálculo da Lei de Controle

O algoritmo GPC calcula uma seqüência de controles que minimiza a função de custo:

$$J = \sum_{j=N_1}^{N_2} \delta(j) [\hat{y}(t+j|t) - w(t+j)]^2 + \sum_{j=1}^{N_u} \lambda(j) [\Delta u(t+j-1)]^2 \quad (\text{A.13})$$

onde $\hat{y}(t+j|t)$ é a predição ótima da saída do sistema, $\Delta u(t)$ são os incrementos na ação de controle e $w(t+j)$ é a referência futura. Sem perda de generalidade, considera-se o efeito do atraso d no sistema e assim os horizontes N_1 , N_2 e N_u escolhem-se como é sugerido em [15]: $N_u = N$, $N_1 = d + 1$ e $N_2 = N + d$. Para calcular o controle que minimiza J devem ser consideradas as N predições ótimas:

$$\begin{aligned} \hat{y}(t+d+1|t) &= G_{d+1} \Delta u(t) + F_{d+1}y(t) \\ \hat{y}(t+d+2|t) &= G_{d+2} \Delta u(t+1) + F_{d+2}y(t) \\ &\vdots \\ \hat{y}(t+d+N|t) &= G_{d+N} \Delta u(t+N-1) + F_{d+N}y(t) \end{aligned}$$

que pode ser escrito na forma vetorial como:

$$\mathbf{y} = \mathbf{G}\mathbf{u} + \mathbf{F}(z^{-1})y(t) + \mathbf{G}'(z^{-1}) \Delta u(t-1) \quad (\text{A.14})$$

Observa-se que os dois últimos termos somente dependem do passado e podem ser agrupados num único vetor que é definido como a resposta livre do sistema \mathbf{f} , o que permite escrever:

$$\mathbf{y} = \mathbf{G}\mathbf{u} + \mathbf{f}$$

Para calcular o mínimo de J , é conveniente escrever a expressão (A.13) como:

$$J = (\mathbf{G}\mathbf{u} + \mathbf{f} - \mathbf{w})^T (\mathbf{G}\mathbf{u} + \mathbf{f} - \mathbf{w}) + \lambda \mathbf{u}^T \mathbf{u} \quad (\text{A.15})$$

onde supõe-se que $\delta(j) = 1$ e $\lambda(j) = \lambda$ constantes. Esta escolha é a mais simples e usada; porém, se as ponderações não são constantes no horizonte, J escreve-se como:

$$J = (\mathbf{G}\mathbf{u} + \mathbf{f} - \mathbf{w})^T Q_\delta (\mathbf{G}\mathbf{u} + \mathbf{f} - \mathbf{w}) + \mathbf{u}^T Q_\lambda \mathbf{u} \quad (\text{A.16})$$

onde Q_λ e Q_δ são matrizes diagonais com os valores das ponderações na diagonal e \mathbf{w} é o vetor do sinal de referência dado por:

$$\mathbf{w} = \begin{bmatrix} w(t+d+1) & w(t+d+2) & \cdots & w(t+d+N) \end{bmatrix}^T$$

A equação (A.15) pode ser escrita como uma forma quadrática:

$$J = \frac{1}{2} \mathbf{u}^T \mathbf{H} \mathbf{u} + \mathbf{b}' \mathbf{u} + \mathbf{f}_0 \quad (\text{A.17})$$

onde:

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

O mínimo de J pode ser calculado, quando não há restrições, igualando o gradiente de J a zero. O controle para isto calcula-se como:

$$\mathbf{u} = -\mathbf{H}^{-1} \mathbf{b} = (\mathbf{G}^T \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}^T (\mathbf{w} - \mathbf{f}) \quad (\text{A.18})$$

Como o algoritmo é de horizonte deslizante, unicamente o primeiro sinal de controle é aplicado (primeiro elemento do vetor \mathbf{u}), assim a lei de controle final é:

$$\Delta u(t) = \mathbf{K}(\mathbf{w} - \mathbf{f}) \quad (\text{A.19})$$

onde \mathbf{K} é a primeira linha da matriz $(\mathbf{G}' \mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{G}'$. Quando as ponderações não são constantes, \mathbf{K} será a primeira linha da matriz $(\mathbf{G}' Q_\delta \mathbf{G} + \mathbf{Q}_\lambda)^{-1} \mathbf{G}' Q_\delta$.

É importante notar que somente o primeiro elemento do vetor \mathbf{u} é aplicado no instante t e que o procedimento de cálculo é repetido a cada período de amostragem. Desta forma, caso os parâmetros do processo ou do controle variem, o cálculo do controle envolverá uma inversão ou triangularização de uma matriz $N \times N$, o que requer uma carga de cálculo considerável. Para reduzir o tempo de cálculo, diversas soluções têm sido propostas, como: (a) utilizar um valor de horizonte de controle menor que N [23] ou (b) utilizar um pré-cálculo dos parâmetros da lei de controle em função do modelo do processo e do ajuste escolhido [16].

A.3 GPC Baseado no Preditor de Smith (SPGPC)

O SPGPC é um algoritmo de controle preditivo proposto por Normey-Rico [61, 70], baseado no GPC e no preditor de Smith. O SPGPC apresenta algumas propriedades que o

tornam mais atrativo que o GPC tradicional, no controle de processos estáveis. Entre elas: (i) possui as características do GPC no que se refere ao comportamento nominal; (ii) oferece melhores índices de robustez do que o GPC; (iii) o projeto de filtros para melhorar a robustez é mais simples. Por outro lado, o SPGPC pode ser analisado como um compensador de atraso, cujo controlador primário é ajustado de maneira ótima, considerando as restrições das variáveis do sistema. Assim, o SPGPC reúne as vantagens do GPC e do preditor de Smith.

A.3.1 O Algoritmo SPGPC

Predição

As predições da saída da planta são calculadas utilizando o mesmo procedimento usado pelo SP:

- calcula-se a predição $\hat{y}_o(t + d - i | t)$, usando o modelo da planta em malha aberta, sem considerar as perturbações: $A(z^{-1})y(t) = z^{-d}B(z^{-1})u(t - 1)$;
- corrige-se cada predição de malha aberta, somando a diferença entre a saída do modelo e a real do processo:

$$\hat{y}(t + d - i | t) = \hat{y}_o(t + d - i | t) + y(t - i) - \hat{y}_o(t - i). \quad (\text{A.20})$$

Cálculo da Lei de Controle

O algoritmo SPGPC utiliza, como o GPC, uma seqüência de controle que minimiza a mesma função objetivo do GPC:

$$J = \sum_{j=N_1}^{N_2} \delta(j)[\hat{y}(t + j | t) - w(t + j)]^2 + \sum_{j=1}^{N_u} \lambda(j)[\Delta u(t + j - 1)]^2, \quad (\text{A.21})$$

onde N_u é o horizonte de controle, N_1 e N_2 são os horizontes de predição (em geral, $N_1 = d + 1$ e $N_2 = d + N$, escolhidos como no GPC), $\delta(j)$ e $\lambda(j)$ são as seqüências de ponderação, $w(t + j)$ é a referência futura e $\hat{y}(t + j | t)$ é a predição em $t + j$ calculada no tempo t usando um modelo incremental da planta, representado pelos polinômios $A(z^{-1})$ e $B(z^{-1})$:

$$\Delta A(z^{-1})y(t) = z^{-d}B(z^{-1}) \Delta u(t - 1), \quad (\text{A.22})$$

considerando conhecidas as predições da saída até $t + d$.

Da mesma forma que no GPC, a lei de controle pode ser calculada com a resposta livre e a forçada. Neste caso, considera-se que:

$$\hat{\mathbf{y}} = \mathbf{G} \mathbf{u} + \mathbf{f}_r \quad (\text{A.23})$$

A resposta livre (\mathbf{f}_r) é calculada de $t + 1$ a $t + d$, usando a resposta em malha aberta e a correção:

$$\begin{bmatrix} y(t) - \hat{y}_o(t) \\ y(t-1) - \hat{y}_o(t-1) \\ \vdots \\ y(t+1-na) - \hat{y}_o(t+1-na) \end{bmatrix} \quad (\text{A.24})$$

e de $t + d + 1$ a $t + d + N$, usando o procedimento normal do GPC com polinômio $T(z) = 1$.

Assim, a lei de controle é:

$$\Delta u(t) = (\mathbf{G}'\mathbf{Q}_\delta\mathbf{G} + \mathbf{Q}_\lambda)^{-1}\mathbf{G}'\mathbf{Q}_\delta(\mathbf{f}_r - \mathbf{w}) \quad (\text{A.25})$$

onde $\mathbf{w} = [w(t+d+1) \cdots w(t+d+N)]'$ é a referência futura.

Deve-se destacar que o SPGPC utiliza dois modelos na implementação da lei de controle, diferentemente dos outros algoritmos MPC. Os coeficientes da lei de controle se calculam com um modelo incremental e um preditor ótimo. Mas os valores de predição usam a estrutura baseada no SP, isto é, utilizam um modelo que não é ótimo nem incremental.

Para melhorar a robustez do sistema, é possível incluir um filtro de robustez F , à saída do sistema, na estrutura do controlador. Este filtro pode ser usado para aumentar o valor do índice de robustez do SPGPC. Observa-se que: (i) o comportamento nominal a mudanças de referência não se modifica pela inclusão do filtro F ; (ii) o filtro permite modificar a rejeição de perturbações, como no GPC. Como, em geral, as incertezas paramétricas da planta são mais importantes a altas frequências, uma possibilidade é escolher F como um filtro passa-baixas do tipo:

$$F(z) = \left(\frac{1-a}{1-az^{-1}} \right), \quad a > 0$$

com a finalidade de obter um comportamento mais robusto da planta em malha fechada. O parâmetro a do filtro deve ser selecionado seguindo regras de ajuste apresentadas em [61], de maneira a manter o índice de robustez sempre maior que o módulo das incertezas da planta.

Tabela A.1: Tabela comparativa entre algoritmos MPC.

Algoritmo	DMC (Cutler & Ramaker, 1980)	GPC (Clarke et al., 1987)	SPGPC (Normey-Rico, 1999)
Origem	meio industrial	meio acadêmico	meio acadêmico
Modelo	Resposta ao Degrau (não paramétrico)	Função de Transferência (paramétrico)	Função de Transferência (paramétrico)
Predição	$\hat{y} = \sum_{i=1}^N g_i u(t+k-i t)$	$\hat{y} = \frac{B(z^{-1})}{A(z^{-1})} u(t+k t)$	$\hat{y}_o = \frac{B(z^{-1})}{A(z^{-1})} u(t+k t)$
Vantagens	- simples e intuitivo - descreve bem atrasos	- válido para todo processo - poucos parâmetros	- bom comportamento nominal - maior robustez que GPC
Desvantagens	- não-aplicável a plantas instáveis - horizonte N grande	- problemas na identificação do modelo do processo	- aplicável a plantas estáveis (devido ao SP)

Apêndice B

Planta Piloto

B.1 Descrição da Planta

Como banco de provas de novas estratégias de controle, o Departamento de Engenharia de Sistemas e Automática da *Escuela Superior de Ingenieros* (ESI) da Universidade de Sevilha (Espanha), dispõe de uma planta piloto para controle e instrumentação industrial. Esta planta, mostrada na figura B.1, consiste basicamente de um sistema que utiliza a água como fluido de trabalho, no qual se podem realizar diversos processos termodinâmicos através de intercâmbios de massa e energia. Essencialmente, a planta piloto consiste em um depósito com aquecimento interno através de uma série de tubos de entrada e saída, além de um circuito de recirculação com um trocador de calor.

O esquema da planta, mostrando seus principais elementos e instrumentação, pode ser visualizado na figura B.2. A planta permite o ensaio de diversas estratégias de controle, pois pode-se controlar temperatura, fluxo, pressão ou nível por intermédio da escolha de sua configuração. Para tanto, dispõe de quatro atuadores: três válvulas automáticas e uma resistência elétrica que esquenta o interior de um tanque. A planta consta de um circuito de alimentação com duas bombas de entrada, uma de água quente e outra de água fria, com válvulas motorizadas para a regulação dos fluxos de entrada, e de um tanque encapsulado com uma resistência de 15 kW para o aquecimento. A água quente do tanque pode ser resfriada através do circuito de resfriamento, composto de uma bomba centrífuga que retira a água quente da base do depósito, recircula-a por um trocador de calor, devolvendo água a uma temperatura mais baixa ao topo do tanque.



Figura B.1: Planta piloto de processos térmicos (cortesia da ESI-US).

Os principais elementos que formam a planta são:

- Circuito de alimentação. A planta dispõe de dois tubos de entrada, um de água fria (à temperatura ambiente) e outro de água quente (aproximadamente 70°C) em condições nominais de fluxo e pressão de 10 l/min e 2 bar para a água fria e 5 l/min e 1 bar para a quente. As temperaturas e os fluxos de entradas são medidos por termopares e placas-orifício, respectivamente, dispondo de válvulas para a regulação dos fluxos de entrada.
- Depósito. É um tanque de 1 metro de altura e 20 centímetros de diâmetro interior, isolado termicamente, com volume aproximado de 31 litros. Pode trabalhar pressurizado (até o limite de 4 bar) ou a pressão atmosférica, segundo a posição de uma válvula. Dispõe em seu interior de uma resistência elétrica de 15 kW para aquecimento, assim como de um escape (ladrão), um tubo de saída e outro de recirculação de água através

de um trocador de calor.

- Circuito de recirculação. A água quente do tanque pode ser resfriada com a entrada de água fria, através do circuito de refrigeração. Este circuito consta de uma bomba centrífuga que faz circular a água quente da parte inferior do depósito por um trocador de calor de seção tubular e retornar à menor temperatura até a parte superior do mesmo.

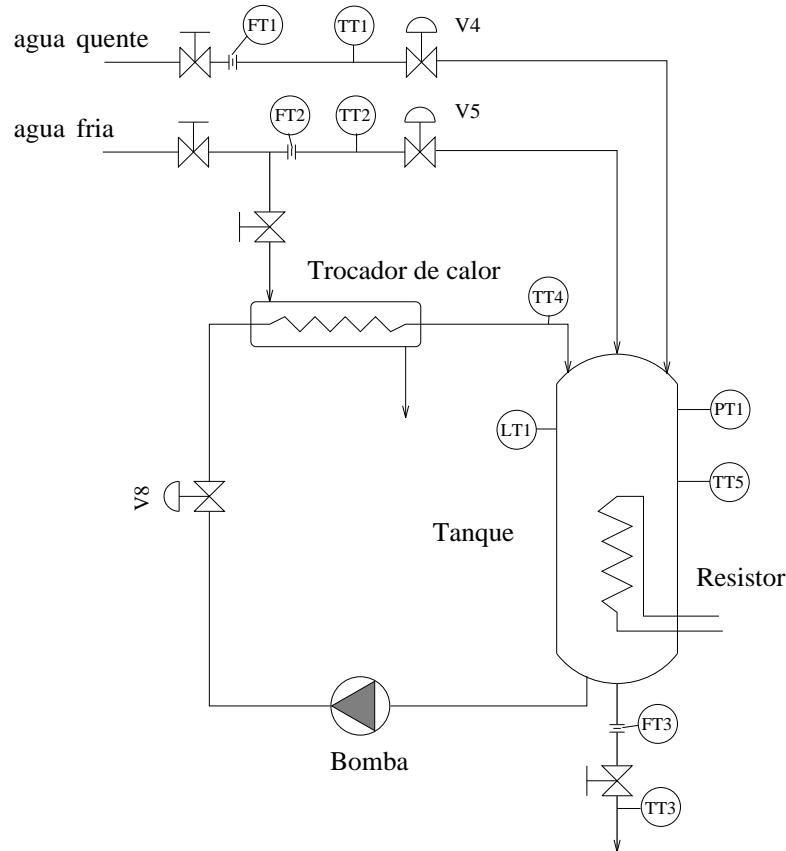


Figura B.2: Esquema geral da planta piloto (cortesia do DISA-US).

Para o controle da instalação, dispõe-se de um sistema de controle distribuído INTEGRAL CUBE de ORSI AUTOMAZIONE, formado por um controlador e um supervisor conectados por uma rede local (LAN) de alta velocidade, conforme o esquema representado na figura B.3. Estes módulos são constituídos pelo *software* implementado em Visual C++ para dar suporte ao controlador MPC, um SCADA usado para resolver os requerimentos relacionados ao processamento de dados e à automação de baixo nível, e finalmente um controlador lógico programável (PLC), onde é executado o *software* programado para o SCADA e gerenciada a conexão com a planta real. O núcleo desse sistema de controle é uma base em tempo real, que centraliza os dados obtidos dos diferentes sensores de campo em uma estrutura de simples acesso.

Este sistema de controle constitui um exemplo típico de controlador industrial, possuindo características usuais de sistemas de médio porte existentes no mercado.




Figura B.3: Estrutura do controle.

B.2 Identificação do Modelo

Dentro do esquema da planta, pode-se considerar o trocador de calor como um processo independente. O trocador faz diminuir a temperatura da água de recirculação, impulsionada pela bomba, usando um fluxo constante de água fria. Para controlar a temperatura de saída da água do trocador de calor (TT4), utiliza-se a variação do fluxo da água de recirculação através da válvula v8; assim, a temperatura desejada é obtida pelas variações no fluxo. O trocador não é mais do que um conjunto de tubos por onde circula água quente que fornece calor à água fria exterior. Por isso, pode ser considerado como formado por um grande número de elementos de primeira ordem com atraso. Portanto, pode-se aproximar o sistema TT4-v8 por um sistema de primeira ordem com atraso puro, cuja função de transferência é descrita por:

$$P_n(s) = \frac{K}{1 + \tau s} e^{-\tau_d s} \quad (\text{B.1})$$

Para identificar os parâmetros do processo, utilizou-se a curva de reação do sistema, trabalhando nas proximidades de 35°C e assumindo que o processo é de primeira ordem com atraso. Os ensaios experimentais realizaram-se em malha aberta, através da variação na abertura da válvula v8, observando a evolução de TT4. Pelos ensaios experimentais, é possível notar que existem incertezas nos valores dos parâmetros da planta: o ganho K pode variar entre 0.08 e 0.15, a constante de tempo τ pode variar entre 5.7 e 6.3 segundos. O atraso do sistema τ_d depende da localização do sensor, tendo sido estimado entre 12 e 16 segundos. O tempo de amostragem foi escolhido como sendo de $T = 1\text{ s}$.

Apêndice C

Planta Solar de Climatização

C.1 Descrição da Planta

A instalação solar de refrigeração pertencente ao Departamento de Engenharia de Sistemas e Automática da *Escuela Superior de Ingenieros* (ESI) da Universidade de Sevilla (Espanha), vista na figura C.1, consta de uma máquina de absorção com uma potência frigorífica nominal de 35kW, junto com um sistema de obtenção de energia térmica necessária para o funcionamento do ciclo de absorção e um sistema de retirada de calor.




Figura C.1: Instalação solar de refrigeração (cortesia da ESI-US).

A possibilidade de empregar energia solar em refrigeração e ar condicionado sempre atraiu a atenção desde os princípios do desenvolvimento da tecnologia solar. A necessidade de ar condicionado para conforto térmico em zonas quentes do mundo e a abundância de sol nestas áreas permite combinar ambas circunstâncias para benefício da sociedade. Uma das aplicações mais claras da energia solar é a produção de frio, pela razão óbvia de que se necessita de refrigeração quando faz mais calor, ou seja, quando existe maior radiação solar incidente. O resfriamento utilizando a energia solar é preciso quando a radiação solar se encontra em seu ponto mais elevado, o que torna seu emprego mais atrativo [31]. Também se deve salientar a repercussão favorável para o meio ambiente ao utilizar energia solar para produzir frio, com a conseqüente redução do impacto ambiental na escolha deste tipo de sistema.

Entre as diversas aplicações térmicas da energia solar, a refrigeração é uma das mais complexas, tanto em conceito como na sua concretização prática. Esta é uma das razões para que sua utilização ainda não esteja tão difundida como é o caso da calefação de ambientes. Um dos procedimentos para conseguir o frio desejado a partir da energia solar é mediante o uso de máquinas de absorção de calor que produzem o frio consumindo o calor aplicado a seu gerador. Este calor pode ser obtido de muitas maneiras e uma delas é a partir da radiação solar.

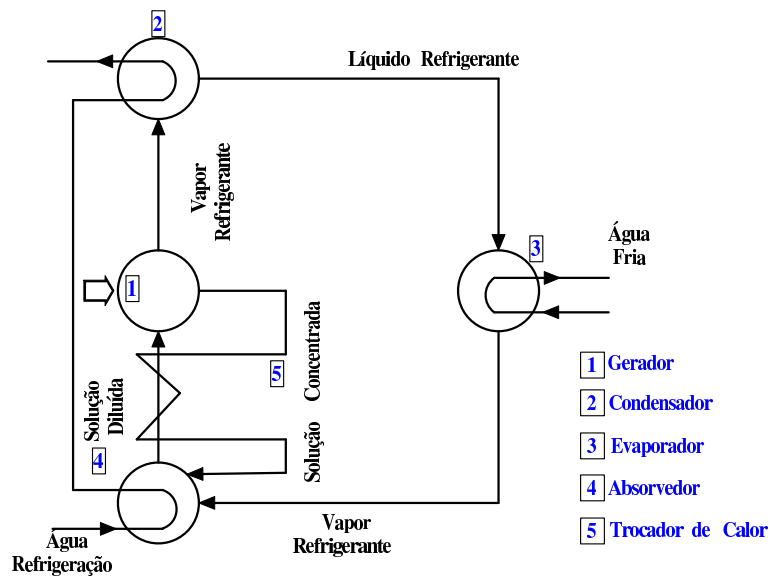


Figura C.2: Esquema de funcionamento da máquina de absorção.

O funcionamento da máquina de absorção emprega dois fluidos de trabalho: um refrigerante (água) e um absorvente, no caso composto por uma solução aquosa de brometo de lítio (Li-Br). O ciclo frigorífico por absorção pode ser descrito por quatro fases: geração, condensação, evaporação e absorção, conforme mostra a figura C.2. Na fase de geração, a solução diluída de Li-Br é aquecida e levada à ebulição, produzindo vapor refrigerante e solução ab-

sorvente concentrada. Na condensação, o vapor refrigerante se condensa com transferência do calor latente da condensação. Na fase da evaporação, o fluido refrigerante, produzido em estado líquido na fase anterior, entra no evaporador onde, como consequência da baixa pressão existente, evapora imediatamente extraindo da água fria circundante nas serpentinas do evaporador uma quantidade de calor equivalente ao calor latente de evaporação. Na absorção, a solução concentrada produzida na primeira fase, absorve o vapor que provém do evaporador, baixando a pressão do vapor ambiente: o calor latente da condensação é cedido à água de resfriamento que circula pelas serpentinas. A solução diluída que sai do absorvedor e a solução concentrada obtida no gerador apresentam respectivamente temperatura baixa e alta. O ciclo de refrigeração acontece pela repetição cíclica destas quatro fases. Para seu adequado funcionamento, a máquina requer que a temperatura de entrada do gerador esteja compreendida entre 75 e 100°C durante a produção de frio.

A fonte de calor do sistema é formada por um conjunto de painéis solares térmicos que transformam a energia incidente em forma de radiação solar em energia interna do fluido portador de calor que, neste caso, é a água. O fluido é aquecido através dos painéis solares a uma temperatura superior à ambiente e será a fonte de energia para o sistema de refrigeração. Este fluido é armazenado nos tanques de acumulação, para que possa ser empregado quando não exista radiação solar. Em condições normais, a energia térmica fornecida pelo sistema de captação é de 50kW. Como complemento ao sistema de painéis, existe um sistema de energia auxiliar constituído por uma caldeira de gás natural de 60 kW de potência nominal, utilizada no caso da absorção de radiação solar não ser suficiente. A energia dissipada pelo sistema de refrigeração por absorção é eliminada mediante uma torre de refrigeração. A demanda de energia térmica pode vir de duas fontes: a climatização de um andar do edifício de laboratórios da *Escuela Superior de Ingenieros* (ESI, Universidade de Sevilha) ou um sistema simulador de cargas que permite realizar ensaios com qualquer tipo de carga.

A figura C.3 representa o esquema da planta solar de refrigeração. Na figura, pode-se observar os diferentes componentes da planta, entre eles: 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 o abastecimento solar não é o bastante; a máquina de absorção encarregada da produção de frio; além de um simulador de carga, composto por um intercambiador e uma bomba de calor que permitem a realização de ensaios.

O simulador da planta solar de refrigeração se baseia no modelo obtido por Delgado e Bordons [31], descrito com base em equações de balanço de energia. Este modelo foi posteriormente modificado e validado com dados de funcionamento reais da planta solar para diferentes condições de operação. A continuação, se descreve brevemente os principais elementos da planta solar.

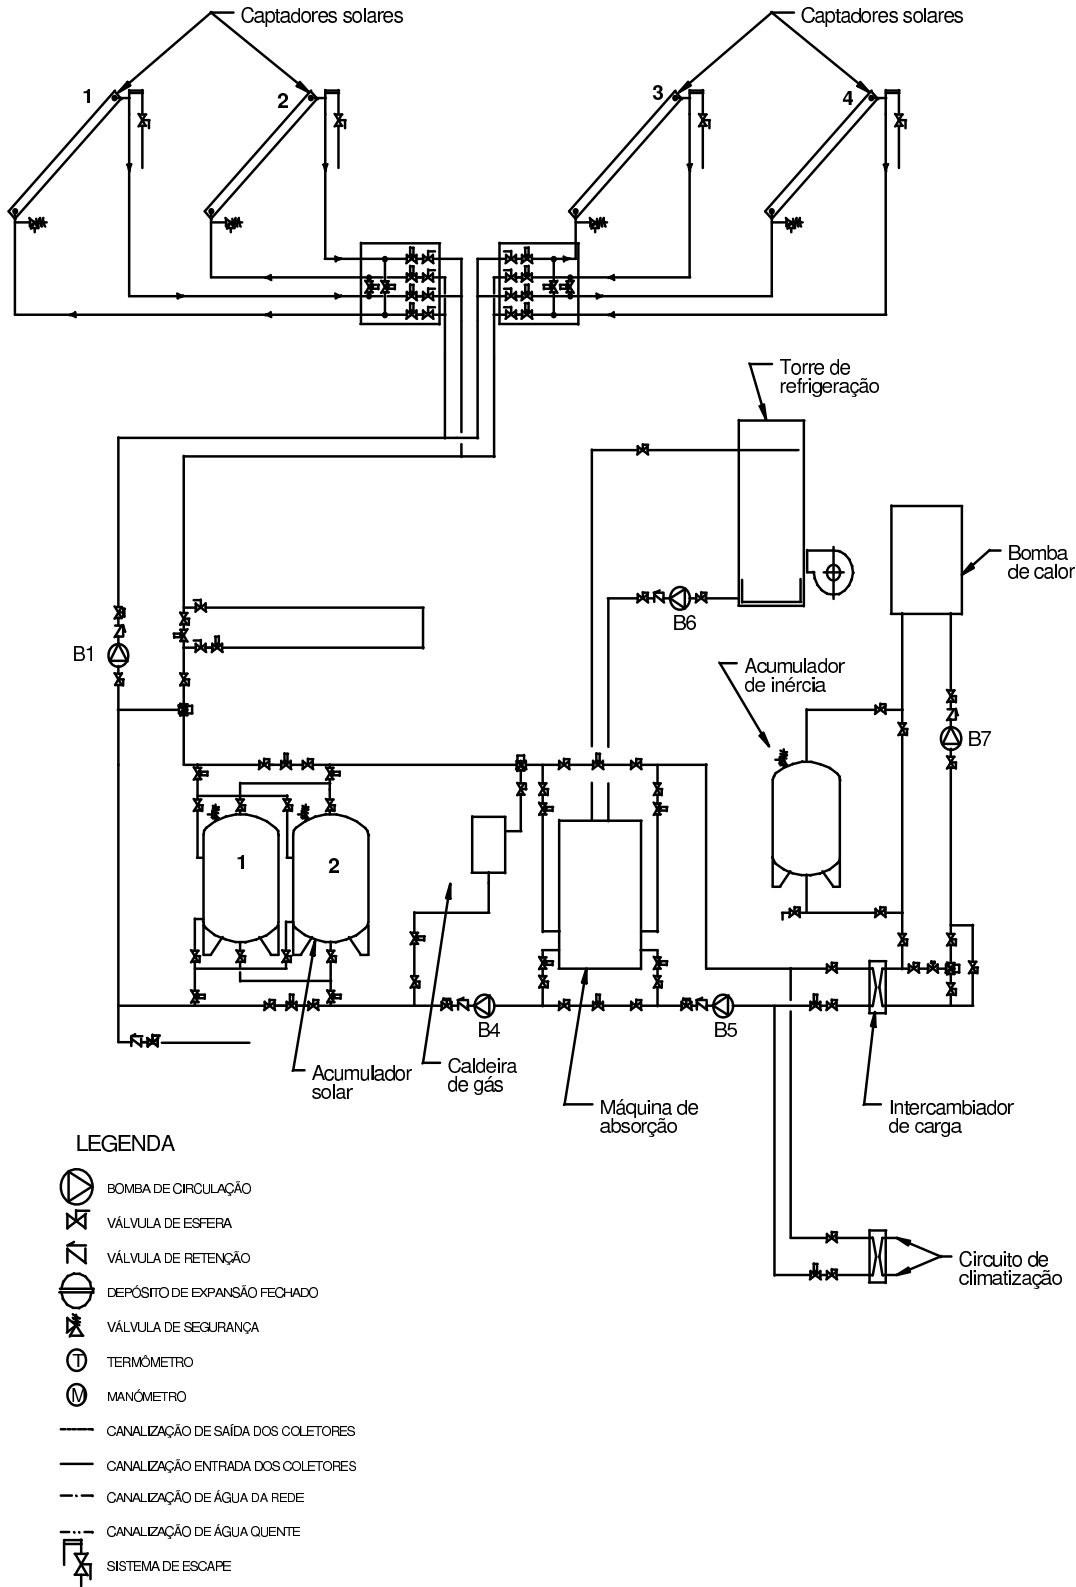


Figura C.3: Esquema da planta solar de climatização (cortesia do DISA-US).

Sistema de Captação Solar

Um painel solar é um intercambiador de calor capaz de utilizar a radiação solar para aumentar a energia interna de um fluido de trabalho. O painel solar apresenta uma superfície plana direcionada à radiação incidente. Abaixo desta superfície, situa-se uma canalização pela qual circula o fluido portador de calor. A energia incidente acaba por ser parcialmente absorvida pela superfície captadora, aumentando a temperatura da mesma e, por consequência, a do fluido que circula pela canalização.

A equação que representa o modelo transitório é obtida mediante um balanço de energia e está dada por:

$$C_A \frac{dT_m}{dt} = F \cdot [I_G - U \cdot (T_m - T_{amb})] - \frac{2 \cdot \dot{m} \cdot C_p}{A_C} \cdot (T_m - T_e)$$

onde T_m é a temperatura média do fluido no painel ($^{\circ}C$), T_e é a temperatura de entrada do fluido no painel ($^{\circ}C$), T_{amb} a temperatura ambiente ($^{\circ}C$), \dot{m} é o fluxo do fluido no painel ($\frac{Kg}{s}$), C_A é a capacidade térmica do painel solar ($\frac{J}{m^2 \cdot ^{\circ}C}$), U o coeficiente de perdas ao ambiente ($\frac{W}{m^2 \cdot ^{\circ}C}$), I_G a irradiação sobre a superfície do coletor ($\frac{W}{m^2}$), A_C área do painel solar (m^2), C_p o calor específico do fluido ($\frac{J}{Kg \cdot ^{\circ}C}$) e F o fator de eficiência.

A temperatura de saída do coletor, T_s , se obtém assumindo que a distribuição da temperatura é linear e está dada por: $T_m = \frac{T_e + T_s}{2}$.

Sistema Auxiliar de Energia

Os sistemas de climatização solar precisam de um sistema auxiliar de aporte de energia que supra as carências energéticas do sistema de captação solar, devido a condições ambientais adversas que impeçam de obter um nível térmico suficiente para seu funcionamento. Nesta planta utiliza-se uma caldeira de gás natural.

As principais funções da caldeira são a de converter energia química presente no combustível em energia térmica mediante um processo de combustão, e a de transferir esta energia térmica ao fluido de trabalho.

O modo de controlar o fornecimento de potência é um controle ON/OFF. Consiste em um sinal de realimentação de um queimador por meio de um termostato, que mantém a temperatura do fluido aproximadamente constante à saída da caldeira.

As equações que descrevem o comportamento da caldeira analisam a evolução de duas

temperaturas, a temperatura de saída dos gases procedentes da combustão (T_{ch}), e a temperatura de exaustão da água na caldeira (T_{ex}), e são as seguintes:

$$C_g \frac{dT_{ch}}{dt} = U_{ge} \cdot (T_{amb} - T_{ch}) + U_{ga} \cdot (T_{ex} - T_{ch}) + \dot{Q}_b$$

$$C_a \frac{dT_{ex}}{dt} = U_{ae} \cdot (T_{amb} - T_{ex}) + U_{ga} \cdot (T_{ch} - T_{ex}) + \dot{m} C_p \cdot (T_{ent} - T_{ex})$$

onde T_{amb} é a temperatura ambiente ($^{\circ}C$), T_{ent} a temperatura de entrada da água na caldeira ($^{\circ}C$), C_a capacidade térmica da água ($\frac{J}{^{\circ}C}$), C_g capacidade térmica dos gases de combustão ($\frac{J}{^{\circ}C}$), C_p calor específico da água ($\frac{J}{Kg \cdot ^{\circ}C}$), U_{ge} coeficiente de transferência de calor entre os gases e o ambiente ($\frac{W}{^{\circ}C}$), U_{ae} coeficiente de transferência de calor entre a água e o ambiente ($\frac{W}{^{\circ}C}$), U_{ga} coeficiente de transferência de calor entre os gases e a água ($\frac{W}{^{\circ}C}$), \dot{m} fluxo de gás natural ($\frac{Kg}{s}$) e \dot{Q}_b potência do queimador (W).

A regulação do ciclo de funcionamento da caldeira é realizada pela injeção de gás, que acompanha uma curva de histerese térmica. Se a temperatura de exaustão da água supera uma determinada referência ($90^{\circ}C$), o fluxo de água é cortado e a temperatura começa a diminuir. Uma vez que a temperatura esteja abaixo desta referência, a caldeira volta a operar.

Sistema de Acumulação

Sua função é armazenar o fluido portador de calor à temperatura adequada para seu posterior consumo. É conveniente que esteja bem isolado para que a água acumulada esfrie o menos possível. Está composto por dois depósitos de 2500l cada um, que trabalham em paralelo. Para o modelo, foi considerado como se houvesse apenas um acumulador, composto por depósitos estratificados. O modelo foi realizado com 12 estratos, sendo 2 deles de volume distinto aos demais (V_1), correspondente as partes superior e inferior do depósito. Os outros estratos representam a região cilíndrica central, com um volume V_2 .

Para $i = 1$:

$$C_p V_1 \rho \frac{dT_1}{dt} = \dot{m}_L C_p \cdot (T_2 - T_1) + U \cdot A_1 \cdot (T_{amb} - T_1)$$

Para $i = 2, 3, 4, 9, 10, 11$:

$$C_p V_2 \rho \frac{dT_i}{dt} = \dot{m}_L C_p \cdot (T_{i+1} - T_i) + U \cdot A_2 \cdot (T_{amb} - T_i)$$

Para $i = 5$:

$$C_p V_2 \rho \frac{dT_5}{dt} = \dot{m}_h C_p \cdot (T_h - T_5) + \dot{m}_L C_p \cdot (T_6 - T_5) + U \cdot A_2 \cdot (T_{amb} - T_5)$$

Para $i = 6, 7, 8$:

$$C_p V_2 \rho \frac{dT_i}{dt} = \dot{m}_h C_p \cdot (T_{i-1} - T_i) + \dot{m}_L C_p \cdot (T_{i+1} - T_i) + U \cdot A_2 \cdot (T_{amb} - T_i)$$

Para $i = 12$:

$$C_p V_1 \rho \frac{dT_{12}}{dt} = \dot{m}_L C_p \cdot (T_L - T_{12}) + U \cdot A_1 \cdot (T_{amb} - T_{12})$$

onde U é o coeficiente de perdas por unidade de superfície de depósito ($\frac{W}{m^2 \cdot ^\circ C}$), $A_{1,2}$ são as superfícies do volume de controle em contato com o ambiente (m^2); $V_{1,2}$ volumes dos estratos (m^3); $\dot{m}_{L,h}$ fluxo de água vindo, respectivamente, da carga e do sistema de captação solar ($\frac{Kg}{s}$); $T_{L,h}$ temperatura da água vinda da carga e dos painéis ($^\circ C$); T_{amb} temperatura ambiente ($^\circ C$), ρ densidade da água ($\frac{Kg}{m^3}$); C_p calor específico da água ($\frac{J}{Kg \cdot ^\circ C}$).

Sistema de Refrigeração

A máquina de absorção possui quatro circuitos, relacionados às fases onde se realizam os intercâmbios de energia para a produção do frio. As variáveis críticas que influenciam no funcionamento da máquina são:

- Temperatura do condensador, que fixa a pressão existente no condensador e no gerador;
- Temperatura do evaporador, cuja a qual fixa a pressão no evaporador e absorvedor;
- Temperatura do gerador, que aliada à pressão do condensador fixa a concentração da solução que sai do gerador;
- Temperatura do absorvedor, que junto à pressão do evaporador fixa a concentração da solução que entra no gerador.

Todos os circuitos têm como fluido portador de calor a água, que sofre uma evolução de sua temperatura como função da quantidade de energia intercambiada. A equação que

modela o comportamento da temperatura da água em cada circuito é análoga para todos, com a seguinte forma:

$$(M \cdot C_p) \frac{d(T)}{dt} = \dot{m} \cdot C_p \cdot (T_e - T) + UA \cdot (T_{amb} - T) + \dot{Q}$$

onde M representa a quantidade de água armazenada no volume de controle (Kg), \dot{m} é o fluxo de água ($\frac{Kg}{s}$), C_p é o calor específico da água ($\frac{J}{Kg \cdot ^\circ C}$), T a temperatura no volume de controle ($^\circ C$), T_e a de entrada ($^\circ C$), T_{amb} a temperatura ambiente ($^\circ C$), UA é o coeficiente de perda de calor ($\frac{W}{^\circ C}$), \dot{Q} é a energia intercambiada por cada circuito (W), seja ele o evaporador, o gerador, o condensador ou o absorvedor.

C.2 Identificação do Modelo

Assim como ocorre em muitos processos industriais quando considerando pequenas mudanças em torno de um ponto de operação, a planta solar pode ser descrita por um modelo linear, composto por uma função de transferência de primeira ordem e um atraso, obtido através do método de identificação por resposta ao degrau, conforme relatado em [10]. Os dados utilizados para a identificação das variáveis foram obtidos experimentalmente da planta solar real. Estes dados reais foram tratados (amostrados a cada 4 segundos e posteriormente normalizados) para a obtenção de um modelo aceitável. As variáveis de entrada e as perturbações mensuráveis foram excitadas com diferentes degraus, com o objetivo de identificar o sistema real. Os parâmetros do modelo do sistema foram determinados não só pelo método da curva de reação, mas também pela estimação por mínimos quadrados recursivos.

A função de transferência do processo pode ser vista na equação (C.1), onde a variável controlada $y(z)$ é a temperatura de entrada da máquina de absorção, a variável manipulada $u(z)$ corresponde a abertura da válvula de três vias VM3, e as perturbações mensuráveis $q_1(z)$ and $q_2(z)$ são respectivamente a temperatura de saída dos tanques de acumulação e a temperatura de saída da caldeira. Estas perturbações têm grande influência no desempenho, porque estão relacionadas a quantidade de energia armazenada no sistema. Estas medidas causarão efeitos na tomada de decisões do controle da planta.

$$y(z) = G_u(z)u(z) + [G_{q_1}(z) G_{q_2}(z)] \mathbf{q}(z) \quad (C.1)$$

Como o algoritmo de controle preditivo permite utilizar o conhecimento das perturbações mensuráveis nas equações de predição, tratando-as simplesmente como entradas do sistema, a identificação do modelo foi realizado como um modelo multivariável de três entradas e

uma saída. As funções de transferência $G_u(z)$, $G_{q_1}(z)$ e $G_{q_2}(z)$ foram transformadas nas matrizes polinomiais A , B para o processo e B_q para as perturbações, calculadas mediante o pacote de identificação do MATLAB, considerando um tempo de amostragem de $T_a = 4s$, são dadas por:

$$\begin{aligned} A &= [1.0000 \quad -1.7055 \quad 0.9625 \quad -0.3638 \quad 0.1243] \\ B &= [0.0000 \quad -0.0665 \quad 0.0959 \quad -0.0328] \\ B_q &= [0.0000 \quad 0.0000 \quad -0.0227 \quad 0.0298 \dots \\ &\quad 0.1940 \quad -0.2575 \quad 0.0686 \quad 0.0000] \end{aligned}$$

Na figura C.4 se apresentam os sinais reais obtidos nos ensaios com a planta real para a abertura da válvula de três vias VM3 e das perturbações de temperatura de tanques de acumulação e de caldeira. A figura C.5 compara o sinal da saída simulada pelo modelo (traço fino) com a saída real (traço de maior espessura) da temperatura de entrada da máquina de absorção. O erro de modelagem foi calculado, utilizando o índice ISE dado pela integral do erro quadrático, como sendo 1.3115.




Figura C.4: Sinais reais. Entrada e perturbações.




Figura C.5: Identificação do modelo.

Apêndice D

Planta de Extração de Azeite de Oliva

D.1 Descrição da Planta

A elaboração do azeite de oliva virgem é obtida pela extração do óleo a partir das azeitonas por meios puramente mecânicos, sem reações químicas. O controle automático da extração de azeite nas indústrias da Espanha é ainda um campo aberto, já que a maior parte das instalações são operadas no modo manual. Todas as operações são realizadas com a finalidade de extrair a maior quantidade de azeite da matéria-prima sem perdas de qualidade. O processo é composto de diversas fases: recepção da matéria-prima (azeitonas), limpeza e armazenagem, preparação, extração do óleo e estocagem do azeite produzido [20]. A figura D.1 mostra as mais importantes etapas do processo.

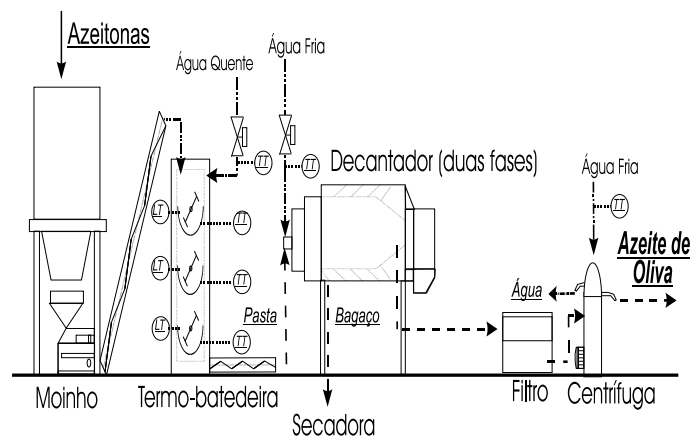


Figura D.1: Esquema da planta de extração de azeite de oliva.

A etapa de recepção da matéria-prima apresenta aspectos que afetam notavelmente a qualidade do produto final, como por exemplo a separação dos frutos que produzem um azeite de maior qualidade (azeitonas boas, colhidas na árvore) dos frutos que produzirão um azeite de pior qualidade (azeitonas recolhidas do solo ou atacadas por pragas).

A fase de preparação consiste de dois subprocessos: a moagem e o batido. O primeiro deles, a moagem, consiste na trituração da azeitona através de um moinho de martelos, cujo objetivo é romper as células do fruto onde o azeite está armazenado. O segundo é o batido, que consiste em homogenizar a pasta das azeitonas obtida da moagem, formando uma base oleosa contínua, apta à extração do azeite. Este procedimento é feito por uma máquina conhecida como termo-batedeira, que homogeniza as três fases da pasta (azeite, água e subproduto (*alpeorujo*), mantendo-a a uma temperatura constante (em torno de 35°C). A homogeneização é realizada para facilitar a extração do óleo no separador mecânico. As condições de operação na termo-batedeira são realmente importantes, já que podem afetar drasticamente a qualidade e a quantidade do produto final. Como se faz necessária uma boa homogeneização, a pasta é aquecida no sentido de facilitar a mistura, já que se torna mais maleável quando a temperatura aumenta. Entretanto, existe um limite máximo de temperatura a partir do qual o azeite de oliva perde em qualidade (aroma, sabor, etc.) devido ao processo de oxidação e a perda dos componentes voláteis. Assim manter a temperatura da termo-batedeira em um ponto ótimo de trabalho pode ser um dos objetivos de máxima prioridade no processo. Experiências de modelagem e controle preditivo desta fase do processo estão descritas em [12].

O estágio seguinte da extração do azeite virgem é a separação das fases do produto. Este é um processo contínuo que separa os diferentes componentes que constituem a pasta por meio de força centrífuga. Esta separação é feita através de uma centrífuga horizontal ou decantador (*decanter*). Existem dois tipos de decantador: o de três fases e o de duas fases. O primeiro separa dois componentes líquidos (azeite e água de refugo) da parte sólida (bagaço). O segundo, usado nesta aplicação, separa apenas o azeite de oliva virgem do subproduto. No sentido de melhorar a separação, a pasta que entra no decantador deve ser acomodada. Seu fluxo deve ser controlado em uma referência que depende das condições de operação. Alguma quantidade de água pode ser adicionada ao processo, dependendo das propriedades da matéria-prima.

Finalmente, a última etapa do sistema consiste na armazenagem e na conservação do azeite obtido.

Diversos fatores afetam o processo de extração do azeite de oliva. A qualidade do produto final e o rendimento industrial são influenciados por diferentes variáveis do processo. A seguir, far-se-á uma descrição destas variáveis mais importantes.

- Temperatura na termo-batedeira. O aquecimento da pasta tem que ser constante e gradual, pois mudanças abruptas afetam negativamente a qualidade do produto final. Duas dificuldades principais podem ocorrer: primeiramente a existência de grandes atrasos devido a natureza térmica do processo, além daquela causada pelo mecanismo *on-off* de alimentação da pasta na termo-batedeira, que podem levar a mudança de temperatura da mistura.
- Tempo de residência. Outro fator importante a ser considerado é o tempo de mistura (tempo de residência) dentro da termo-batedeira. Um curto tempo leva a uma mistura incompleta, não-homogênea, já um longo tempo pode dar origem a emulsões, que interferem no processo de extração.
- Consistência da pasta. A consistência da pasta fornece informação sobre o grau de diluidade da mesma, que está associado a umidade da azeitona. Este valor tem grande influência sobre a quantidade de água que deve ser adicionada à pasta antes de que ela entre no decantador.
- Fluxo da pasta para decantador. O fluxo de pasta para o decantador bem como a proporção água/massa determinam o máximo rendimento industrial. O fluxo de massa é ajustável de acordo com o tipo de azeitona.
- Fluxo de água para decantador. Este também determina a eficiência da extração. A quantidade de água que é introduzida no decantador deve ser constante; isto é, a soma da água proveniente da azeitona com a água adicionada ao sistema deve permanecer constante. Como é sabido, a matéria-prima não contém uma umidade homogênea, o que leva a ajustar continuamente o fluxo de água no sentido de extrair a máxima quantidade de azeite no decantador.

Na maioria das indústrias de extração de azeite de oliva, o processo é controlado manualmente, já que muitos fatores podem afetar a produção. Existem muitos objetivos a serem atendidos e o operador usa sua experiência para manter o sistema sob controle. Esta situação justifica o uso de um controlador preditivo multivariável, que esteja apto a manipular diversos atuadores com o objetivo de obter um desempenho desejado no sistema.

D.2 Identificação do Modelo

A maioria dos processos na indústria, quando considerando pequenas mudanças em torno de um ponto de operação, pode ser descrita por um modelo linear, normalmente, de alta ordem. Estes modelos costumam ser difíceis de controlar mas, felizmente, é possível aproximar o comportamento de tais processos de alta ordem por um sistema com uma constante

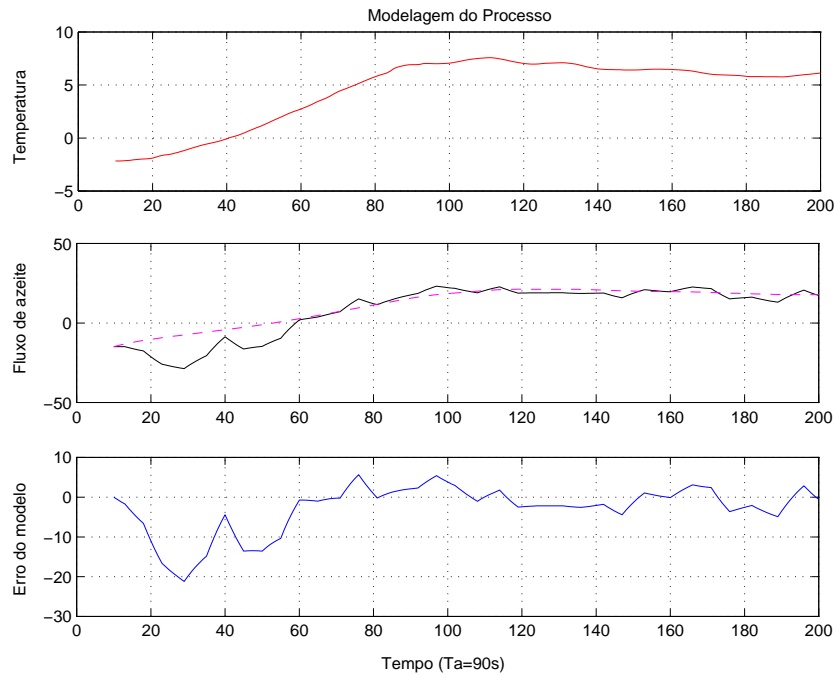


Figura D.2: Modelagem do fluxo de azeite em relação à temperatura da termo-batedeira.

Note que a precisão do ajuste do modelo aos dados reais é suficientemente boa para os propósitos de controle, apesar de sua simplicidade. Melhores resultados podem ser obtidos com modelos de ordem mais alta, mas pagando o custo da perda de simplicidade. Maiores detalhes sobre a identificação do modelo da planta podem ser encontrados em [12] e [96].

D.3 Controle do Processo

Para o controle da planta, o Departamento de Engenharia de Sistemas e Automática da *Escuela Superior de Ingenieros* da Universidade de Sevilla (Espanha) desenvolveu um controlador SPGPC com restrições, como parte integrante de um sistema de controle distribuído, equivalente aos relatados nos apêndices B e C, só que em escala industrial. O sistema é constituído pelo *software* implementado em Visual C++ dando suporte ao controlador SPGPC, um SCADA usado para resolver os requerimentos relacionados ao processamento de dados e à automação de baixo nível, e finalmente um controlador lógico programável (PLC), que executa o *software* programado para o SCADA e gerencia a conexão com a planta real. Este controlador foi implementado à indústria durante a produção de azeite (e safra de azeitonas) de 2000 (entre novembro/2000-fevereiro/2001). A presença do controlador SPGPC proporcionou melhorias no desempenho do sistema, pela restrição do valor da principal variável

do processo, a temperatura da termo-batedeira. Com esta temperatura controlada, a indústria passou a ter maior rentabilidade. Devido a estes avanços, a possibilidade de aplicar novas estratégias de controle MPC, com a inclusão de diferentes funções objetivos, especialmente de ordem econômica, foi vislumbrada como uma nova área de pesquisa dentro das expectativas da indústria em questão, o que foi realizado no seguinte ano (safra 2001-2002).

Referências Bibliográficas

- [1] F. Alcahud e C. Bordons. Control y supervisión de una planta solar de aire acondicionado. *PFC, Escuela Superior de Ingenieros, Universidad de Sevilla*, 2001.
- [2] T. Alvarez e C. Prada. Handling Infeasibility in Predictive Control . *Computers and Chemical Engineering*, 21:577–582, 1997.
- [3] P. Ansay e V. Wertz. Model Uncertainties in GPC: A Systematic Two-Step Design. Em *Proceedings of the ECC 97*, Brussels, Julho 1997.
- [4] K.J. Astrom e T. Hagglund. *PID Controllers: Theory, Design and Tuning*. Instrument Society of America, 1995.
- [5] K.J. Astrom, C.C. Hang, e B.C. Lim. A new Smith predictor for controlling a process with a integrator and long dead-time. *IEEE Transactions on Automatic Control*, 39(2):343–345, 1994.
- [6] A. Bemporad, G. Ferrari-Trecate, D. Mignone, M. Morari, e F.D. Torrise. A framework for control, fault detection, state estimation and verification of hybrid systems. Em *Proceedings of the American Control Conference*, páginas 134–138, San Diego, EUA, 1999.
- [7] A. Bemporad, G. Ferrari-Trecate, D. Mignone, M. Morari, e F.D. Torrise. Model predictive control - Ideas for the next generation. Em *Proceedings of the European Control Conference*, Karlsruhe, Germany, 1999.
- [8] A. Bemporad e M. Morari. Control of systems integrating logic, dynamics and constraints. *Automatica*, 35:407–427, 1999.
- [9] A. Bemporad e E. Mosca. Constraint fulfilment in feedback control via predictive reference management. *Proceedings 3rd IEEE CCA*, páginas 1909–1914, 1994.
- [10] Q. Bi, W. Cai, e E. Lee et al. Robust identification of first-order plus dead-time model from step response. *Control Engineering Practice*, 7:71–77, Janeiro 1999.

- [11] C. Bordons e E.F. Camacho. A generalized predictive controller for a wide class of industrial processes. *IEEE Transactions on Control Systems Technology*, 6(3):372–387, Maio 1998.
- [12] C. Bordons e J.R. Cueli. Modeling and predictive control of an olive oil mill. Em *European Control Conference*, Porto, 2001.
- [13] E.F. Camacho. Constrained generalized predictive control. *IEEE Transactions on Automatic Control*, 38(2):327–332, 1993.
- [14] E.F. Camacho, M. Berenguel, e F. R. Rubio. *Advanced Control of Solar Plants*. Springer Verlag, 1997.
- [15] E.F. Camacho e C. Bordons. *Model Predictive Control in Process Industry*. Springer Verlag, 1995.
- [16] E.F. Camacho e C. Bordons. *Model Predictive Control*. Springer Verlag, 1999.
- [17] T. M. Cavalier, P.M. Pardalos, e A.L. Soyster. Modeling and integer programming techniques applied to propositional calculus. *Computers Opns Res.*, 17(6):561–570, 1990.
- [18] Y. Censor. Pareto optimality in multiobjective problems. *Appl. Math. Optimization*, 4:41–59, 1977.
- [19] I.L. Chien e P.S. Fruehauf. Consider IMC tuning to improve performance. *Chem. Eng. Progress*, 10:33–, 1990.
- [20] L. Civantos. *Obtención del Aceite de Oliva Virgen*. Ed. Agrícola Española, S.A, 1999.
- [21] D.W. Clarke e P.J. Gawthrop. Self tuning control. *Proceedings IEE*, 123:633–640, 1979.
- [22] D.W. Clarke e C. Mohtadi. Properties of generalized predictive control. *Automatica*, 25(6):859–875, 1989.
- [23] D.W. Clarke, C. Mohtadi, e P.S. Tuffs. Generalized Predictive Control. Part I: The Basic Algorithm. *Automatica*, 23(2):137–148, 1987.
- [24] D.W. Clarke, C. Mohtadi, e P.S. Tuffs. Generalized Predictive Control. Part II: Extensions and Interpretations. *Automatica*, 23(2):149–160, 1987.
- [25] D.W. Clarke e R. Scattolini. Constrained receding-horizon predictive control. *Proceedings IEE*, 138(4):347–354, 1991.
- [26] J.L. Cohon. Multiobjective programming and planning. *Academic Press, UK*, 1978.

- [27] T. Coleman, M. A. Branch, e A. Grace. *Optimization Toolbox User's Guide*. The Math Works Inc., 1999.
- [28] C.R. Cutler e B.L. Ramaker. Dynamic matrix control - a computer control algorithm. Em *Automatic Control Conference*, San Francisco, 1980.
- [29] A. Datta e J. Ochoa. Adaptive Internal Model Control: Design and Stability Analysis. *Automatica*, 32(2):261–266, 1996.
- [30] J.A. Delgado, F. Alcahud, C. Bordons, e F.R. Rubio. Control integral de una planta de climatización solar. Em *Proceedings JA'00*, Sevilla, 2000.
- [31] J.A. Delgado e C. Bordons. Modelado y simulación de una planta solar de climatización. *PFC, Escuela Superior de Ingenieros, Universidad de Sevilla*, 2000.
- [32] S. Dormido. Una revisión de las tecnologías de control predictivo basado en modelos en la industria. Em *Workshop sobre Estado y Perspectivas del Control Predictivo*, Valladolid, Spain, 1987.
- [33] G. Favier e D. Dubois. A review of k-step-ahead predictors. *Automatica*, 26(1):75–84, 1990.
- [34] R. Fletcher e S. Leyffer. Numerical experience with lower bounds for MIQP branch-and-bound. *Technical Report, University of Dundee*, 1995.
- [35] C. E. Garcia e M. Morari. Internal model control 1: A unified review and some new results. *Ind. Eng. Chem. Process Des. Dev.*, 21:308–, 1982.
- [36] C.E. Garcia, D.M. Prett, e M. Morari. Model Predictive Control: Theory and Practice - A Survey. *Automatica*, 25:335–348, 1989.
- [37] F. W. Gembicki. *Vector Optimization for Control with Performance and Parameter Sensitivity Indices*. PhD thesis, Case Western Reserve University, 1974.
- [38] J. Gómez-Ortega e E. F. Camacho. Neural network MBPC for mobile robots path tracking. *Robotics and Computer Integrated Manufacturing Journal*, 11(4):271–278, Dezembro 1994.
- [39] G. Goodwin e K. Sin. *Adaptive Filtering Prediction and Control*. Prentice Hall, 1984.
- [40] J.R. Gossner, B. Kouvaritakis, e J.A. Rossiter. Stable Generalized Predictive Control with Constraints and Bounded Disturbances. *Automatica*, 33:551–568, 1997.
- [41] T. Hagglung. An industrial dead-time compensating PI controller. *Control Engineering Practice*, 4(6):749–756, 1996.

- [42] Y. Halevi. Optimal reduced order model with delay. Em *Proceedings of 30th Conf. on Decision and Control*, páginas 602–607, Brighton, UK, 1991.
- [43] C.C. Hang e D. Chin. Reduced order process modelling in self-tuning control. *Automatica*, 27(3):529, 1991.
- [44] E.C. Kerrigan. *Robust Constraint Satisfaction: Invariants Sets and Predictive Control*. PhD thesis, Control Group, University of Cambridge, UK, 2000.
- [45] E.C. Kerrigan, A. Bemporad, D. Mignone, M. Morari, e J.M. Maciejowski. Multi-objective prioritisation and reconfiguration for the control of constrained hybrid systems. Em *Proceedings of the American Control Conference*, 2000.
- [46] E.C. Kerrigan e J.M. Maciejowski. Designing model predictive controllers with prioritised constraints and objectives. Em *Congress of Control Applications*, Glasgow, 2002.
- [47] R.M.C. De Keyser e A.R. Cuawenberghe. Extended prediction self adaptive control. Em *IFAC Simp. on Ident. and Syst. Parameter Estimation*, páginas 1317–1322, York, 1985.
- [48] R.M.C. De Keyser, P.G.A. Van de Velde, e F.A.G. Dumortier. A comparative study of self-adaptive long-range predictive control methods. *Automatica*, 24:149–163, 1988.
- [49] A. G. Kutnetsov e D. W. Clarke. *Advances in Model Based Predictive Control. Chapter: Application of constrained GPC for improving performance of controlled plants*. Oxford University, 1994.
- [50] J. H. Lee e Z. H. Yu. Tuning od model predictive controllers for robust performance. *Computers & Chemical Engineering*, 18(1):15, 1994.
- [51] J.H. Lee, M. Morari, e C.E. Garcia. State Space Interpretation of Model Predictive Control. *Automatica*, 30(4):707–714, 1994.
- [52] M.R. Matausek e A.D. Micic. A modified Smith predictor for controlling a process with a integrator and long dead-time. *IEEE Transactions on Automatic Control*, 41(8):1199–1203, Agosto 1996.
- [53] M.R. Matausek e A.D. Micic. On the modified Smith predictor for controlling a process with a integrator and long dead-time. *IEEE Transactions on Automatic Control*, 44(8):1603–1606, Agosto 1999.
- [54] T.A. Meadowcroft, G. Stephanopolos, e C. Brosilow. The modular multivariable controller i: Steady-state proprieties. *AIChE Journal*, 38(8):1254–1278, Agosto 1992.
- [55] D. Megias, J. Serrano, e C. de Prada. Uncertainty treatment in GPC: Design of T polynomial. Em *Proceedings ECC 97*, páginas FR–A B1, Brussels, Julho 1997.

- [56] M. Morari. Hybrid systems analysis and control via mixed integer optimization. *AIChE Symposium Series*, 98(326):136–149, 2002.
- [57] M. Morari e J.H. Lee. Model predictive control: Past, present and future. *Computers & Chemical Engineering*, páginas 23:667–682, 1999.
- [58] M. Morari e N. L. Ricker. *Model Predictive Control Toolbox User's Guide*. The Math Works Inc., 1994.
- [59] M. Morari e E. Zafiriou. *Robust Process Control*. Prentice Hall, 1989.
- [60] E. Mosca. *Optimal, Predictive and Adaptive Control*. Prentice Hall, 1995.
- [61] J. E. Normey-Rico. *Predicción para Control*. PhD thesis, Escuela Superior de Ingenieros, Universidad de Sevilla, 1999.
- [62] J.E. Normey-Rico. Controle preditivo de processos com grandes atrasos de transporte. Em *Proceedings of CBA'00*, Florianópolis, Brazil, Setembro 2000.
- [63] J.E. Normey-Rico, I. Alcalá, J. Gómez-Ortega, e E.F. Camacho. Mobile robot path tracking using a robust PID controller. *Control Engineering Practice*, 9:1209–1214, 2001.
- [64] J.E. Normey-Rico, C. Bordons, e E.F. Camacho. Improving the robustness of dead-time compensating PI controllers. *Control Engineering Practice*, 5(6):801–810, Junho 1997.
- [65] J.E. Normey-Rico e E.F. Camacho. Dead-time compensators: A unified approach. Em *Proceedings of IFAC-LDTS'98*, páginas 141–146, Grenoble, France, Julho 1998.
- [66] J.E. Normey-Rico e E.F. Camacho. Ensino do projeto de compensadores para sistemas com atraso. *Internal report. DAS-J01*, 1998.
- [67] J.E. Normey-Rico e E.F. Camacho. Robust tuning of dead-time compensators for processes with an integrator and long dead-time. *IEEE Transactions on Automatic Control*, 44(8):1597–1603, 1999.
- [68] J.E. Normey-Rico e E.F. Camacho. Robustness effects of a prefilter in Smith predictor based generalized predictive controller. *IEE Proceedings, Control Theory and Applications*, 146(2):179–185, 1999.
- [69] J.E. Normey-Rico e E.F. Camacho. Smith predictor and modifications: A comparative study. Em *Proceedings of ECC99*, Germany, Agosto 1999.
- [70] J.E. Normey-Rico e E.F. Camacho. A multivariable Smith predictor based generalised predictive controller. *IEE Proceedings, Control Theory and Applications*, 147:538–546, 2000.

- [71] J.E. Normey-Rico e E.F. Camacho. Robust design of GPC for processes with time delay. *International Journal of Robust Nonlinear Control*, 10:1105–1127, 2000.
- [72] J.E. Normey-Rico, E.F. Camacho, e C. Bordons. Robustness analysis for generalized predictive controllers for industrial processes. Em *Proceedings of Control 96*, Porto, Setembro 1996.
- [73] A. Núñez-Reyes, C.B. Scheffer-Dutra, e C. Bordons. Comparison of different predictive controllers with multi-objective optimization. Application to an olive oil mill. Em *Congress of Control Applications*, páginas 1242–1247, Glasgow, 2002.
- [74] M. Ohshima, I. Hashimoto, T. Takamatsu, e H. Ohno. Robust stability of model predictive control (MPC). *Int. Chem. Eng.*, 31(1):119, 1991.
- [75] Z.J. Palmor. Stability properties of Smith dead-time compensator controller. *Int. J. Control*, 32:937–949, 1980.
- [76] Z.J. Palmor. Properties of optimal stochastic control systems with dead-time. *Automatica*, 18:107–116, 1982.
- [77] Z.J. Palmor. *The Control Handbook. Time Delay Compensation: Smith Predictor and its Modifications*. CRC Press and IEEE Press, 1996.
- [78] Z.J. Palmor e D.V. Powers. Improved dead time compensator controllers. *AIChE-Journal*, 31:215–221, 1985.
- [79] Z.J. Palmor e R. Shinnar. Design of sampled data controllers. *Ind. Eng. Chem. Process Des. Dev.*, 18:8–30, 1979.
- [80] C. Prada, J. Serrano, P. Vega, e M.A. Piera. *Advances in Model Based Predictive Control. Chapter: A Comparative Study of DMC and GPC Controllers*. Oxford University, 1994.
- [81] D.M. Prett e M. Morari. Optimization and constrained multivariable control of a catalytic cracking unitworkshop. Em *Proceedings of the Joint Automatic Control Conference*, 1980.
- [82] S. J. Qin e T. A. Badgwell. An overview of industrial model predictive control technology in chemical process control: Assessment and new directions for research. *AIChE Symposium Series*, 316, 93:232–256, 1997.
- [83] R. Raman e I.E. Grossmann. Relation Between MILP Modeling and Logical Inference for Chemical Process Synthesis. *Computers & Chemical Engineering*, 15(2):73–84, 1991.
- [84] K.Yamuna Rani e H. Unbehauen. Study of predictive controller tuning methods. *Automatica*, 33(12):2243–2248, 1997.

- [85] J. Rawlings. Tutorial overview of model predictive control. *IEEE Control Systems Magazine*, páginas 38–52, Junho 2000.
- [86] J. Rawlings e K. Muske. The stability of constrained receding-horizon predictive control. *IEEE Transactions on Automatic Control*, 38:1512–1516, 1993.
- [87] J.B. Rawlings e K.R. Muske. The stability of constrained receding horizon control. *IEEE Transactions on Automatic Control*, páginas 38:1512–1516, 1993.
- [88] J. Richalet. Industrial applications of model based predictive control. *Automatica*, 29(5):1251–1274, 1993.
- [89] J. Richalet, A. Rault, J.L. Testud, e J. Papon. Algorithm Control for Industrial Processes. Em *Proceedings 4th IFAC Symp. on Identification and System Parameter Estimation*, Tbilisi, URSS, 1976.
- [90] T. Robinson e D. Clarke. Robustness effects of a prefilter in receding-horizon predictive control. *IEE-D*, 138:2–8, 1991.
- [91] C. Santacesaria e R. Scattolini. Easy tuning of Smith predictor in presence of delay uncertainty. *Automatica*, 29:1595–1597, 1993.
- [92] A.A.M. Sayigh e J. C. McVeigh. *Solar Air Conditioning and Refrigeration*. Pergamon Press, 1992.
- [93] C.B. Scheffer-Dutra e J. E. Normey-Rico. Un DMC simplificado para control de procesos con retardo. Em *Proceedings of XXII Jornadas de Automática*, Barcelona, 2001.
- [94] C.B. Scheffer-Dutra, J. E. Normey-Rico, e E.B. Castelan. Robustness analysis of DMC for first order plus dead-time processes. Em *Proceedings of the 15th IFAC World Congress*, Barcelona, Julho 2002.
- [95] C.B. Scheffer-Dutra, A. Núñez-Reyes, e C. Bordons. Controle preditivo com restrições aplicado a uma planta solar de climatização. Em *XIV Congresso Brasileiro de Automática*, páginas 2798–2803, Natal, Setembro 2002.
- [96] C.B. Scheffer-Dutra, A. Núñez-Reyes, e C. Bordons. Predictive control of an olive oil mill with multi-objective prioritization. Em *Proceedings of the 15th IFAC World Congress*, Barcelona, Julho 2002.
- [97] P. Scokaert e D. W. Clarke. *Advances in Model Based Predictive Control. Chapter: Stability and Feasibility en Constrained Predictive Control*. Oxford University, 1994.
- [98] P. M. Scokaert e J.B. Rawlings. Feasibility issues in model predictive control. *AIChE Journal*, 45(8):1649–1659, Agosto 1999.

- [99] R. Shridar e D.J. Cooper. A tuning strategy for unconstrained siso model predictive control. *Ind. Eng. Chem. Res.*, 36:729–746, 1997.
- [100] O. J. M. Smith. Closed control of loops with dead-time. *Chem. Eng. Progress*, 53:217–219, 1957.
- [101] O. J. M. Smith. *Feedback Control Systems*. Mc Graw Hill, 1958.
- [102] R. Soeterboek. *Predictive Control: A Unified Approach*. Prentice Hall, 1992.
- [103] H. Takatsu, T. Itoh, e M. Araki. Future needs for the control theory in industries - report and topics of the control technology survey in the japanese industry. *Journal of Process Control*, 8(5-6):369–374, 1998.
- [104] K.K. Tan, Q. G. Wang, T. H. Lee, e Q. Bi. New approach to analysis and design of Smith predictor controllers. *AIChE Journal*, 42(6):1793–1797, 1996.
- [105] M. L. Tyler e M. Morari. Propositional logic in control and monitoring problems. *Automatica*, 35:565–582, 1999.
- [106] J. Vada, O. Slupphaug, e B.A. Foss. Infeasibility handling in linear MPC subject to prioritized constraints. Em *Proceedings of the IFAC'99 World Congress*, Beijing, China, 1999.
- [107] J. Vada, O. Slupphaug, e T.A. Johansen. Efficient infeasibility handling in linear MPC subject to prioritized constraints. Em *Proceedings of the European Control Conference*, Germany, 1999.
- [108] K. Watanabe e M. Ito. A process-model control for linear systems with delay. *IEEE Transactions on Automatic Control*, 26(6):1261–1269, 1981.
- [109] B.E. Ydstie. Extended horizon adaptive control. Em *9th IFAC World Congress*, Budapest, Hungary, 1984.
- [110] T. Yoon e D. Clarke. Observer design in receding-horizon control. *Int. Journal of Control*, 2:171–191, 1995.
- [111] T. Yoon e D.W. Clarke. Receding-horizon predictive control with exponential weighting. Em Oxford University, editor, *Technical Report OUEL 1940/92*, Oxford, 1992.
- [112] T. Yoon e D.W. Clarke. Prefiltering in receding-horizon predictive control. Em *Technical Report OUEL 1995/93*. Oxford University, 1993.
- [113] A. Zheng e M. Morari. Stability of model predictive control with mixed constraints. *IEEE Transactions on Automatic Control*, 40(10):1918–1923, 1995.